

Application of the SARIMA Method for Forecasting Inflation in Malang City for the Period May-December 2026

Penerapan Metode SARIMA untuk Peramalan Inflasi Kota Malang Periode Mei-Desember 2026

Silma Istafhlaha^{1*}, Andi Daniah Pahrany², Muhammad Arief Nurohman³

¹²Department of Mathematics, State University of Malang, ³Statistics of Batu Municipality
Email: ¹sistafhlaha@gmail.com, ²andi.daniah.fmipa@um.ac.id, ³ariefnurohman@bps.go.id

*Corresponding author

Received: 8 June 2026, revised: 27 August 2026, accepted: 30 August 2026

Abstract

Inflation is an important indicator in maintaining economic stability. Inflation is defined as a general increase in the prices of goods and services. The government and Bank Indonesia have agreed to set the inflation target range for 2026 at $2,5 \pm 1\%$. Although the government has set the inflation target range, regional characteristics can influence inflation. Inflation YoY in Malang City in 2026 can be predicted using the SARIMA forecasting method. The stages in forecasting using ARIMA $(p, d, q) \times (P, D, Q)_s$ include data analysis, data stationarity, model development, model testing, error calculation, and forecasting. Forecasting of Malang City's Inflation YoY in 2026 was carried out using the ARIMA $(0,1,1) \times (0,0,1)_{12}$ model, which produced a MAPE of 11% and a MAD of 0.27. The forecasted Inflation YoY for 2026 reached 2.60%, indicating that in 2026, inflation YoY was within the range set by the government. The results obtained from this forecast are based on only univariate approach, namely historical data.

Keywords: Inflation, Malang City, SARIMA

Abstrak

Dalam menjaga stabilitas perekonomian, inflasi menjadi salah satu indikator penting. Inflasi didefinisikan sebagai suatu peristiwa kenaikan harga barang dan jasa secara umum. Pemerintah dan Bank Indonesia sepakat menetapkan kisaran sasaran inflasi pada tahun 2026 berada di angka $2,5 \pm 1\%$. Meskipun pemerintah menetapkan kisaran sasaran inflasi tersebut, akan tetapi adanya faktor karakteristik daerah dapat mempengaruhi inflasi. Inflasi YoY di Kota Malang Tahun 2026 dapat diramalkan menggunakan metode peramalan SARIMA. Tahapan dalam meramalkan menggunakan ARIMA $(p, d, q) \times (P, D, Q)_s$ meliputi analisis data, stasioneritas data, pembangunan model, pengujian model, perhitungan *error*, dan peramalan. Peramalan Inflasi YoY Kota Malang 2026 dilakukan dengan menggunakan model ARIMA $(0,1,1) \times (0,0,1)_{12}$ yang menghasilkan MAPE sebesar 11% dan MAD 0,27. Hasil peramalan Inflasi YoY tahun 2026 mencapai angka 2,60% yang menunjukkan bahwa pada tahun 2026, Inflasi YoY berada di dalam kisaran yang ditetapkan pemerintah. Hasil yang diperoleh dari peramalan ini hanya berdasarkan pada pendekatan univariat, yaitu data historis.

Kata kunci: Inflasi, Kota Malang, SARIMA



1. PENDAHULUAN

Inflasi termasuk ke dalam faktor yang berperan dalam mempengaruhi pertumbuhan ekonomi negara [24]. Dapat dikatakan inflasi memiliki kaitan erat dengan pertumbuhan ekonomi. Inflasi didefinisikan sebagai suatu peristiwa kenaikan harga barang dan jasa secara umum [29]. Pemerintah dan Bank Indonesia sepakat menetapkan kisaran sasaran inflasi pada tahun 2026 berada di angka $2,5 \pm 1\%$. Sasaran inflasi tersebut sepakat ditetapkan dengan tujuan memperkuat sinergi dan koordinasi untuk mengendalikan inflasi [6]. Meskipun pemerintah menetapkan kisaran sasaran inflasi tersebut, akan tetapi adanya faktor karakteristik daerah dapat mempengaruhi inflasi.

Peneliti terdahulu telah melakukan banyak penelitian mengenai peramalan inflasi dengan menerapkan berbagai metode, seperti peramalan laju inflasi mingguan di Kota Surabaya menggunakan pendekatan *Multivariate Long Short Term Memory* (LSTM) [27]. Peramalan ini dilakukan berbasis komoditas makanan. Selain itu, terdapat penelitian mengenai peramalan inflasi dan arus kas keluar menggunakan pendekatan *Spatial Vector Autoregressive with Metric Exogenous Variable* (SpVARX) di wilayah Jawa Tengah [34]. Peramalan tersebut menunjukkan hubungan wilayah dan arus kas keluar terhadap inflasi daerah. Disisi lain, terdapat penelitian mengenai peramalan inflasi di Kota Padang menggunakan metode SARIMA [11]. Peramalan dilakukan berdasarkan data historis inflasi bulanan Kota Padang. Ketiga penelitian tersebut menunjukkan bahwa inflasi tiap daerah dipengaruhi oleh karakteristik daerah. Penerapan metode dan model pada suatu daerah tidak dapat dipukul rata untuk meramalkan inflasi pada daerah yang lain. Oleh karena itu, perlu dilakukan penerapan metode dan model khusus untuk Kota Malang yang disesuaikan dengan karakteristik kota Malang.

Kota Malang merupakan kota terbesar kedua di Jawa Timur setelah Surabaya [5]. Inflasi Year on Year (YoY) Kota Malang pada Januari 2026 menempati angka 3,33%, kemudian pada bulan Februari menyentuh angka 4,81%. Bulan Maret 2026 berada di angka 3,75% dengan didominasi oleh komoditas tarif listrik, emas perhiasan, daging ayam ras, beras dan telur ayam ras. Serta data terakhir yang tersedia, yaitu April 2026 sebesar 2,70% [4]. Inflasi YoY Kota Malang tahun 2026 tentunya belum diketahui akan berada pada sasaran kisaran yang ditetapkan pemerintah atau tidak. Akan tetapi, inflasi pada bulan yang belum diketahui dapat diramalkan dengan menggunakan pendekatan matematis.

Peramalan didefinisikan sebagai suatu proses menganalisis yang bertujuan untuk memprediksi nilai di masa depan berdasarkan data, fakta historis, atau tren yang telah tersedia [31]. Peramalan dilakukan dengan cara mengumpulkan data yang ada pada masa lampau yang selanjutnya diolah dengan menerapkan metode peramalan [37]. Pada peramalan perlu diterapkan metode-metode guna meminimalisir kesalahan dan menghasilkan peramalan yang mendekati kondisi nyata. Peramalan yang dilakukan secara manual seringkali menghasilkan peramalan yang tidak akurat [30]. Zega [37] juga menyatakan bahwa peramalan berperan penting dalam menyusun perencanaan guna mengambil kebijakan yang sesuai. Salah satu metode peramalan yang ada ialah ARIMA.

ARIMA (*Autoregressive Integrated Moving Average*) merupakan suatu metode yang menghasilkan model peramalan jangka pendek akurat dengan sepenuhnya memanfaatkan data deret waktu (*time series*) dan mengesampingkan variabel independen [10]. Secara umum proses ARIMA menghasilkan model ARIMA (p, d, q) dengan p menyatakan derajat *autoregressive* (AR), d menyatakan banyaknya proses *differencing*, dan q menyatakan derajat *moving average* (MA) [14]. Lebih jauh lagi terdapat SARIMA yang merupakan perluasan ARIMA. Maksud dari perluasan adalah ARIMA memiliki kekurangan dalam mengindikasikan adanya pola musiman. Oleh karena itu, SARIMA menambahkan komponen musiman pada ARIMA [21].

Adanya data inflasi dengan kurun waktu panjang menunjukkan bahwa data inflasi termasuk data deret waktu. Beberapa penelitian terdahulu telah dilakukan, salah satunya yaitu peramalan laju inflasi di Indonesia menggunakan metode ARIMA [32]. Penelitian ini terbatas pada metode yang hanya

berpacu pada komponen non musiman. Disisi lain, juga terdapat peramalan inflasi menggunakan metode SARIMA di negara Philippines dan Bangladesh [8], [13]. Meskipun beberapa penelitian tersebut menunjukkan tingkat keefektifan metode yang digunakan, akan tetapi model yang diperoleh terbatas pada lingkup nasional serta berbeda dengan lingkup daerah. Adanya perbedaan karakteristik negara mengakibatkan model tidak dapat disamaratakan untuk meramalkan inflasi pada tingkat daerah di Indonesia. Juga terdapat penelitian Henderi & Sofiana [15] yang melakukan peramalan inflasi menggunakan model tradisional dan modern. Peneliti menyatakan model tradisional seperti ARIMA dan SARIMA memiliki keterbatasan dalam menangani pola non-linear dan perubahan yang mendadak. Akan tetapi, kedua model tersebut efektif dalam menangkap tren dan musiman.

Penelitian terdahulu terkait peramalan inflasi di Kota Malang terbatas pada penggunaan data periode lama. Hal tersebut menunjukkan belum adanya peramalan inflasi dengan kondisi Kota Malang untuk periode terbaru. Guna memenuhi keterbaruan tersebut, penelitian ini melakukan peramalan Inflasi YoY di Kota Malang pada bulan Mei 2026 - Desember 2026 menggunakan metode SARIMA. Peramalan ini dilakukan guna mengetahui Inflasi YoY Kota Malang tahun 2026 akan berada di kisaran $2,5 \pm 1\%$ atau tidak. Penelitian ini terbatas pada peramalan yang hanya didasarkan pada data historis Inflasi YoY Kota Malang tahun 2016 - 2026, tanpa melihat faktor lain yang mempengaruhi. Penelitian ini diharapkan menghasilkan peramalan yang presisi sehingga dapat menjadi salah satu pedoman yang berbasis data historis. Pedoman tersebut dapat digunakan oleh pemerintah Kota Malang, Tim Pengendalian Inflasi Daerah (TPID) dalam merencanakan kebijakan terkait inflasi untuk tahun mendatang.

2. HASIL UTAMA

2.1 SARIMA (*Seasonal Autoregressive Integrated Moving Average*)

ARIMA (*Autoregressive Integrated Moving Average*) merupakan metode yang mengacuhkan variabel independen dan melakukan peramalan dengan menggunakan nilai di masa lampau sebagai variabel dependen. Metode ini dinotasikan ARIMA (p, d, q) [32]. Lebih jauh, terdapat SARIMA yang merupakan perluasan dari metode ARIMA yang sering dimanfaatkan dalam analisis deret waktu. SARIMA diaplikasikan ketika data deret waktu yang dimiliki memuat pola musiman. Pola musiman ditandai dengan terjadinya pola yang berulang pada selang waktu yang tetap [20]. Metode SARIMA meliputi beberapa komponen diantaranya orde p sebagai komponen non musiman *Autoregressive* (AR), orde P pada lag s sebagai komponen *Seasonal Autoregressive* (SAR), orde q sebagai komponen non musiman *Moving Average* (MA), dan orde Q pada lag s sebagai komponen *Seasonal Moving Average* (SMA). Sedangkan, *differencing* dari komponen non musiman dan musiman berturut-turut diwakili oleh orde d dan D pada lag s . Sehingga SARIMA dinotasikan sebagai ARIMA (p, d, q) $\times$ (P, D, Q)_s [2]. Persamaan metode SARIMA ditampilkan sebagai berikut [16].

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - \phi_1 B^s - \phi_2 B^{2s} - \dots - \phi_p B^{Ps})(1 - B)^d (1 - B^s)^D y_t = (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q)(1 + \theta_1 B^s + \theta_2 B^{2s} + \dots + \theta_q B^{Qs})e_t \quad (1)$$


Keterangan:

y_t	: banyaknya data deret waktu
B	: operator <i>backshift</i> ($B^k y_t = y_{t-k}$)
e_t	: <i>error</i>
$\phi_1, \phi_2, \dots, \phi_p$	: parameter <i>autoregressive</i>
$\theta_1, \theta_2, \dots, \theta_q$	: parameter <i>moving average</i>
$\phi_1, \phi_2, \dots, \phi_P$	: parameter musiman <i>autoregressive</i>

$\theta_1, \theta_2, \dots, \theta_Q$: parameter musiman *moving average*
 d : orde *differencing* non musiman
 D : orde *differencing* musiman
 s : periode musiman

2.2 Tahapan Penelitian

Untuk mencapai tujuan pada penelitian ini dilakukan beberapa tahapan yang ditampilkan pada *flowchart* berikut.



Gambar 2.1. *Flowchart Tahapan Penelitian*

2.2.1 Analisis Data

Tahap analisis data terbagi menjadi 3 bagian, yaitu pengelompokan data, deskriptif statistik data, dan pembuatan plot data. Pada SARIMA, data dikelompokkan menjadi dua bagian, yaitu data *training* dan data *testing*. Kedua data tersebut berturut-turut berguna dalam membangun model serta menguji dan memvalidasi model. Dalam proses pembangunan dan pengujian model, data dibagi menjadi 70% data *training* dan 30% data *testing* [22]. Selanjutnya dilakukan deskriptif statistik data yang mencakup nilai minimum dan maksimum data, banyak data, serta mean dan median dari data tersebut. Pada bagian analisis data, memvisualisasikan plot data berguna untuk mengetahui pola data yang termuat seperti adanya tren, musiman, atau pola data lainnya.

2.2.2 Stasioneritas Data

Sebelum mengaplikasikan metode SARIMA suatu data harus memenuhi stasioneritas terlebih dahulu. Data telah stasioner apabila berada disekitar nilai yang sama atau memuat varians dan mean yang nilainya konstan seiring waktu [1]. Sedangkan jika nilai varians dan mean mengalami penurunan atau kenaikan yang drastis, maka data dikatakan tidak stasioner. Stasioneritas data dilakukan terhadap varians dan mean serta berlaku pada data non musiman dan musiman. Untuk mendeteksi data telah stasioner terhadap varians, dilakukan dengan menggunakan transformasi Box-cox [35]. Data dikatakan stasioner terhadap varians jika memenuhi nilai *rounded value* $\lambda = 1$ [26]. Selanjutnya, stasioneritas data terhadap mean dapat mengacu pada plot ACF (*Autocorrelation Function*) [33]. Data dikatakan stasioner terhadap mean jika pada plot ACF nya, tiga lag pertama

tidak ada yang melewati batas signifikan [28]. Data juga dikatakan stasioner terhadap mean apabila lag menunjukkan adanya penurunan secara eksponensial. Jika data belum stasioner terhadap mean, maka perlu dilakukan *differencing* [25]. Sebaliknya, jika data telah stasioner baik terhadap varians maupun mean, maka dapat dilanjutkan pada tahap pembangunan model.

2.2.3 Pembangunan Model

Pembangunan model merujuk pada pola yang ada dalam plot ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*) [19]. ACF adalah hubungan antar data pada suatu data deret waktu. Sedangkan, PACF adalah hubungan parsial antar data pada suatu data deret waktu. ACF dan PACF memiliki dua pola yang dapat dikenali. Pola *dies down* yang ditandai dengan penurunan secara perlahan mendekati nol. Pola *cut off* ditandai dengan penurunan secara drastis hingga mendekati nol setelah lag tertentu [17]. Pada komponen non musiman, orde p mengacu pada plot PACF dan orde q mengacu pada plot ACF. Sedangkan pada komponen musiman, orde P melihat pada plot PACF musiman dan orde Q melihat pada plot ACF musiman [18]. Setelah mendapatkan beberapa kandidat model, maka akan dilakukan pengujian model.

2.2.4 Pengujian Model

Pengujian model meliputi uji signifikansi parameter dan uji diagnostik. Uji diagnostik terbagi menjadi dua, yaitu uji normalitas dan uji *white noise*. Uji signifikansi dilakukan baik terhadap parameter komponen non musiman maupun musiman [17]. Berikut merupakan uji statistik dan hipotesis dari uji signifikan [23].

$$t = \frac{\hat{\theta}}{se(\hat{\theta})} \quad (2)$$

Keterangan:

$\hat{\theta}$: nilai taksiran parameter θ

$se(\hat{\theta})$: standar *error* dari nilai taksiran $\hat{\theta}$

$$H_0 : \beta_i = 0$$

$$H_1 : \beta_i \neq 0$$

Jika p -value bernilai $p < \alpha$ atau $|t| > t_{\frac{\alpha}{2}}; df = n - p$, maka H_0 ditolak dan parameter model menjadi signifikan. Model yang memenuhi uji signifikan selanjutnya dilakukan uji diagnostik. Uji diagnostik berfungsi sebagai gambaran dari kualitas model yang telah dibangun.

Untuk mengidentifikasi suatu data berdistribusi normal, maka dilakukan statistik uji Kolmogorov Smirnov. Berikut merupakan uji statistik dan hipotesis dari uji normalitas.

$$KS = \max |F_0(X) - S_n(X)| \quad (3)$$

Keterangan:

$F_0(X)$: frekuensi distribusi kumulatif di bawah distribusi normal

$S_n(X)$: fungsi distribusi kumulatif yang diamati

$$H_0 : \epsilon_t \sim N(0, \sigma^2)$$

$$H_1 : \epsilon_t \not\sim N(0, \sigma^2)$$

Jika p -value bernilai $p > \alpha$, maka terima H_0 dan residual data tersebut berdistribusi normal. Pengujian terakhir merupakan uji *white noise*. Untuk mengidentifikasi suatu data tidak memiliki autokorelasi pada residual, maka dilakukan statistik uji Ljung-Box. Berikut merupakan uji statistik dan hipotesis dari uji *white noise*.

$$Q^* = n(n+2) \sum_{k=2}^{n-k} \frac{\widehat{P_k^2}}{(n-k)} \quad (4)$$

Keterangan:

n : banyak data observasi

P_k : nilai perkiraan pada lag ke- k ACF

k : nilai lag

K : maksimum lag

H_0 : residual data tidak memuat autokorelasi

H_1 : residual data memuat autokorelasi

Jika p -value bernilai $p > \alpha$ atau $Q^* \leq x_{\alpha}^2$, $df = K - p - q$, maka terima H_0 dan data tidak ada autokorelasi pada residual.

2.2.5 Perhitungan Error

Perhitungan *error* dilakukan guna mengetahui seberapa bagus model yang dipilih. Suatu model dikatakan baik jika memiliki *error* yang cukup kecil [17]. Berikut merupakan rumus dari akurasi kesalahan model [9].

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - f_t}{y_t} \right| \times 100 \quad (5)$$

$$MAD = \frac{1}{n} \sum_{t=1}^n |y_t - f_t| \quad (6)$$

Keterangan:

y_t : nilai data aktual

f_t : nilai hasil peramalan

n : banyak data

MAPE (*Mean Absolute Percentage Error*) memiliki kelebihan utama, yaitu menghasilkan nilai berupa persentase sehingga mudah diinterpretasikan. Jika MAPE bernilai 0%, maka menunjukkan bahwa pada seluruh observasi yang dievaluasi memiliki selisih absolut sebesar nol antara nilai aktual dan hasil peramalan. Sedangkan, MAPE yang bernilai tinggi artinya peramalan yang dilakukan tidak akurat. Interpretasi nilai MAPE terhadap hasil peramalan didasarkan pada tabel berikut [17].

Tabel 2.1. Interpretasi Nilai MAPE

MAPE (%)	Interpretasi
≤ 10	Sangat Akurat
10 – 20	Baik
20 – 50	Layak
> 50	Tidak Akurat

Disisi lain terdapat MAD (*Mean Absolute Deviation*) sebagai representasi dari rata-rata selisih mutlak antara nilai hasil peramalan dengan nilai data aktual. Nilai MAD yang rendah menunjukkan bahwa model peramalan yang digunakan baik [36]. Setelah semua uji dilakukan, selanjutnya dilakukan peramalan menggunakan model terbaik dan evaluasi hasil peramalan. Model terbaik merupakan model yang memenuhi uji signifikan, uji diagnostik, dan memiliki nilai *error* terkecil [17].


2.3 Pengaplikasian SARIMA

2.3.1 Analisis Data

Data yang digunakan merupakan data Inflasi *Year on Year* (YoY) Kota Malang Januari 2016 - April 2026. Data ini diperoleh dari website resmi BPS Kota Malang. Menganut pada penelitian yang dilakukan Chinmayi [7] bahwa penggunaan data yang lebih banyak memberikan kualitas model yang lebih bagus. Selain itu terdapat berbagai rasio yang dapat digunakan dalam membagi data *training* dan data *testing*. Pembagian rasio dapat dilakukan dalam *range* 10:90 hingga 90:10.

Pada penelitian ini dimulai dengan pembagian rasio 70:30. Sebelum melakukan peramalan, data akan dikelompokkan menjadi dua bagian, yaitu menjadi 70% data *training* dan 30% data *testing*. 70% data *training* terdiri atas 87 data, meliputi data Inflasi YoY Bulan Januari 2016 - Maret 2023. Data *testing* terdiri atas 37 data, meliputi data Inflasi YoY bulan April 2023 - April 2026. Berdasarkan hasil dari pengaplikasian SARIMA, diperoleh bahwa pengelompokkan data tersebut menghasilkan nilai MAPE yang cukup besar. MAPE terkecil yang diperoleh, yaitu bernilai 197%. Kemudian, dilakukan pengelompokkan data kembali menjadi 80% data *training* dan 20% data *testing*. Hasil yang diperoleh dari pengelompokkan data tersebut menunjukkan hal yang sama. MAPE terkecil yang diperoleh, yaitu bernilai 158%. Nilai MAPE yang dihasilkan oleh pembagian data 70:30 dan 80:20 bernilai besar, karena adanya deflasi pada bulan Februari 2025 yang termasuk ke dalam himpunan data *testing*. Hal tersebut karena pada perhitungan MAPE memuat pembagian dengan nol sehingga terjadi pembesaran nilai MAPE. Sedangkan, pada pembagian data 90:10, deflasi pada bulan Februari 2025 termasuk ke dalam himpunan data *training*. Data deflasi tersebut diatasi dengan cara menambahkan konstanta pada seluruh data *training* sehingga nilai MAPE memiliki hasil yang lebih baik. Oleh karena itu dilakukan pengelompokkan data menjadi 90% data *training* dan 10% data *testing*. Pengelompokkan data ini menghasilkan peramalan yang akurat dengan MAPE sebesar 11%. Pengaplikasian SARIMA pada 90% data *training* dan 10% data *testing* dirincikan sebagai berikut.

Berdasarkan pengelompokkan data tersebut, data *training* berjumlah 112 data terdiri atas data Inflasi YoY bulan Januari 2016 - April 2025. Sedangkan, data *testing* berjumlah 12 data meliputi data Inflasi YoY bulan Mei 2025 - April 2026. Periode yang akan diramalkan merupakan Mei 2026 - Desember 2026. Berdasarkan deskriptif data, diketahui data yang digunakan sebanyak 124 data. Nilai terbesar inflasi mencapai 7,08% dan nilai terendah berada di angka -0,22% yang artinya mengalami deflasi. Mean dan median berturut-turut sebesar 2,809 dan 2,685. Plot data untuk mengetahui pola data ditampilkan pada gambar berikut.




Gambar 2.2. Plot Data Inflasi YoY Kota Malang Januari 2016 - April 2026

Diketahui bahwa grafik memuncak pada Mei 2017 yang dipengaruhi oleh kelompok pengeluaran transportasi (angkutan udara), komunikasi, tarif listrik, dan semacam jasa keuangan.

Selanjutnya terjadi penurunan dari puncak pada Juni 2018. Pada April 2020 terdapat penurunan kembali yang diantaranya disebabkan oleh komoditas daging ayam ras, angkutan udara, serta bermacam perbumbuan dapur. September 2022 terjadi lonjakan cukup drastis dengan penyumbang tertinggi diambil alih oleh transportasi. Pada September 2023 - Mei 2024 terlihat memiliki pola yang cukup sama dengan September 2018 - May 2019. Periode ini mengindikasikan adanya pola musiman pada data Inflasi YoY Kota Malang Januari 2016 - April 2026. Pada Februari 2025 terjadi deflasi yang cukup besar, yaitu berada di angka -0,22. Deflasi ini disumbang oleh kelompok perumahan, air, listrik, dan bahan bakar rumah tangga senilai 15,45%. Sedangkan, pada Februari tahun selanjutnya mengalami peningkatan kembali.

2.3.2 Stasioneritas Data


Sebelum melakukan peramalan menggunakan metode yang dipilih, data deret waktu harus telah stasioner. Pada uji ini, data *training* digunakan untuk membangun model. Uji stasioneritas terhadap varians, dilakukan menggunakan Box-Cox plot dengan mengacu pada nilai *rounded value* (λ). Karena nilai $\lambda = 1$, maka Gambar 2.3. menunjukkan bahwa data telah stasioner.



Gambar 2.3. Stasioneritas Data terhadap Varians

Setelah data stasioner terhadap varians, untuk meraih stasioneritas yang utuh juga perlu dipastikan bahwa nilai mean konstan sepanjang waktu [12]. Selanjutnya dilakukan uji stasioner data terhadap mean. Data yang stasioner terhadap mean dapat dilihat pada plot ACF yang terbentuk. Apabila lag mengalami penurunan secara perlahan (*dies down*), maka disimpulkan data belum stasioner. Berdasarkan Gambar 2.4. a) terlihat bahwa pada plot ACF mengalami *dies down*. Artinya, data belum stasioner terhadap mean dan harus dilakukan *differencing* hingga data stasioner. Pada *differencing* pertama terlihat bahwa plot ACF menurun secara eksponensial yang mengindikasikan bahwa data telah stasioner terhadap mean dengan *differencing* sebanyak satu.


Di sisi lain, pada plot ACF juga menunjukkan bahwa terdapat lag 12 yang keluar dari garis batas signifikan. Hal ini menunjukkan bahwa data memuat pola musiman. Selain pada data non musiman, stasioneritas juga berlaku pada data musiman. Data musiman disebut stasioner apabila pada lag 12, 24, 36 dan seterusnya mengalami penurunan secara eksponensial. Gambar 2.4. b) menunjukkan bahwa lag 12 sebesar -0,319 dan lag 24 sebesar -0,101. Artinya, data musiman mengalami penurunan secara eksponensial sehingga telah stasioner dan tidak perlu dilakukan *differencing seasonal*. Data yang telah stasioner baik terhadap data non musiman maupun musiman dapat dilanjutkan pada tahap pembangunan kandidat model.



Gambar 2.4. Plot ACF

2.3.3 Pembangunan Model

Kandidat model dapat dibentuk melalui plot ACF dan PACF yang telah dilakukan pada data teruji stasioner. Orde dari AR (p) merujuk pada plot PACF, sedangkan orde dari MA (q) merujuk pada plot ACF. Plot PACF Gambar 2.5. menunjukkan bahwa untuk data non musiman, tiga lag pertama berada di dalam garis batas signifikan dan hanya lag 7 dan 12 yang keluar dari garis batas signifikan. Sedangkan, plot ACF menunjukkan lag 5 berada di luar garis batas signifikan. Di sisi lain untuk data musiman, baik plot PACF maupun ACF menunjukkan *cut off* pada lag 12. Oleh karena itu, dipilih beberapa variasi kombinasi orde untuk AR non musiman, MA non musiman, AR musiman, dan MA musiman berturut-turut, yaitu AR (0), AR(1), MA (0), MA (1), SAR (0), SAR(1), SMA (0), dan SMA(1). Pemilihan orde tersebut berdasarkan pertimbangan lag 1 yang mendekati batas signifikan. Juga diperoleh $d = 1$ dan $D = 0$ karena dilakukan *differencing* non musiman sebanyak satu kali. Kandidat model yang memungkinkan disajikan pada tabel berikut.



Gambar 2.5. Plot ACF dan PACF

Tabel 2.2. Kandidat Model

$(0, 1, 0) \times (0, 0, 1)_{12}$	$(0, 1, 1) \times (1, 0, 0)_{12}$	$(1, 1, 0) \times (1, 0, 1)_{12}$
$(0, 1, 0) \times (1, 0, 0)_{12}$	$(0, 1, 1) \times (1, 0, 1)_{12}$	$(1, 1, 1) \times (0, 0, 1)_{12}$
$(0, 1, 0) \times (1, 0, 1)_{12}$	$(1, 1, 0) \times (0, 0, 0)_{12}$	$(1, 1, 1) \times (1, 0, 0)_{12}$
$(0, 1, 1) \times (0, 0, 0)_{12}$	$(1, 1, 0) \times (0, 0, 1)_{12}$	$(1, 1, 1) \times (1, 0, 1)_{12}$
$(0, 1, 1) \times (0, 0, 1)_{12}$	$(1, 1, 0) \times (1, 0, 0)_{12}$	$(1, 1, 1) \times (0, 0, 0)_{12}$

2.3.4 Pengujian Model

Berdasarkan kandidat model yang telah dibangun melalui plot ACF dan PACF, diperoleh 15 model. Model sementara tersebut akan dilakukan uji signifikansi, uji diagnostik, dan perhitungan *error*. Model terbaik dipilih berdasarkan model yang memenuhi setiap uji dan menghasilkan nilai *error* terkecil. Model dikatakan memenuhi uji signifikansi apabila nilai $p - value < 0,05$. Model yang memenuhi uji signifikansi ditampilkan pada Tabel 2.3. berikut.

Tabel 2.3. Model yang Memenuhi Uji Signifikansi

ARIMA	<i>p-value</i>	ARIMA	<i>p-value</i>
$(0, 1, 0) \times (0, 0, 1)_{12}$	SMA (12) 0,000	$(0,1,1) \times (1,0,0)_{12}$	MA (1) 0,007 SAR (12) 0,000
$(0, 1, 0) \times (1, 0, 0)_{12}$	SAR (12) 0,000	$(1,1,0) \times (0,0,0)_{12}$	AR (1) 0,035
$(0, 1, 1) \times (0, 0, 0)_{12}$	MA (1) 0,025	$(1,1,0) \times (0,0,1)_{12}$	AR (1) 0,014 SMA (12) 0,000
$(0, 1, 1) \times (0, 0, 1)_{12}$	MA (1) 0,002 SMA (12) 0,000	$(1,1,0) \times (1,0,0)_{12}$	AR (1) 0,013 SAR (12) 0,000

Pada delapan model yang memenuhi uji signifikansi, selanjutnya akan dilakukan uji diagnostik. Uji diagnostik merupakan langkah analitis dan fundamental dalam mengembangkan model guna memperoleh model yang paling sesuai [3]. Uji diagnostik terbagi menjadi dua, yaitu uji normalitas dan uji *white noise*. Model dikatakan memiliki residual yang berdistribusi normal apabila memenuhi $p - value > 0,05$ pada uji Kolmogorov-Smirnov. Sedangkan, model dikatakan tidak autokorelasi terhadap residual, apabila memenuhi $p - value > 0,05$ pada hasil yang ditampilkan Ljung Box. Tabel 2.4. menunjukkan model yang telah memenuhi uji diagnostik.

Tabel 2.4. Uji Diagnostik

ARIMA	Uji Normalitas ($p - value$)	Uji White Noise ($p - value$)
$(0, 1, 1) \times (0, 0, 1)_{12}$	0,085	Lag 12 0,646 Lag 24 0,783 Lag 36 0,557 Lag 48 0,822
$(0, 1, 1) \times (1, 0, 0)_{12}$	0,057	Lag 12 0,351 Lag 24 0,290 Lag 36 0,255 Lag 48 0,555
$(1, 1, 0) \times (0, 0, 1)_{12}$	0,087	Lag 12 0,483 Lag 24 0,636 Lag 36 0,408 Lag 48 0,708
$(1, 1, 0) \times (1, 0, 0)_{12}$	$p > 0,150$	Lag 12 0,295 Lag 24 0,227 Lag 36 0,198 Lag 48 0,473

2.3.5 Perhitungan *Error*

Berdasarkan Tabel 2.4. diperoleh empat model yang memenuhi uji signifikansi dan uji diagnostik. Berdasarkan empat model tersebut akan dilakukan validasi model dengan menggunakan data *testing*. Hasil peramalan yang diperoleh akan digunakan untuk menghitung *error* pada setiap model terpilih. Tabel 2.5. menyajikan nilai dari perhitungan *error* tiap model. Model $ARIMA (0,1,1) \times (0,0,1)_{12}$ terpilih sebagai model terbaik karena menghasilkan nilai *error* terkecil. Nilai MAPE 11% tergolong dalam peramalan yang baik.

Tabel 2.5. Perhitungan *Error*


ARIMA	MAPE	MAD
$(0, 1, 1)$	11	0,27
$\times (0, 0, 1)_{12}$		
$(0, 1, 1)$	16	0,50
$\times (1, 0, 0)_{12}$		
$(1, 1, 0)$	13	0,30
$\times (0, 0, 1)_{12}$		
$(1, 1, 0)$	15	0,43
$\times (1, 0, 0)_{12}$		

2.3.6 Peramalan

Peramalan Inflasi YoY untuk bulan Mei 2026 - Desember 2026 dilakukan pada data keseluruhan yang terdiri dari bulan Januari 2016 - April 2026. Gambar 2.6. menampilkan grafik kemungkinan peramalan. Hasil peramalan ditampilkan pada tabel berikut.

Tabel 2.6. Hasil Peramalan Inflasi YoY Kota Malang Mei - Desember 2026


Bulan	Hasil Peramalan (Persen)
Mei	2,98
Juni	2,77
Juli	2,83
Agustus	2,83
September	2,60
Oktober	2,47
November	2,63
Desember	2,60




Gambar 2.6. Plot Hasil Peramalan

2.3.7 Evaluasi Hasil Peramalan

Pemerintah dan Bank Indonesia menetapkan sasaran kisaran inflasi untuk tahun 2026 berada di rentang 1,5 - 3,5%. Berdasarkan hasil peramalan, diketahui bahwa Inflasi YoY Kota Malang Tahun 2026 berada di angka 2,60%. Hal ini menunjukkan bahwa Inflasi YoY pada tahun 2026 berada di dalam sasaran kisaran yang ditetapkan oleh pemerintah. Hasil yang diperoleh dari peramalan ini hanya berdasarkan pada satu variabel, yaitu data historis. Sehingga peramalan ini belum tentu akan sama dengan yang terjadi pada dunia nyata, mengingat bahwa inflasi dipengaruhi oleh banyak faktor. Inflasi YoY Kota Malang Tahun 2026 ditampilkan pada Gambar 2.7. Sedangkan, Gambar 2.8. menunjukkan Inflasi YoY Kota Malang Januari 2016 - Desember 2026.



Gambar 2.7. Inflasi YoY Kota Malang Tahun 2026



Gambar 2.8. Inflasi YoY Kota Malang Januari 2016 - Desember 2026

3. KESIMPULAN

Peramalan Inflasi YoY Kota Malang Mei 2026 - Desember 2026 dilakukan dengan menggunakan model $ARIMA(0,1,1) \times (0,0,1)_{12}$. Model ini dipilih karena memenuhi uji signifikansi, uji diagnostik, dan menghasilkan *error* terkecil dibanding dengan model yang lain. MAPE sebesar 11% menunjukkan bahwa peramalan memuat tingkat kesalahan sebesar 11%. Peramalan juga menghasilkan perhitungan MAD sebesar 0,27. Hasil peramalan Inflasi YoY tahun 2026 mencapai angka 2,60% yang menunjukkan bahwa pada tahun 2026, Inflasi YoY berada di dalam kisaran yang ditetapkan pemerintah. Hasil yang diperoleh dari peramalan ini hanya berdasarkan pada pendekatan univariat, yaitu data historis. Sehingga peramalan ini belum tentu akan sama dengan yang terjadi di dunia nyata, mengingat bahwa inflasi dipengaruhi oleh banyak faktor. Penelitian ini diharapkan dapat menjadi salah satu pedoman yang berbasis data historis. Pedoman tersebut dapat digunakan oleh pemerintah Kota Malang dalam merencanakan kebijakan terkait inflasi untuk tahun mendatang.

REFERENSI

- [1] Alviana, K., Kamila, V.Z., & Masa, A.P.A., 2025. Peramalan Menggunakan Metode Single Exponential Smoothing dan ARIMA untuk Pengendalian Persediaan Barang pada Perusahaan Pengumpul Limbah. *Jurnal Informatika dan Teknik Elektro Terapan*, Vol. 13, No. 3S1, 1481–1491. <https://doi.org/10.23960/jitet.v13i3S1.7794>.
- [2] Arif, S., Hassan, R., Nasir, H. A., Riaz, N., & Mahmood, I., 2026. Modeling and Clustering of Residential Electricity Consumption for Short-term Forecasting Using Seasonal Autoregressive Integrated Moving Average (SARIMA). *Global Energy Interconnection*, Vol. 9, No. 3, 567–584. <https://doi.org/10.1016/j.gloi.2026.04.001>.
- [3] Ashraf, M., Arshad, A., Iqbal, F., Pourshirazi, S., Azhar, M. U., Tanoli, U. F., Ahmad, T., Ahmed, A., & Bilal, R., 2025. Agrometeorological Drought Early Warning As A Climate Service: SPI Projections Using SARIMA Models for Seasonal Risk Management. *Climate Services*, Vol. 40, 100622. <https://doi.org/10.1016/j.cliser.2025.100622>.
- [4] Badan Pusat Statistik Kota Malang. 2026. *Inflasi Year on Year (YoY) Kota Malang (Persen)*, 2026. Diakses pada 27 April 2026, dari malangkota.bps.go.id
- [5] Badan Pemeriksa Keuangan Republik Indonesia. *Kota Malang*. Diakses pada 2 Mei 2026, dari jatim.bpk.go.id
- [6] Bank Indonesia. 2026. *Target Inflasi*. Diakses pada 27 April 2026, dari bi.go.id

- [7] Chinmayi, H. K., Flynn, K. C., Baath, G. S., Gowda, P., Northup, B., & Ashworth, A., 2025. Monitoring Legume Nutrition with Machine Learning: The Impact of Splits in Training and Testing Data. *Applied Soft Computing*, Vol. 176, 113186. <https://doi.org/10.1016/j.asoc.2025.113186>.
- [8] Corpin, S. J. T., Marbella, J. N. P., Kua, S. J. J., Mabborang, R. C., & Lamprea, C. T., 2023. Forecasting Inflation Rate in the Philippines Using Seasonal Autoregressive Integrated Moving Average (SARIMA) Model. *European Journal of Computer Science and Information Technology*, Vol. 11, No. 2, 13–36. <https://doi.org/10.37745/ejcsit.2013/vol11n21336>.
- [9] Deretic, N., Stanimirovic, D., Awadh, M. Al, Vujanovic, N., & Djukic, A., 2022. SARIMA Modelling Approach for Forecasting of Traffic Accidents. *Sustainability*, Vol. 14, No. 8, 4403. <https://doi.org/10.3390/su14084403>.
- [10] Fauzani, S.P., & Rahmi, D., 2023. Penerapan Metode ARIMA dalam Peramalan Harga Produksi Karet di Provinsi Riau. *Jurnal Teknologi dan Manajemen Industri Terapan*, Vol. 2, No. 4, 269–277. <https://doi.org/10.55826/tmit.v2i4.283>.
- [11] Febrinanda, P., Muchlian, M., & Resti, S., 2026. Inflation Rate Forecasting Using the SARIMA Method in Padang City. *Jurnal AKTUIRIA Matematika Terapan, Statistika, Ekonomi dan Manajemen Risiko*, Vol. 5, No. 1, 1–9. <https://doi.org/10.31317/aktr.v5i01.1243>.
- [12] Fondo-Ferreiro, P., Rodelgo-Lacruz, M., González-Castaño, F. J., Gil-Castiñeira, F., Zamorano-Pinal, C., & Candal-Ventureira, D., 2026. Real-Time SARIMA-Based Anomaly Detection in Operator Networks. *Computer Networks*, Vol. 277, 112070. <https://doi.org/10.1016/j.comnet.2026.112070>.
- [13] Hassan, A., Alam, M.M., & Faeique, A., 2023. Forecasting Monthly Inflation in Bangladesh: A Seasonal Autoregressive Moving Average (SARIMA) Approach. *Journal of Economics and Financial Analysis*, Vol. 7, No. 2, 25–43. <http://dx.doi.org/10.1991/jefa.v7i2.a61>.
- [14] Hassydidqy, H., & Hasdiana, 2022. Analisis Peramalan (Forecasting) Penjualan dengan Metode ARIMA (Autoregressive Integrated Moving Average) pada Huebee Indonesia. *Jurnal Data Science Indonesia*, Vol. 2, No. 2, 92–100. <https://doi.org/10.47709/dsi.v2i2.2022>.
- [15] Henderi & Sofiana, S., 2025. Comparative Study of Traditional and Modern Models in Time Series Forecasting for Inflation Prediction. *International Journal for Applied Information Management*, Vol. 5, No. 3, 155–167. <https://doi.org/10.47738/ijaim.v5i3.108>.
- [16] Hossain, M. A., Rahman, M. M., Hasan, S. S., Mahmud, A., & Bai, L., 2025. Analysis and Forecasting of Meteorological Drought Using PROPHET and SARIMA Models Deploying Machine Learning Technique for Southwestern Region of Bangladesh. *Environmental and Sustainability Indicators*, Vol. 27, 100761. <https://doi.org/10.1016/j.indic.2025.100761>.
- [17] Khoiri, H. A., 2023. *Analisis Deret Waktu Univariat Teori dan Pengolahan Data*. UNIPMA PRESS.
- [18] Kholifah, R. I. N., Amri, I. F., Haris, M. A., Izzah, N., Baita, M. F., & Nurhalisa, S., 2024. Forecasting Red Onion Prices in Riau Islands Using the Seasonal Autoregressive Integrated Moving Average (SARIMA) Method. *Journal of Data Insights*, Vol. 2, No. 2, 61–71. <https://doi.org/10.26714/jodi.v2i2.412>.
- [19] Khotimah, N., Huda, M., & Yuliana, R., 2025. Peramalan Curah Hujan di Provinsi Banten Berdasarkan Stasiun Klimatologi Tangerang Selatan Menggunakan Metode ARIMA. *Jurnal Bayesian: Jurnal Ilmiah Statistika dan Ekonometrika*, Vol. 5, No. 2, 215–226. <https://doi.org/10.46306/bay.v5i2.122>.
- [20] Kumari, S., & Muthulakshmi, P., 2024. SARIMA Model: An Efficient Machine Learning Technique for Weather Forecasting. *Procedia Computer Science*, Vol. 235, 656–670. <https://doi.org/10.1016/j.procs.2024.04.064>.
- [21] Makoni, T., Mazuruse, G., & Nyagadza, B., 2023. International Tourist Arrivals Modelling and Forecasting: A Case of Zimbabwe. *Sustainable Technology and Entrepreneurship*, Vol. 2, No.

- 1, 100027. doi:10.1016/j.stae.2022.100027.
- [22] Malki, A., Atlam, E., Hassanien, A. E., Ewis, A., Dagnew, G., & Gad, I., 2022. SARIMA Model-based Forecasting Required Number of COVID-19 Vaccines Globally and Empirical Analysis of Peoples' View Towards the Vaccines. *Alexandria Engineering Journal*, Vol. 61, No. 12, 12091–12110. <https://doi.org/10.1016/j.aej.2022.05.051>.
- [23] Nabila, P., & Saumi, F., 2024. Peramalan Produksi Padi di Kota Padang dengan Metode ARIMA. *Jurnal Gamma-Pi (Matematika dan Pendidikan Matematika)*, Vol. 6, No. 2, 21–31. <https://doi.org/10.33059/gamma-pi.v6i2.9315>.
- [24] Owusu, B., & Bökemeier, B., 2026. The Economic Growth and Inflation Nexus: New Empirical Assessment for Emerging Market Economies. *International Review of Economics and Finance*, Vol. 107, 105078. doi:10.1016/j.iref.2026.105078.
- [25] Pratiwi, A.U., Zukhronah, E., & Slamet, I., 2024. Perbandingan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA) dan Extreme Learning Machine (ELM) pada Peramalan Peredaran Uang Kartal di Indonesia. *Indonesian Journal of Applied Statistics*, Vol. 7, No. 2, 195–210. <https://doi.org/10.13057/ijas.v7i2.83128>.
- [26] Putri, F.V., Ikhsan, E., & Fitri, F., 2024. Peramalan Suhu Rata-Rata Kota Padang Panjang dengan Membandingkan Metode SARIMA dan Holt-Winter Additive. *VARIANSI: Journal of Statistics and Its Application on Teaching and Research*, Vol. 6, No. 3, 107–118. <https://doi.org/10.35580/variensiunm237>.
- [27] Putri, N. A., Indraswari, R., Atletiko, F. J., Wibowo, R. P., & Dharmawan, Y. S., 2026. Prediction of Surabaya City' s Inflation Rate Based on Staple Food Price Forecast using Multivariate Long Short-Term Memory (LSTM). *Procedia Computer Science*, Vol. 284, 1619–1628. <https://doi.org/10.1016/j.procs.2026.07.155>.
- [28] Qurniawan, N.T., & Sukmono, T., 2025. Peramalan Permintaan dengan Menerapkan Metode Autoregressive Integrated Moving Average (ARIMA) pada Industri Beton. *Jurnal Teknologi dan Manajemen Industri Terapan (JTMIT)*, Vol. 4, No. 3, 1024–1032. <https://doi.org/10.55826/jtmit.v4i3.1117>.
- [29] Saefulloh, M.H.M., Fahlevi, M.R., & Centauri, S.A., 2023. Pengaruh Inflasi terhadap Pertumbuhan Ekonomi: Perspektif Indonesia. *Jurnal Acitya Ardana*, Vol. 3, No. 1, 17–26. <https://doi.org/10.31092/jaa.v3i1.2045>.
- [30] Sam, M., Kurniawati, E., & Fausia, S.R., 2022. Peramalan Permintaan Smartphone Oppo Android Menggunakan Metode Single Moving Average. *Infinity Jurnal Matematika dan Aplikasinya (IJMA)*, Vol. 2, No. 2, 93–103. <https://doi.org/10.30605/27458326-93>.
- [31] Samudra, M. S. R., Marcellina, D., Terttiavini, Yulianti, E., Coyanda, J. R., & Putri, I. P., 2024. Penerapan Metode Forecasting dalam Menentukan Prediksi Jumlah Mahasiswa Baru dengan Menggunakan Single Exponential Smoothing. *Jurnal Ilmiah Informatika Global*, Vol. 15, No. 2, 45–51. <https://doi.org/10.36982/jiig.v15i2.3916>.
- [32] Saputra, J.E., & Febrianti, W., 2025. Penerapan Autoregressive Integrated Moving Average (ARIMA) untuk Peramalan Laju Inflasi di Indonesia. *Jurnal Matematika, Statistika dan Komputasi*, Vol. 21, No. 2, 382–396. <https://doi.org/10.20956/j.v21i2.36609>.
- [33] Shalahuddin, M., & Oktaviyani, H., 2024. Model ARIMA Box-Jenkins untuk Peramalan Pergerakan Harga Saham PT. Astra International Tbk. *Journal of Social and Economics Research*, Vol. 6, No. 2, 496–506. <https://doi.org/10.54783/jsr.v6i2.715>.
- [34] Sohieben, G. P. D., Setiawan, & Prastyo, D. D., 2024. Spatial Vector Autoregressive with Metric Exogenous Variable (SpVARX) for Inflation and Outflow Forecasting. *Procedia Computer Science*, Vol. 234, 140–147. <https://doi.org/10.1016/j.procs.2024.02.160>.
- [35] Susanti, N.E., Saputra, R., & Situmorang, I.A., 2024. Perbandingan Metode SARIMA, Double Exponential Smoothing dan Holt-Winter Additive dalam Peramalan Retail Sales Mobil Honda. *Jurnal Sains Matematika dan Statistika*, Vol. 10, No. 1, 58–70.

- <https://doi.org/10.24014/jsms.v10i1.26375>.
- [36] Szostek, K., Mazur, D., Kuszner, J., & Drałus, G., 2024. Analysis of the Effectiveness of ARIMA, SARIMA, and SVR Models in Time Series Forecasting: A Case Study of Wind Farm Energy Production. *energies*, Vol. 17, No. 19, 4803. <https://doi.org/10.3390/en17194803>.
- [37] Zega, F. K., Hulu, T. H. S., Zebua, S., & Zebua, E., 2024. Analisis Peramalan (Forecasting) Penjualan Tahu dengan Metode Single Moving Average untuk Mengoptimalkan Produksi pada Pabrik Tahu Nias. *INNOVATIVE: Journal Of Social Science Research*, Vol. 4, No. 1, 2931–2942. <https://doi.org/10.31004/innovative.v4i1.8226>.