

Application of Autoregressive Integrated Moving Average (ARIMA) for Forecasting Inflation Rate in Indonesia

Penerapan *Autoregressive Integrated Moving Average* (ARIMA) untuk Peramalan Laju Inflasi di Indonesia

Jova Edri Saputra¹, Werry Febrianti*²

^{1,2}Program Studi Matematika, Fakultas Sains, Institut Teknologi Sumatera

Email address: ¹jova.121160021@student.itera.ac.id, ²werry.febrianti@ma.itera.ac.id

*Corresponding Author

Received: 23 August 2024, revised: 13 November 2024, accepted: 28 November 2024

Abstract

Inflation is one of the indicators to maintain economic stability. Controlling inflation reflects the success of economic growth, while very high or volatile inflation can lead to economic instability. The purpose of this research is to forecast the time series data of inflation rate in Indonesia until the end of 2024 using ARIMA method. The data used in this study are secondary data of monthly inflation rates in Indonesia from January 2003 to May 2024 obtained from the Bank Indonesia website. Based on the research results, the optimal model for forecasting the inflation rate in Indonesia until the end of 2024 is ARIMA (1,0,1) with a MAPE of 6.91%. The forecasting results show a stable and not too significant increase and are still within the target range set by Bank Indonesia and the Government, which is between 1,5% and 3,5% for 2024.

Keywords: Inflation, Time Series Data, ARIMA, Economic Stability

Abstrak

Inflasi merupakan salah satu indikator untuk menjaga kestabilan ekonomi. Pengendalian inflasi mencerminkan keberhasilan pertumbuhan ekonomi, sementara inflasi yang sangat tinggi atau fluktuatif dapat mengakibatkan ketidakstabilan ekonomi. Tujuan dari penelitian ini adalah untuk melakukan peramalan terhadap data deret waktu laju inflasi di Indonesia hingga akhir tahun 2024 dengan menggunakan metode ARIMA. Data yang digunakan dalam penelitian ini merupakan data sekunder laju inflasi bulanan di Indonesia dari Januari 2003 hingga Mei 2024 yang diperoleh dari *website* Bank Indonesia. Berdasarkan hasil penelitian, diperoleh model optimal untuk meramalkan laju inflasi di Indonesia hingga akhir tahun 2024 adalah ARIMA(1,0,1) dengan MAPE sebesar 6,91%. Hasil peramalan menunjukkan peningkatan stabil dan tidak terlalu signifikan serta masih berada dalam kisaran target yang ditetapkan oleh Bank Indonesia dan Pemerintah, yaitu antara 1,5% dan 3,5% untuk tahun 2024.

Kata kunci: Inflasi, Data Deret Waktu, ARIMA, Stabilitas Ekonomi



1. PENDAHULUAN

Fenomena peningkatan harga barang dan jasa secara umum serta berkelanjutan dalam suatu perekonomian selama jangka waktu tertentu disebut sebagai inflasi. Inflasi pada dasarnya mencerminkan ketidakseimbangan antara penawaran dan permintaan dalam perekonomian nasional [10]. Pengendalian inflasi mencerminkan keberhasilan pertumbuhan ekonomi, sementara inflasi yang sangat tinggi atau fluktuatif dapat mengakibatkan ketidakstabilan ekonomi. Inflasi dapat disebabkan oleh berbagai faktor, termasuk peningkatan permintaan barang dan jasa (*demand-pull inflation*), kenaikan biaya produksi (*cost-push inflation*), serta kebijakan moneter dan fiskal yang tidak tepat.

Inflasi menjadi perhatian utama dalam kebijakan perekonomian Indonesia, terutama bagi Bank Indonesia, yang memiliki peran krusial dalam mempertahankan kestabilan nilai rupiah. Dalam beberapa tahun terakhir, Indonesia telah mengalami fluktuasi inflasi yang cukup signifikan. Inflasi yang tidak terlalu tinggi diperlukan untuk memastikan keberlanjutan ekonomi dan dapat menguntungkan mayoritas masyarakat. Oleh karena itu, pengendalian inflasi menjadi sangat penting, terutama mengingat dampak negatif inflasi yang ekstrem dan fluktuatif terhadap kondisi sosial. Kenaikan inflasi yang terus meningkat berdampak pada penurunan pendapatan riil masyarakat secara berkelanjutan sehingga mengurangi taraf hidup masyarakat, yang pada akhirnya membuat setiap individu, terutama golongan miskin, semakin terpuruk dan menurunkan status sosial ekonomi secara keseluruhan. Dengan adanya kondisi ini, penelitian untuk meramalkan laju inflasi di masa mendatang menjadi sangat relevan, karena dapat memberikan informasi yang berharga bagi pengambil kebijakan dalam merumuskan strategi untuk menjaga stabilitas ekonomi di Indonesia.

Salah satu indikator utama yang digunakan untuk mengevaluasi laju inflasi adalah Indeks Harga Konsumen (IHK). IHK mengevaluasi perubahan rata-rata harga dari berbagai barang dan jasa yang biasanya dikonsumsi oleh rumah tangga. Perubahan pada IHK mencerminkan laju inflasi dan menjadi acuan penting bagi Bank Indonesia dalam menentukan kebijakan moneter. Selain IHK, terdapat beberapa indikator yang berperan penting dalam analisis inflasi, seperti Indeks Harga Produsen (IHP) yang mengukur perubahan harga di tingkat produsen, serta tingkat suku bunga yang dapat mempengaruhi pengeluaran dan investasi. Meskipun demikian, IHK mampu menggambarkan laju inflasi karena disajikan secara bulanan, sehingga informasi yang diperoleh tergolong sebagai data deret waktu [8].

Data deret waktu merupakan jenis data yang ideal untuk dianalisis karena dapat disajikan dalam periode waktu periode dengan interval waktu yang seragam, seperti harian, mingguan, bulanan, tahunan sehingga memungkinkan untuk melakukan peramalan [15]. Berbagai metode peramalan dapat diterapkan pada data deret waktu. Sekine (2001) menggunakan model *moving average* (MA) untuk meramalkan inflasi satu tahun ke depan di Jepang [18]. Tchakondo (2022) menerapkan model *autoregressive* (AR) sederhana untuk meramalkan inflasi di Togo, Afrika Barat, dan menemukan bahwa model AR(1) secara efektif dapat meramalkan inflasi menggunakan data perubahan persentase tahunan dalam IHK dari tahun 1967 hingga 2019 [20].

Meskipun banyak penelitian mencakup penerapan AR dan MA dalam peramalan inflasi, terdapat beberapa kekurangan. Model AR dapat memberikan hasil yang baik, tetapi sering kali memerlukan asumsi yang lebih ketat mengenai stasionaritas data dan dapat menjadi kurang efektif jika terdapat banyak variabel yang saling mempengaruhi. Sementara model MA, meskipun sederhana dan mudah diterapkan, tidak dapat menangkap pola yang lebih kompleks dalam data, terutama jika terdapat tren atau musiman yang signifikan. Penelitian ini bertujuan untuk menggabungkan proses AR dan MA dengan menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA). ARIMA mampu mengintegrasikan komponen AR dan MA, sehingga dapat menangkap pola yang lebih kompleks dalam data deret waktu.

Penelitian yang dilakukan oleh Safwandi (2023) menerapkan ARIMA untuk meramalkan laju inflasi di Indonesia dari Januari 2023 hingga Desember 2023 dengan menggunakan data laju inflasi bulanan dari Januari 2010 hingga Desember 2022 [17]. Selanjutnya, penelitian oleh Rifai dan Zhahirulhaq (2024) juga menerapkan ARIMA untuk meramalkan laju inflasi di Indonesia dari Mei 2024 hingga Desember 2024 dengan memanfaatkan data laju inflasi bulanan dari Januari 2020 hingga April 2024 [16].

Oleh karena itu, penelitian ini akan membahas peramalan laju inflasi di Indonesia untuk periode Juni 2024 hingga Desember 2024 dengan menggunakan data laju inflasi bulanan dari Januari 2003 hingga Mei 2024. Diharapkan bahwa hasil dari penelitian ini akan menghasilkan peramalan yang akurat mengenai dinamika inflasi di masa mendatang sehingga memberikan informasi yang berharga bagi pengambil kebijakan dalam mengantisipasi perubahan harga dan menjaga stabilitas ekonomi.

2. HASIL UTAMA

a. Metode *Autoregressive Integrated Moving Average* (ARIMA)

ARIMA merupakan metode peramalan yang memprediksi nilai-nilai berdasarkan pola data historis [14]. Diperkenalkan untuk pertama kalinya oleh Box dan Jenkins pada tahun 1970, metode *Box-Jenkins* juga dikenal sebagai ARIMA yang dirancang untuk data deret waktu stasioner. Dalam pendekatan peramalan ini, variabel independen diabaikan karena ARIMA menghasilkan prediksi yang akurat dalam jangka pendek yang didasarkan pada nilai variabel dependen saat ini dan sebelumnya.

ARIMA pada umumnya merupakan kombinasi dari model *Autoregressive* (AR) dan *Moving Average* (MA). Model AR mengandalkan nilai-nilai variabel sebelumnya untuk menjelaskan perubahannya, sedangkan model MA memanfaatkan residual atau kesalahan dari masa lalu untuk memperkirakan perubahan tersebut [9]. Metode ARIMA terdiri dari tahapan identifikasi, estimasi parameter, dan diagnosa model, serta peramalan [13]. Berikut adalah bentuk umum ARIMA(p, d, q) untuk data deret waktu.

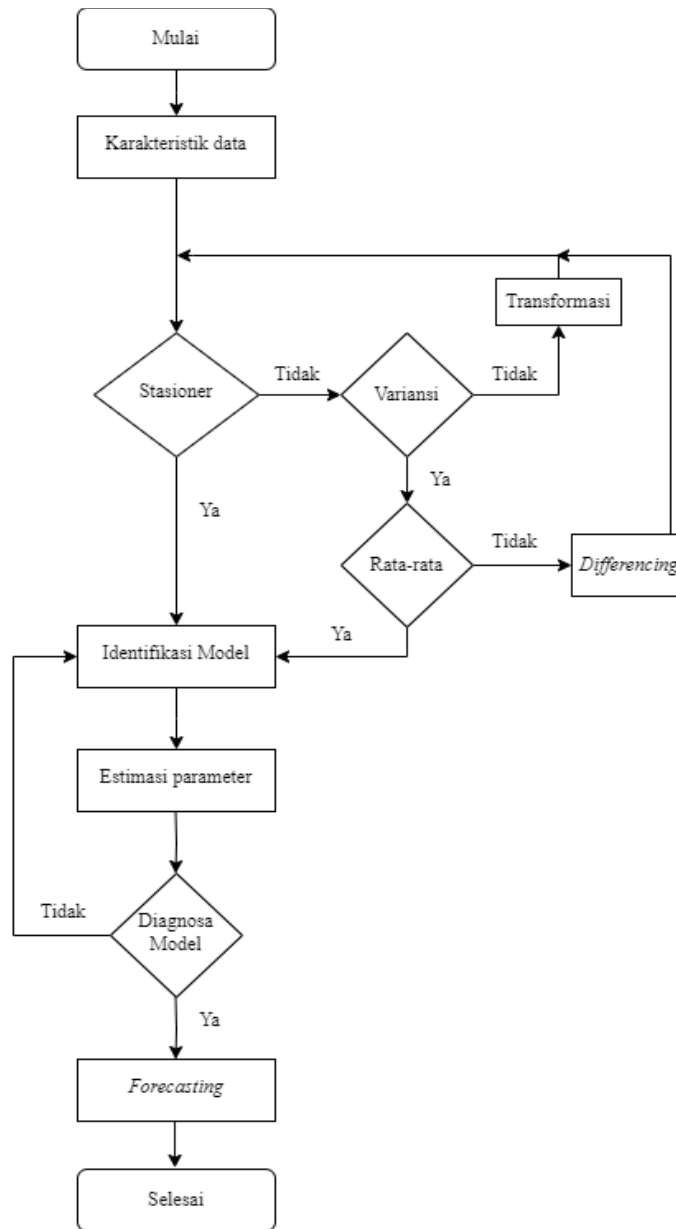
$$\phi_p(B)(1 - B)^d Y_t = \theta_q(B)e_t \quad (1)$$

Keterangan:

$\phi_p(B)$	$= (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$
$(1 - B)^d$	$= \text{differencing non seasonal}$
$\theta_q(B)$	$= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$
Y_t	$= \text{Nilai data deret waktu ke-}t$
e_t	$= \text{Residual atau kesalahan}$
B	$= \text{Operator backshift}$
p	$= \text{Orde AR}$
d	$= \text{Orde MA}$
q	$= \text{Orde differencing}$

Langkah-langkah dalam menentukan model ARIMA dapat digambarkan melalui diagram alir berikut:

JURNAL MATEMATIKA, STATISTIKA DAN KOMPUTASI
Jova Edri Saputra, Werry Febrianti



Gambar 2.1 Diagram Alir Model ARIMA

2.1.1 Stasioneritas

Data dianggap stasioner apabila variansi dan rata-rata tetap konstan sepanjang waktu [21]. Salah satu metode untuk mendekati data pada distribusi normal dan mencapai variansi konstan adalah transformasi Box-Cox. Transformasi Box-Cox secara umum dapat dinyatakan:

$$T(Y_t) = \frac{Y_t^\lambda - 1}{\lambda} \quad (2)$$

dengan ketentuan sebagai berikut [22].

Tabel 2.1. Transformasi Box-Cox

Nilai λ (lambda)	Transformasi
-1,0	$\frac{1}{Y_t}$
-0,5	$\frac{1}{\sqrt{Y_t}}$
0,0	$\ln(Y_t)$
0,5	$\sqrt{Y_t}$
1,0	Y_t

Selanjutnya melakukan uji *Augmented Dickey-Fuller* (ADF) untuk memeriksa hipotesis nol bahwa deret waktu memiliki akar unit atau tidak bersifat stasioner terhadap rata-rata. Apabila deret waktu bersifat tidak stasioner, maka data perlu melalui proses *differencing* [1].

2.1.2 Identifikasi Model

Penentuan kandidat model $ARIMA(p, d, q)$ dilakukan dengan mengamati plot dari data yang telah stasioner menggunakan *Autocorrelation Function* (ACF) untuk menentukan orde q serta *Partial Autocorrelation Function* (PACF) untuk menentukan orde p . Sedangkan, orde d bergantung pada data yang diperoleh selama proses *differencing*. Berikut ini adalah gambaran mengenai proses penentuan orde p dan q [6].

Tabel 2.2. Identifikasi Orde dari ACF dan PACF

Proses	ACF	PACF
$AR(p)$	Menurun secara bertahap (<i>Tails off</i>)	Terputus setelah lag ke- p (<i>cut off</i>)
$MA(q)$	Terputus setelah lag ke- q (<i>cut off</i>)	Menurun secara bertahap (<i>Tails off</i>)
$ARMA(p, q)$	Menurun secara bertahap setelah lag ($q-p$)	Menurun secara bertahap setelah lag ($p-q$)

Tails off menunjukkan adanya penurunan lag yang stabil dan bertahap pada plot ACF dan PACF. Sebaliknya, *cuts off* mengindikasikan penurunan lag yang segera mencapai nol setelah lag ke- p atau ke- q .

Identifikasi model juga dapat dilakukan dengan pendekatan *Extended ACF* (EACF) yang secara teori menunjukkan pola segitiga-nol (*triangle of zeroes*). Setelah proses *differencing* pada data, model yang dihasilkan adalah $ARIMA(p, d, q)$ [3].

2.1.3 Estimasi Parameter

Estimasi parameter dalam model $ARIMA$ mengacu pada proses menghitung nilai parameter yang mendeskripsikan dinamika data secara optimal. Parameter tersebut meliputi:

- p (*autoregressive*): mengindikasikan banyaknya lag pada komponen *autoregressive*.
- d (*differencing*): jumlah transformasi *differencing* yang dilakukan untuk membuat data stasioner.
- q (*moving average*): banyaknya lag pada komponen *moving average*.

Selanjutnya, metode *Maximum Likelihood* (ML) digunakan untuk memperkirakan parameter model dengan cara memaksimalkan *fungsi likelihood*, yaitu fungsi yang menunjukkan seberapa besar kemungkinan model dengan parameter tertentu dapat menghasilkan data yang diamati. Fungsi *likelihood* dihitung berdasarkan asumsi distribusi residual dari model (biasanya normal).

Setelah parameter diestimasi, langkah berikutnya adalah memeriksa apakah parameter tersebut signifikan secara statistik. Hal ini dilakukan melalui:

- a. Uji hipotesis parameter: Menguji apakah parameter memiliki pengaruh yang berarti terhadap model atau tidak.
- b. Nilai p-value: Parameter dianggap signifikan jika p-value < tingkat signifikansi (biasanya $\alpha = 0.05$).

Dengan pendekatan ini, proses estimasi parameter memberikan nilai numerik yang optimal dan signifikan secara statistik, yang memungkinkan model ARIMA merepresentasikan data dengan baik.

Setelah menentukan kandidat model pada tahap identifikasi, langkah selanjutnya adalah estimasi parameter. Pada tahap ini, metode *Maximum Likelihood* (ML) digunakan untuk memperkirakan nilai parameter yang paling sesuai dengan data yang ada. Metode ML berupaya menemukan nilai parameter yang memaksimalkan kemungkinan dari data yang teramati, dengan asumsi bahwa model yang telah dipilih benar [12]. Tahap berikutnya melibatkan perbandingan *p-value* dengan tingkat signifikansi α untuk mengevaluasi signifikansi parameter. Berikut ini adalah hipotesis yang ditetapkan serta kriteria penolakannya.

H_0 : $\phi = 0$ atau Parameter model dianggap tidak signifikan

H_1 : $\phi \neq 0$ atau Parameter model dianggap signifikan

Jika *p-value* lebih kecil dibandingkan α , maka keputusan yang diambil adalah menolak H_0 untuk $\alpha = 5\%$.

2.1.4 Diagnosa Model

Diagnosa model bertujuan untuk memastikan kandidat model telah sesuai dan residu yang dihasilkan adalah *white noise* [7]. Berikut adalah beberapa langkah diagnosa model yang perlu dilakukan.

- **Time Series Plot Residual**

Residu yang ideal harus tersebar secara acak di sekitar garis nol, menunjukkan rata-rata nol dan variansi yang konstan. Residual dalam deret waktu dapat ditentukan dengan menggunakan rumus berikut.

$$e_t = Y_t - \hat{Y}_t \quad (3)$$

Keterangan:

e_t = Residu pada waktu ke- t

Y_t = Nilai observasi pada waktu ke- t

\hat{Y}_t = Nilai yang diprediksi oleh model pada waktu ke- t

- **ACF Residual**

ACF Residual membantu dalam memahami apakah ada autokorelasi yang signifikan pada lag-lag tertentu. Untuk residu yang bersifat *white noise*, ACF seharusnya mendekati nol untuk semua lag. Berikut ini adalah rumus umum untuk ACF pada lag ke- k .

$$ACF(k) = \frac{\sum_{t=1}^{T-k} (e_t - \bar{e})(e_{t+k} - \bar{e})}{\sum_{t=1}^{T-k} (e_t - \bar{e})^2} \quad (4)$$

$ACF(k)$ = Korelasi antara residu pada lag ke- k

k = Lag yang diinginkan

e_t = Residu pada waktu ke- t

\bar{e} = Rata-rata semua residu

T = Jumlah observasi dalam deret waktu

- **Uji Normalitas Residual**

Untuk memastikan bahwa distribusi residual mendekati distribusi normal, dilakukan uji normalitas residual. Pada penelitian ini, akan digunakan uji *Kolmogorov-Smirnov* dengan hipotesis berikut.

H_0 : Residual menyebar secara normal

H_1 : Residual tidak menyebar secara normal

Jika p -value lebih besar dibandingkan α , maka keputusan yang diambil adalah menolak H_0 untuk $\alpha = 5\%$.

- **Ljung-Box Test**

Uji *Ljung-Box* (Q) dapat diterapkan dalam mengevaluasi kecocokan penerapan model ARIMA [4]. Uji ini bertujuan untuk menentukan adanya korelasi pada residual model di berbagai lag. Berikut adalah hipotesis dan perhitungan statistik Q [2].

H_0 : Kecukupan model terpenuhi

H_1 : Kecukupan model tidak terpenuhi

Jika p -value lebih kecil dibandingkan α , maka keputusan yang diambil adalah menolak H_0 untuk $\alpha = 5\%$.

$$Q = n(n+2) \sum_{k=1}^h \frac{\hat{\rho}_k^2}{n-k} \quad (5)$$

Keterangan:

Q = Statistik Q

n = Jumlah observasi dalam deret waktu

$\hat{\rho}_k^2$ = Korelasi sampai lag ke- k

h = Lag maksimum

2.1.5 Mean Absolute Percentage Error (MAPE)

MAPE merupakan metrik yang digunakan untuk mengevaluasi tingkat keakuratan model peramalan. Kualitas model peramalan dianggap semakin baik apabila persentase MAPE semakin rendah [5]. Berikut ini adalah rumus untuk MAPE.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\% \quad (6)$$

Keterangan:

n = Jumlah data

y_t = Nilai hasil aktual pada waktu ke- t

\hat{y}_t = Nilai hasil prediksi pada waktu ke- t

Proses analisis MAPE membantu dalam mengevaluasi kualitas dan keefektifan model peramalan, serta untuk menentukan apakah hasil peramalan dapat diandalkan dan seberapa layak model tersebut untuk digunakan. Tabel 2.3 menunjukkan kriteria nilai MAPE yang digunakan dalam penelitian ini [19].

Tabel 2.3. Kriteria MAPE

MAPE	Deskripsi
$MAPE \leq 10\%$	Baik Sekali
$10\% < MAPE \leq 20\%$	Baik

$20% < MAPE \leq 50%$	Cukup
$MAPE > 50%$	Buruk

b. Implementasi Metode

2.2.1 Statistika Deskriptif

Statistika deskriptif digunakan untuk menyajikan data laju inflasi di Indonesia dari Januari 2003 hingga Mei 2024 yang diperoleh dari *website* Bank Indonesia. Analisis ini mencakup nilai minimum dan maksimum, mean, median (Q2), kuartil pertama (Q1), dan kuartil ketiga (Q3).

Tabel 2.4. Statistika Deskriptif Data Laju Inflasi di Indonesia

	Inflasi (%)
Min	1,320
Q1	3,245
Median	4,740
Mean	5,538
Q3	6,952
Max	18,380

Berdasarkan Tabel 2.4, laju inflasi di Indonesia berkisar antara nilai minimum 1,320% hingga maksimum sebesar 18,380%. Hal ini mencerminkan besarnya *range* pada data laju inflasi di Indonesia. *Skewness* positif, atau kecenderungan distribusi data dengan ekor panjang di sisi kanan menunjukkan lebih banyak nilai inflasi tinggi, seperti yang tercermin dari mean 5,538% dan median 4,740%.

2.2.2 Plot Deret Waktu



Gambar 2.2 Plot Deret Waktu Data Laju Inflasi di Indonesia

Identifikasi awal pada plot deret waktu dilakukan untuk menggambarkan laju inflasi di Indonesia dari Januari 2003 hingga Mei 2024. Visualisasi plot deret waktu tersebut menunjukkan bahwa variansi dan rata-rata tidak konstan. Hal ini mengindikasikan adanya fluktuasi signifikan pada laju inflasi di Indonesia. Bulan dengan laju inflasi terendah dan tertinggi adalah Agustus 2020 dan November 2005.

Fluktuasi laju inflasi di Indonesia dapat disebabkan oleh beberapa faktor utama. Perubahan kebijakan pemerintah, terutama kebijakan moneter dan fiskal, dapat memiliki dampak signifikan pada laju inflasi. Misalnya, kenaikan harga bahan bakar pada November 2005 menyebabkan

lonjakan inflasi yang drastis. Selain itu, harga komoditas global, seperti minyak, pangan, dan bahan baku lainnya, sering kali mempengaruhi inflasi domestik.

2.2.3 Kekuatan Sinyal Data

Tabel 2.5. Kekuatan Sinyal Data Laju Inflasi di Indonesia

Inflasi	
<i>Trend Strength</i>	0,9
<i>Seasonal Strength</i>	0

Kekuatan sinyal tren sebesar 0,9 pada Tabel 2.5 mengindikasikan adanya komponen tren yang sangat kuat dalam data. Artinya, laju inflasi di Indonesia cenderung menurun. Sebaliknya, kekuatan sinyal musiman sebesar 0 menunjukkan bahwa data tidak memiliki komponen musiman yang signifikan. Dengan kata lain, fluktuasi yang terjadi dalam data laju inflasi di Indonesia tidak mengikuti pola berulang yang konsisten pada interval waktu tertentu, seperti bulanan atau tahunan. Dengan demikian, metode ARIMA sesuai dengan karakteristik data yang ada sehingga dapat diterapkan dalam peramalan laju inflasi di Indonesia.

2.2.4 Uji Stasioneritas Data

Pada tahap ini, penting untuk memastikan bahwa data yang digunakan bersifat stasioner baik terhadap variansi maupun rata-rata. Untuk mengatasi masalah ketidakstasioneran data terhadap variansi, dapat dilakukan transformasi Box-Cox.

Tabel 2.6. Nilai PPCC Data Laju Inflasi di Indonesia

Lambda (λ)	PPCC
-2,0	0,7945646
-1,5	0,8611120
-1,0	0,9249451
-0,5	0,9731808
0,0	0,9923718
0,5	0,9746112
1,0	0,9226717
1,5	0,8497578
2,0	0,7722207

Pada Tabel 2.6, diperoleh nilai *Pearson Product-Moment Correlation* (PPCC) tertinggi ketika lambda bernilai 0. Hal ini menunjukkan bahwa diperlukan transformasi $y_t = \ln(Y_t)$ untuk data laju inflasi. Selanjutnya, dilakukan pengujian terhadap data laju inflasi yang telah ditransformasi dengan menerapkan uji ADF. Tingkat signifikansi α yang umumnya digunakan untuk menguji adalah 5%.


Tabel 2.7. Hasil Uji ADF

Uji ADF	
Statistik uji Dickey-Fuller	-4,2684
Urutan lag	6
p-value	0,01
Hipotesis alternatif	Stasioner

Hasil pengujian menunjukkan bahwa *p-value* sebesar 0,01 lebih kecil dibandingkan dengan α . Hal ini mengindikasikan bahwa data laju inflasi telah menunjukkan kestasioneran terhadap rata-rata.

2.2.5 Identifikasi Model

Setelah data laju inflasi dinyatakan stasioner terhadap variansi maupun rata-rata, langkah selanjutnya adalah menentukan orde yang sesuai untuk model ARIMA berdasarkan plot ACF dan PACF.



Gambar 2.3 Plot ACF dan PACF Data Laju Inflasi

Berdasarkan Gambar 2.3, ACF menunjukkan *tails off* sementara PACF *cut off* pada lag ke-2. Dengan demikian, diperoleh orde $p = 2$ dan $q = 0$ yang mengindikasikan kandidat model berdasarkan plot tersebut adalah ARIMA(2,0,0).

AR/MA	0	1	2	3	4	5	6	7	8	9	10	11	12	13
0	x	x	x	x	x	x	x	x	x	x	x	x	x	x
1	x	o	o	x	o	o	o	o	o	o	o	x	x	o
2	x	o	o	o	o	o	o	o	o	o	o	x	o	o
3	x	x	x	o	o	o	o	o	o	o	o	x	o	x
4	x	o	o	o	o	o	o	o	o	o	o	x	o	o
5	x	x	o	o	o	o	o	o	o	o	o	x	o	o
6	x	x	o	o	o	o	o	o	o	o	o	x	x	o
7	x	x	o	o	o	o	o	o	o	o	o	x	x	o

Gambar 2.4. Hasil EACF Data Laju Inflasi di Indonesia

Metode EACF, sebagaimana ditunjukkan pada Gambar 2.4 merupakan metode yang digunakan untuk memperoleh kandidat model selain dengan mengidentifikasi plot ACF dan PACF. ARIMA(2,0,0) yang sebelumnya diidentifikasi sebagai kandidat model, ternyata tidak terkonfirmasi sebagai kandidat pada EACF. Tabel 2.8 berikut menyajikan kandidat model yang mungkin untuk data laju inflasi.

Tabel 2.8. Kandidat Model

No.	ARIMA(p, d, q)
1	(1,0,1)
2	(1,0,2)
3	(1,0,4)
5	(2,0,2)
6	(2,0,3)
7	(2,0,4)
8	(3,0,3)
9	(3,0,4)
10	(4,0,1)
11	(4,0,2)
12	(4,0,3)
13	(4,0,4)

2.2.6 Estimasi Parameter

Estimasi parameter merupakan tahap yang bertujuan untuk menentukan nilai parameter optimal berdasarkan model yang telah diidentifikasi sebelumnya. Berikut adalah hasil estimasi parameter menggunakan metode ML.

Tabel 2.9. Nilai AIC dari Kandidat Orde Model

No.	ARIMA(p, d, q)	Nilai AIC
1	(1,0,1)	-336,0669
2	(1,0,2)	-334,3734
3	(1,0,4)	-331,4102
5	(2,0,2)	-332,4255
6	(2,0,3)	-325,4826
7	(2,0,4)	-322,9638
8	(3,0,3)	-315,7352
9	(3,0,4)	-328,707
10	(4,0,1)	-331,5947
11	(4,0,2)	-332,8867
12	(4,0,3)	-330,5562
13	(4,0,4)	-328,002

Berdasarkan Tabel 2.9, ARIMA(1,0,1) diidentifikasi sebagai kandidat model terbaik dalam hal akurasi dengan *Akaike's Info Criterion* (AIC) terkecil. Nilai AIC baik negatif maupun positif tidak memiliki perbedaan signifikan karena nilainya tergantung pada unit data yang digunakan [11].

Tabel 2.10. Parameter Kandidat Model

ARIMA(p, d, q)	Nilai Koefisien Parameter	
	ϕ_1	θ_1
(1,0,1)	0,9587	0,2707

Berdasarkan koefisien parameter yang diperoleh, persamaan untuk model ARIMA(1,0,1) dapat dinyatakan sebagai berikut.

$$Y_t = 0,9587Y_{t-1} + e_t - 0,2707e_{t-1} \quad (7)$$

Selanjutnya, parameter-parameter yang membentuk model ARIMA diidentifikasi melalui uji signifikansi parameter. Berikut ini disajikan hasil uji signifikansi parameter.

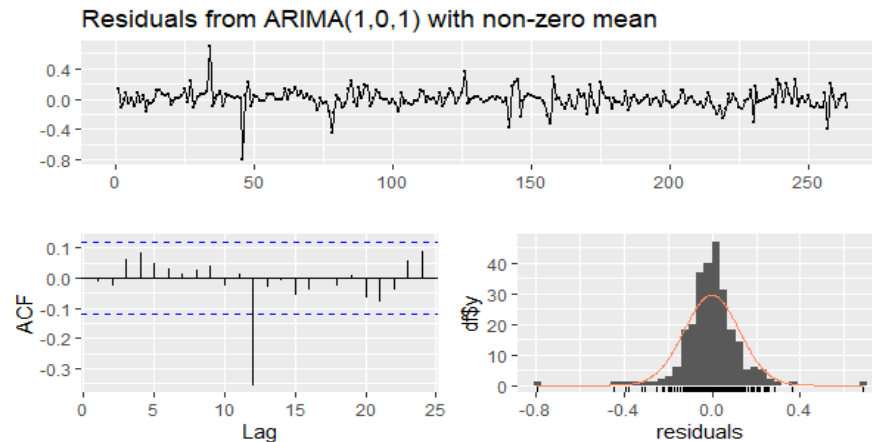
Tabel 2.11. Hasil Uji Signifikansi Parameter

ARIMA(p, d, q)	Uji z untuk koefisien: Pr(> z)	
	ϕ_1	θ_1
(1,0,1)	ϕ_1	< 2.2e-16
	θ_1	2,001e-05
	Intercept	8,960e-13

Setiap parameter memberikan hasil signifikan, karena tidak ada satu pun parameter yang melebihi α sehingga model ARIMA(1,0,1) dapat dilanjutkan ke tahap diagnosa model.

2.2.7 Diagnosa Model

Tahap selanjutnya adalah mengidentifikasi plot deret waktu residual dan plot ACF residual untuk menguji setiap parameter. Harapannya, plot ACF residual tidak akan menunjukkan lag yang signifikan dan memiliki variansi konstan serta rata-rata nol dalam plot deret waktu residual.



Gambar 2.5 Plot Deret Waktu dan Plot ACF Residual

Kesimpulan sementara menunjukkan bahwa residual terdistribusi di sekitar rata-rata nol dan memiliki variansi konstan, berdasarkan hasil analisis plot deret waktu dari residual yang diperoleh. Namun, plot ACF residual menunjukkan adanya *cut off* pada lag 12, yang mengindikasikan adanya hubungan antar lag residual dan menyebabkan ketidakcocokan model. Oleh karena itu, untuk memastikan bahwa residual telah menyebar secara normal, uji normalitas akan dilakukan dengan uji *Kolmogorov-Smirnov*.

Tabel 2.12. Hasil Uji *Kolmogorov-Smirnov*

ARIMA(p, d, q)	Uji normalitas <i>Kolmogorov-Smirnov</i>	
(1,0,1)	D	0,087236
	<i>p-value</i>	0,03597

Residual dianggap menyebar secara normal karena *p-value* lebih kecil dari α , sesuai dengan hasil uji normalitas tersebut. Langkah selanjutnya melakukan uji *Ljung-Box* pada model residual untuk mengukur seberapa baik model. Hasil dari uji tersebut disajikan pada tabel berikut.

Tabel 2.13. Hasil Uji *Ljung-Box*

ARIMA(p, d, q)	Uji <i>Ljung-Box</i>	
(1,0,1)	<i>X-squared</i>	0,048205
	df	1
	<i>p-value</i>	0,8262

Berdasarkan hasil yang telah diperoleh, kesimpulan menunjukkan bahwa ARIMA(1,0,1) memenuhi kriteria kecukupan model karena *p-value* yang lebih besar dari α . Langkah selanjutnya adalah menentukan tingkat keakuratan model berdasarkan MAPE. Berikut adalah nilai MAPE untuk model ARIMA(1,0,1).

Tabel 2.14 Nilai MAPE

ARIMA(p, d, q)	MAPE
(1,0,1)	6,91%

Dari hasil yang diperoleh, model ARIMA(1,0,1) memiliki nilai MAPE sebesar 6,91% yang menempatkan model dalam kategori baik sekali dan mengindikasikan bahwa model tersebut memiliki tingkat kesalahan yang kecil dalam meramalkan laju inflasi di Indonesia. Selain itu, model

ARIMA(1,0,1) juga menunjukkan nilai AIC sebesar -336,0669 yang lebih rendah dibandingkan dengan nilai AIC yang diperoleh dalam penelitian Rifai dan Zhahirulhaq (2024), yakni sebesar 51,81. Nilai AIC yang lebih rendah mengindikasikan bahwa model yang dikembangkan dalam penelitian ini memiliki akurasi yang lebih baik dibandingkan dengan model dalam penelitian tersebut.

Perbandingan ini menunjukkan adanya perbedaan signifikan antara penelitian ini dengan penelitian sebelumnya. Salah satu faktor utama yang membedakan adalah penggunaan data historis yang lebih panjang dalam penelitian ini, yang memungkinkan model untuk mendapat pola data yang lebih kompleks dan memberikan hasil yang lebih akurat.

2.2.8 Peramalan

Hasil peramalan yang diperoleh masih dalam bentuk transformasi $y_t = \ln(Y_t)$. Oleh karena itu, perlu dilakukan anti-transformasi $Y_t = \exp(y_t)$ guna mengembalikannya ke kondisi semula. Hasil peramalan model ARIMA(1,0,1) hingga akhir tahun 2024 adalah sebagai berikut.



Gambar 2.6 Peramalan Laju Inflasi di Indonesia

Peramalan hingga akhir tahun 2024 menunjukkan peningkatan yang stabil dan tidak terlalu signifikan dalam laju inflasi di Indonesia. Tabel berikut menyajikan nilai hasil peramalan laju inflasi di Indonesia.

Tabel 2.15 Nilai Peramalan Laju Inflasi di Indonesia

Periode	Inflasi (%)
Juni 2024	2,817634
Juli 2024	2,879691
Agustus 2024	2,940467
September 2024	2,999938
Oktober 2024	3,058080
November 2024	3,114879
Desember 2024	3,170322

Hasil peramalan menunjukkan bahwa laju inflasi di Indonesia hingga akhir tahun 2024 diperkirakan meningkat dari 2,817634% pada Juni 2024 menjadi 3,170322% pada Desember 2024. Kenaikan ini mencerminkan adanya kontrol yang baik terhadap variabel-variabel penyebab inflasi,

termasuk kebijakan moneter dan harga komoditas. Selain itu, hasil peramalan ini juga menunjukkan laju inflasi di Indonesia masih berada dalam kisaran target yang ditetapkan oleh Bank Indonesia dan Pemerintah, yaitu antara 1,5% dan 3,5% untuk tahun 2024.

3. KESIMPULAN

Berdasarkan hasil penelitian, diperoleh model optimal untuk meramalkan laju inflasi di Indonesia hingga akhir tahun 2024 adalah ARIMA(1,0,1) dengan MAPE sebesar 6,91% yang menempatkan model dalam kategori baik sekali dan mengindikasikan bahwa model tersebut memiliki tingkat kesalahan yang kecil dalam meramalkan laju inflasi di Indonesia. Peramalan yang dihasilkan dari model ini menunjukkan peningkatan stabil dan tidak terlalu signifikan yang mencerminkan adanya kontrol yang baik terhadap faktor-faktor yang mempengaruhi inflasi. Hasil tersebut masih berada dalam kisaran target yang ditetapkan oleh Bank Indonesia dan Pemerintah.

DAFTAR PUSTAKA

- [1] Abdulrahman, B.M.A., Ahmed, A.Y.A. & Abdellah, A.E.Y., 2018. Forecasting of Sudan Inflation Rates using ARIMA Model. *International Journal of Economics and Financial Issues*, Vol. 8, No. 3, 17.
- [2] Bhardwaj, S.P., Paul, R.K., Singh, D.R. & Singh, K.N., 2014. An Empirical Investigation of ARIMA and GARCH Models in Agricultural Price Forecasting. *Economic Affairs*, Vol. 59, No. 3, 415-428.
- [3] Hidayati, N., 2024. Perbandingan Model Asymmetric Power ARCH dengan Threshold GARCH dalam Peramalan Kurs Poundsterling terhadap Kurs Rupiah. *MATHunesa: Jurnal Ilmiah Matematika*, Vol. 12, No. 1, 11-20.
- [4] Huda, M., Azizah, R.N.N. & Setyana, A.N., 2023. Implementasi Metode ARMA dalam Peramalan Inflasi Provinsi Banten. *Jurnal Bayesian: Jurnal Ilmiah Statistika dan Ekonometrika*, Vol. 3, No. 2, 210-221.
- [5] Hutasuhut, A.H., Anggraeni, W. & Tyasnurita, R., 2014. Pembuatan Aplikasi Pendukung Keputusan untuk Peramalan Persediaan Bahan Baku Produksi Plastik Blowing dan Inject Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average) di CV. Asia. *Jurnal Teknik ITS*, Vol. 3, No. 2, A169-A174.
- [6] Istiqomah, N., 2015. Prediksi Kemunculan Titik Panas di Provinsi Riau Menggunakan Seasonal Autoregressive Integrated Moving Average (SARIMA).
- [7] Jagero, B.A., Mageto, T. & Mwalili, S., 2022. Modelling and Forecasting Inflation Rates in Kenya Using ARIMA Model. *European Journal of Statistics and Probability*, Vol. 11, No. 1, 54-68.
- [8] Kennedy, P.S.J., 2018. Modul Ekonomi Makro Kompetensi Dasar: Mendeskripsikan Masalah-Masalah yang Dihadapi Pemerintah di Bidang Ekonomi.
- [9] Laura, V., 2019. Peramalan Banyaknya Penabung di Credit Union Sumber Kasih Teraju dengan Metode Box-Jenkins. *Universitas Sanata Dharma*.
- [10] Meiditambua, M.H., Centauri, S.A. & Fahlevi, M.R., 2023. Pengaruh Inflasi terhadap Pertumbuhan Ekonomi: Perspektif Indonesia. *Jurnal Acitya Ardana*, Vol. 3, No. 1, 17-26.
- [11] Melani, V.D., Miftahuddin, M. & Subianto, M., 2022. Pemilihan Model ARFIMA-GPH dan Intervensi Multi Input pada Indeks Harga Perdagangan Besar Indonesia. *Jurnal Gaussian*, Vol. 11, No. 2, 163-172.
- [12] Meyler, A., Kenny, G. & Quinn, T., 1998. Forecasting Irish Inflation Using ARIMA Models.

- [13] Mukron, M.H., Susianti, I., Azzahra, F., Kumala, Y.N., Widiyana, F.R. & Al Haris, M., 2021. Peramalan Indeks Harga Konsumen Indonesia Menggunakan Autoregressive Integrated Moving Avarage. *Jurnal Statistika Industri Dan Komputasi*, Vol. 6, No. 1, 20-25.
- [14] Okafor, C. & Shaibu, I., 2013. Application of ARIMA Models to Nigerian Inflation Dynamics. *Research Journal of Finance and Accounting*, Vol. 4, No. 3, 138-150.
- [15] Purnama, J. & Juliana, A., 2020. Analisa Prediksi Indeks Harga Saham Gabungan Menggunakan Metode ARIMA. *Cakrawala Management Business Journal*, Vol. 2, No. 2, 454-468.
- [16] Rifai, N.A.K. & Zhahirulhaq, M.A., 2024. Forecasting Inflation in Indonesia Using The Autoregressive Integrated Moving Average Method. *Parameter: Journal of Statistics*, Vol. 4, No. 1, 37-45.
- [17] Safwandi, 2023. Time Series Model Using Autoregressive Integrated Moving Average (ARIMA) Method For Inflation In Indonesia. Vol. 8, 13-25.
- [18] Sekine, T., 2001. Modeling and Forecasting Inflation in Japan.
- [19] Setiawan, W., Juniati, E. & Farida, I., 2016. The Use of Triple Exponential Smoothing Method (Winter) in Forecasting Passenger of PT Kereta Api Indonesia with Optimization Alpha, Beta, and Gamma Parameters. In *2016 2nd International Conference on Science in Information Technology (ICSITech)*, 198-202. IEEE.
- [20] Tchakondo, Y., 2022. Forecating Inflation in Togo Using an Autoregressive Model. *Available at SSRN 4214913*.
- [21] Wahyuningtyas, A.R., Pratiwii, W.P., Wasono, R. & Utami, T.W., 2022. Peramalan Indeks Harga Konsumen Kabupaten Banyumas dengan Metode SARIMA. *Jurnal Litbang Edusaintech*, Vol. 3, No. 1, 56-60.
- [22] William, W. & Wei, S., 2006. Time Series Analysis: Univariate and Multivariate Methods. *Pearson Addison Wesley*, USA, Segunda edicion, Cap. 10, 212-235.