

Analisis Tren, Siklus, dan Peramalan Inflasi Bulanan di Indonesia Menggunakan Hodrick–Prescott Filter dan ARIMA

Nur Ikhwana^{1,*}, Annisa Syalsabila², Nalto Batty Mangiri³, Lalu Ramzy Rahmanda⁴

^{1,2,4}Program Studi Statistika, Universitas Negeri Makassar, Indonesia

³Program Studi Pendidikan Matematika, Universitas Negeri Manado, Indonesia

Keywords: ARIMA, HP Filter, Inflasi, Dekomposisi, Peramalan

Abstract:

This study aims to analyze the structure of inflation and forecast monthly inflation in Indonesia using a time series approach. The method used is the Hodrick–Prescott Filter to decompose data into trend and cycle components, and the ARIMA model to forecast inflation. The data used is monthly inflation data for the period 2010–2025. The decomposition results show that inflation has a relatively stable long-term trend with short-term fluctuations reflecting the presence of economic shocks. Based on model identification, the best model is ARIMA(2,0,1)(1,0,1)[12] which is able to capture past influences, seasonal components, and short-term shocks. The evaluation results show that the model meets the white noise assumption and is suitable for use in forecasting. The forecasting results show that inflation tends to be stable with a moderate increasing tendency, although uncertainty increases over longer periods. This study shows that the combination of structural analysis and time series modeling provides a more comprehensive understanding of inflation dynamics and produces relevant predictions to support decision making.

Penelitian ini bertujuan untuk menganalisis struktur inflasi serta melakukan peramalan inflasi bulanan di Indonesia menggunakan pendekatan deret waktu. Metode yang digunakan adalah Hodrick–Prescott Filter untuk mendekomposisi data menjadi komponen tren dan siklus, serta model ARIMA untuk meramalkan inflasi. Data yang digunakan adalah data inflasi bulanan periode 2010–2025. Hasil dekomposisi menunjukkan bahwa inflasi memiliki tren jangka panjang yang relatif stabil dengan fluktuasi jangka pendek yang mencerminkan adanya shock ekonomi. Berdasarkan identifikasi model, diperoleh model terbaik adalah ARIMA(2,0,1)(1,0,1)[12] yang mampu menangkap pengaruh masa lalu, komponen musiman, dan shock jangka pendek. Hasil evaluasi menunjukkan bahwa model memenuhi asumsi white noise dan layak digunakan untuk peramalan. Hasil peramalan menunjukkan bahwa inflasi cenderung stabil dengan kecenderungan meningkat secara moderat, meskipun ketidakpastian meningkat pada periode yang lebih panjang. Penelitian ini menunjukkan bahwa kombinasi analisis struktural dan pemodelan deret waktu memberikan pemahaman yang lebih komprehensif terhadap dinamika inflasi serta menghasilkan prediksi yang relevan untuk mendukung pengambilan keputusan.

* Corresponding author.

E-mail address: nurikhwana@unm.ac.id



1. Pendahuluan

Inflasi adalah salah satu indikator ekonomi makro yang sangat penting dalam menentukan kebijakan moneter di Indonesia. Menurut Bank Indonesia, inflasi adalah kenaikan harga barang dan jasa secara umum dan terus menerus dalam jangka waktu tertentu. Bank Indonesia menetapkan target inflasi sebesar $2,5 \pm 1\%$ untuk menjaga stabilitas sistem keuangan dan mendukung pertumbuhan ekonomi berkelanjutan (Bank Indonesia, 2020). Memahami dinamika tingkat inflasi memiliki implikasi penting dalam kebijakan ekonomi karena tingkat inflasi yang tinggi dapat mengurangi daya beli masyarakat, mengurangi daya saing ekonomi negara di pasar global, serta menciptakan ketidakpastian bagi pelaku ekonomi, termasuk pengusaha, investor, dan rumah tangga (Widyaningsih, 2024).

Dalam analisis deret waktu, data inflasi umumnya terdiri atas beberapa komponen utama, yaitu tren jangka panjang dan fluktuasi jangka pendek. Tren menunjukkan arah pergerakan inflasi dalam jangka panjang, sedangkan fluktuasi jangka pendek menunjukkan adanya shock ekonomi yang bersifat sementara. Untuk memisahkan kedua komponen tersebut, digunakan metode Hodrick–Prescott Filter yang mampu mendekomposisi data menjadi komponen tren dan siklus. Meskipun HP Filter efektif dalam mengidentifikasi struktur data, metode ini tidak dapat digunakan untuk melakukan peramalan. Oleh karena itu, diperlukan pendekatan lain yang mampu memodelkan dinamika data dan memprediksi nilai di masa depan. Dalam hal ini, model ARIMA digunakan karena kemampuannya dalam menangkap pola autokorelasi, baik dalam bentuk pengaruh masa lalu (autoregressive) maupun shock jangka pendek (moving average) (Saputra & Febrianti, 2025).

Dengan menggunakan HP Filter dan ARIMA dalam satu penelitian, dapat diperoleh pendekatan yang komprehensif, dimana HP Filter digunakan untuk memahami struktur dasar inflasi, sedangkan ARIMA digunakan untuk memodelkan dan meramalkan dinamika inflasi tersebut. Dengan demikian, hasil dekomposisi yang menunjukkan adanya tren dan fluktuasi dapat dihubungkan dengan hasil pemodelan ARIMA yang menangkap pengaruh historis dan shock dalam data.

Namun demikian, masih terdapat kesenjangan dalam penelitian sebelumnya yang cenderung menggunakan salah satu pendekatan saja, baik dekomposisi maupun peramalan, tanpa mengintegrasikan keduanya secara sistematis. Oleh karena itu, penelitian ini bertujuan untuk menggabungkan analisis struktural menggunakan HP Filter dengan pemodelan prediktif menggunakan ARIMA guna memperoleh pemahaman yang lebih menyeluruh mengenai dinamika inflasi bulanan di Indonesia.

2. Tinjauan Pustaka

2.1. Hodrick-Prescott Filter

Hodrick-Prescott (HP) Filter adalah metode dekomposisi time series yang memisahkan komponen tren dari komponen siklus. Metode ini pertama kali diperkenalkan oleh Hodrick dan Prescott (1997). Dalam studi makroekonomi, filter ini sering digunakan untuk mengukur output gap atau inflasi gap dengan mengasumsikan bahwa deret waktu y_t terdiri dari komponen tren g_t dan komponen siklikal c_t . Secara formal, persamaan dasarnya dinyatakan sebagai berikut:

$$y_t = g_t + c_t$$

di mana y_t , g_t , dan c_t masing-masing adalah deret waktu (dalam log), komponen tren, dan komponen siklus. Metode ini pada dasarnya menghitung deret stokastik g_t dengan meminimalkan jumlah kuadrat selisih antara deret waktu asli y_t dan tren g_t , yang merepresentasikan *goodness of fit*, dengan kendala bahwa jumlah kuadrat dari perbedaan dinamis komponen permanen (yang mengukur tingkat kehalusan/smoothness) tidak terlalu besar.

Dengan demikian, masalah optimasi yang diselesaikan adalah:

$$\min_{g_t} \sum_{t=1}^T (y_t - g_t)^2$$

dengan kendala:

$$\sum_{t=1}^T (\Delta^2 g_t)^2 = \sum_{t=1}^T [(g_{t+2} - g_{t+1}) - (g_{t+1} - g_t)]^2 = v$$

di mana Δ^2 merupakan differencing orde dua dari tren dan v adalah konstanta tertentu.

Dalam praktiknya, masalah ini diselesaikan menggunakan metode pengali Lagrange sehingga diperoleh:

$$\min_{g_t} \left[\sum_{t=1}^T (y_t - g_t)^2 + \lambda \sum_{t=1}^T [(g_{t+2} - g_{t+1}) - (g_{t+1} - g_t)]^2 \right]$$

Pada formulasi ini terdapat trade-off antara kesesuaian model (*goodness of fit*) dan tingkat kehalusan tren (*smoothness*) yang dikendalikan oleh parameter λ . Parameter ini merepresentasikan rasio varians antara komponen siklus dan perubahan pertumbuhan dari komponen tren.

Dalam penerapan Hodrick–Prescott Filter, pemilihan nilai parameter smoothing λ merupakan aspek penting yang mempengaruhi hasil dekomposisi tren dan siklus (Hodrick & Prescott, 1997). Secara umum, semakin besar nilai λ , maka komponen tren akan menjadi lebih halus, sementara fluktuasi jangka pendek akan lebih banyak ditangkap edalam komponen siklus. Sebaliknya, nilai λ yang kecil akan menghasilkan tren yang lebih mengikuti pergerakan data asli, sehingga komponen siklus menjadi relatif kecil (Enders, 2014).

Penentuan nilai λ tidak bersifat arbitrer, melainkan disesuaikan dengan frekuensi data yang digunakan. Hodrick dan Prescott (1997) awalnya merekomendasikan nilai $\lambda = 1600$ untuk data triwulanan. Selanjutnya, Ravn dan Uhlig (2002) mengembangkan aturan penyesuaian nilai λ berdasarkan frekuensi data dengan menggunakan pendekatan skala frekuensi. Mereka menunjukkan bahwa nilai λ berbanding lurus dengan pangkat empat dari rasio frekuensi data (Ravn & Uhlig, 2002).

Berdasarkan hasil tersebut, nilai λ yang umum digunakan adalah $\lambda = 100$ untuk data tahunan, $\lambda = 1600$ untuk data triwulanan, dan $\lambda = 14400$ untuk data bulanan.

Penggunaan nilai $\lambda = 14400$ untuk data bulanan bertujuan untuk menghasilkan tren yang cukup halus sehingga mampu merepresentasikan pergerakan jangka panjang tanpa terdistorsi oleh fluktuasi jangka pendek yang bersifat sementara (Ravn & Uhlig, 2002). Oleh karena itu, dalam penelitian ini digunakan nilai $\lambda = 14400$ karena data yang dianalisis adalah data bulanan. Pemilihan nilai ini diharapkan mampu menghasilkan pemisahan yang optimal antara tren inflasi jangka panjang dan fluktuasi jangka pendek yang disebabkan oleh shock ekonomi (Monahov, 2023).

2.2. Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA merupakan salah satu metode yang digunakan dalam analisis deret waktu untuk memodelkan dan melakukan peramalan berdasarkan pola historis data (Box & Jenkins, 1976). Model ini diperkenalkan oleh Box dan Jenkins (1976) dan dikenal sebagai pendekatan Box–Jenkins, yang terdiri dari tahap identifikasi, estimasi parameter, diagnostic checking dan peramalan secara sistematis.

Secara umum, model ARIMA dinyatakan dalam bentuk $ARIMA(p, d, q)$ dengan model masing-masing diuraikan pada tabel 1 berikut ini

Tabel 1. Model runtun waktu AR, MA, dan ARMA

Model	Persamaan
AR (p)	$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p}$
MA (q)	$Y_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots + \theta_q a_{t-q}$
ARMA (p, q)	$\phi_p(B)Y_t = \theta_q(B)a_t$

dengan,

- ϕ_p : Parameter model AR orde p
 θ_q : Parameter model MA orde q
 a_t : Nilai galat pada saat t
 B : Operator *backshift*

Komponen integrated menunjukkan bahwa data perlu dilakukan differencing untuk mencapai kondisi stasioner. Proses differencing dilakukan dengan:

$$y'_t = y_t - y_{t-1}$$

Jika data sudah stasioner pada level, maka $d = 0$ (Hamilton, 1994)

2.2.1. Konsep Stasioneritas

Suatu deret waktu dikatakan stasioner jika memiliki rata-rata dan varians yang konstan sepanjang waktu. Untuk menguji stasioneritas, dapat digunakan uji Augmented Dickey-Fuller (ADF). Jika nilai p-value pada ADF Test $< \alpha$ (0,05) maka data telah stasioner terhadap rata-rata (Enders, 2014)

2.2.2. Identifikasi Model (ACF dan PACF)

Penentuan nilai p dan q dilakukan melalui analisis plot Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF). ACF digunakan untuk mengidentifikasi komponen MA sedangkan PACF digunakan untuk mengidentifikasi komponen AR. Ciri umum plot ACF dan PACF diuraikan pada tabel 2 berikut

Tabel 2 . Plot ACF dan PACF

Model	ACF	PACF
AR (p)	Turun cepat membentuk eksponensial	Terpotong setelah lag ke-p
MA (q)	Terpotong setelah lag ke-q	Turun cepat membentuk eksponensial
ARMA (p, q)	Turun cepat membentuk eksponensial	Turun cepat membentuk eksponensial

2.2.3. Model Musiman (SARIMA)

Untuk data yang memiliki pola musiman, digunakan model Seasonal ARIMA atau SARIMA, yang dinyatakan sebagai:

$$ARIMA(p, d, q)(P, D, Q)_s$$

di mana P, D, Q adalah komponen musiman dan s adalah periode musiman (misal 12 untuk data bulanan)

Model ini mampu menangkap pola berulang dalam data, seperti pola tahunan pada inflasi (Hyndman & Athanopoulos, 2018).

2.2.4. Estimasi dan Evaluasi Model

Setelah model diidentifikasi, parameter diestimasi dan dilakukan evaluasi. Model terbaik adalah model yang memiliki nilai AIC kecil dan residual yang memenuhi asumsi white noise dan tidak mengandung autokorelasi (Box et al., 2008)

2.3. Inflasi

Inflasi diartikan sebagai kenaikan jumlah uang beredar atau kenaikan likuiditas dalam suatu perekonomian. Pengertian tersebut mengacu pada gejala umum yang ditimbulkan oleh adanya kenaikan jumlah uang beredar yang diduga telah menyebabkan adanya kenaikan harga-harga. Dalam perkembangan lebih lanjut, inflasi secara singkat dapat diartikan sebagai suatu kecenderungan meningkatnya harga-harga barang dan jasa secara umum dan terus-menerus.

Perkembangan kenaikan harga sejumlah barang dan jasa secara umum dalam suatu periode waktu ke waktu tersebut disebut sebagai laju inflasi (inflation rate). Laju inflasi pada umumnya dinyatakan dalam angka persentase (%). Laju inflasi dapat terjadi pada tingkat yang ringan, sedang, berat, dan hiperinflasi.

Laju inflasi dihitung berdasarkan angka indeks yang disusun dari harga barang dan jasa yang dikonsumsi oleh masyarakat dan disebut sebagai Indeks Harga Konsumen (IHK). Cara perhitungannya adalah dengan membandingkan IHK pada tahun dasar dengan IHK periode pengamatan. IHK di Indonesia dihitung menggunakan formula Laspeyres yang dimodifikasi sebagai berikut: (Badan Pusat Statistik, 2022).

$$IHK_n = \frac{\sum_{i=1}^k \frac{P_{ni}}{P_{(n-1)i}} P_{(n-1)i} \cdot Q_{oi}}{\sum_{i=1}^k P_{oi} \cdot Q_{oi}} \times 100$$

Dengan,

- IHK_n : Indeks Harga Konsumen bulan ke-n
 P_{ni} : Harga jenis barang/jasa i pada bulan ke (n)
 $P_{(n-1)i}$: Harga jenis barang/jasa i pada bulan ke (n-1)
 $P_{(n-1)i} \cdot Q_{oi}$: Nilai Konsumsi (NK) jenis barang/jasa i pada bulan ke (n-1)
 $\frac{P_{ni}}{P_{(n-1)i}}$: Relatif harga (RH) jenis barang/jasa i pada bulan ke (n)
 $P_{oi} \cdot Q_{oi}$: Nilai konsumsi (NK) janis barang/jasa i pada tahun dasar
 k : Jumlah jenis barang/jasa yang tercakup dalam paket komoditas IHK

Presentase perubahan indeks atau laju inflasi atau deflasi setiap bulan diperoleh dengan mengurangkan indeks suatu bulan dengan indeks bulan sebelumnya, kemudian hasilnya dibagi dengan indeks bulan sebelumnya dan dikalikan 100. Laju inflasi atau deflasi tersebut juga dapat dihitung dari indeks suatu bulan dibagi dengan indeks bulan sebelumnya, hasilnya dikurangi dengan 1, dan dikalikan dengan 100. Perhitungan di atas dijabarkan dengan rumus sebagai berikut: (Badan Pusat Statistik, 2022).

$$Inf_n = \frac{IHK_n - IHK_{(n-1)}}{IHK_{(n-1)}} \times 100$$

Atau

$$Inf_n = \left(\frac{IHK_n}{IHK_{(n-1)}} - 1 \right) \times 100$$

Dengan ,

- Inf_n : Laju inflasi/deflasi bulan ke (n)
 IHK_n : Indeks Harga Konsumen bulan ke (n)
 $IHK_{(n-1)}$: Indeks Harga Konsumen bulan ke (n-1)

3. Metode Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari Badan Pusat Statistik (BPS) yaitu data inflasi bulanan periode tahun 2010 hingga 2025. Data yang telah dikumpulkan selanjutnya diolah menggunakan perangkat lunak Rstudio. Analisis data dilakukan melalui tahapan berikut:


- 1) HP Filter

- a. Dekomposisi Data
Data inflasi dianalisis menggunakan HP Filter dengan parameter smoothing $\lambda = 14400$ (untuk data bulanan) untuk memperoleh komponen tren dan siklus.
 - b. Analisis Deskriptif
Hasil dekomposisi dianalisis melalui visualisasi grafik serta perhitungan statistik untuk mengidentifikasi pola inflasi jangka panjang dan fluktuasi jangka pendek.
- 2) ARIMA
- a. Uji Stasioneritas
Uji Augmented Dickey-Fuller (ADF) digunakan untuk mengetahui apakah data bersifat stasioner.
 - b. Identifikasi Model ARIMA
Penentuan model dilakukan menggunakan grafik Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF).
 - c. Estimasi Model
Model ARIMA diestimasi berdasarkan hasil identifikasi parameter (p,d,q) dan komponen musiman.
 - d. Evaluasi Model
Model dievaluasi menggunakan Akaike Information Criterion (AIC) dan uji diagnostik residual (uji Ljung-Box) untuk memastikan residual bersifat white noise.
 - e. Peramalan (Forecasting)
Model terbaik digunakan untuk memprediksi inflasi dalam beberapa periode ke depan.

4. Hasil dan Pembahasan

4.1. Analisis Dekomposisi Inflasi Menggunakan HP Filter


Hasil dekomposisi data inflasi bulanan menggunakan Hodrick–Prescott Filter menunjukkan bahwa inflasi Indonesia dapat dipisahkan menjadi dua komponen utama, yaitu tren jangka panjang dan siklus jangka pendek.



Gambar 1. Tren inflasi Indonesia hasil dekomposisi HP Filter

Berdasarkan Gambar 1, komponen tren menunjukkan pola yang relatif stabil dalam jangka panjang. Pada periode awal pengamatan (2010–2014), tren inflasi cenderung meningkat, yang mengindikasikan adanya tekanan harga yang relatif tinggi. Selanjutnya, tren mengalami penurunan secara bertahap pada periode 2015–2020, yang menunjukkan adanya stabilisasi inflasi. Pada periode pandemi COVID-19, tren inflasi berada pada level rendah dan cenderung datar, yang mencerminkan melemahnya permintaan agregat. Setelah tahun 2023, tren kembali menunjukkan peningkatan yang mengindikasikan adanya pemulihan ekonomi.

Selain tren, diperoleh komponen siklus yang menunjukkan fluktuasi jangka pendek inflasi.



Gambar 2. Komponen siklus inflasi hasil HP Filter

Berdasarkan Gambar 2, komponen siklus menunjukkan fluktuasi yang cukup signifikan di sekitar nilai nol. Nilai siklus yang positif mengindikasikan inflasi berada di atas tren, sedangkan nilai negatif menunjukkan inflasi berada di bawah tren. Fluktuasi yang tinggi terlihat pada periode 2013–2015, yang mencerminkan adanya shock inflasi yang kuat. Pada periode pandemi, komponen siklus cenderung bernilai negatif, yang menunjukkan tekanan deflasi akibat penurunan aktivitas ekonomi. Setelah tahun 2023, fluktuasi kembali meningkat yang mengindikasikan munculnya shock baru dalam perekonomian.

Berdasarkan gambar 1 dan gambar 2 dapat disimpulkan bahwa meskipun tren inflasi relatif stabil, inflasi tetap rentan terhadap shock jangka pendek yang dapat menyebabkan deviasi dari tren.

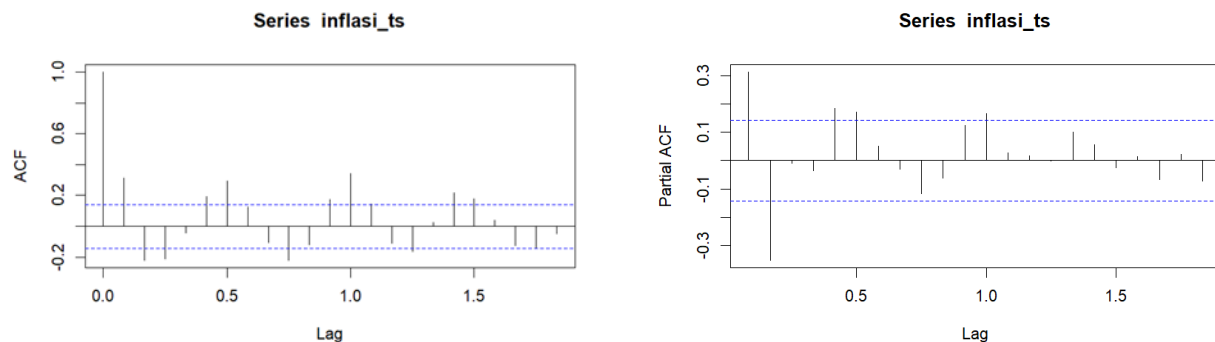
4.2. ARIMA

4.2.1. Uji Stasioneritas Data

Hasil uji Augmented Dickey-Fuller (ADF) menunjukkan bahwa data inflasi telah stasioner pada level dengan nilai p-value sebesar 0,01 ($< 0,05$). Hal ini menunjukkan bahwa data tidak mengandung unit root sehingga tidak diperlukan proses differencing. Dengan demikian, dalam model ARIMA digunakan nilai $d = 0$.

4.2.2. Identifikasi Model ARIMA

Identifikasi model dilakukan melalui analisis grafik Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF).



Gambar 3. ACF dan PACF Data Inflasi

Berdasarkan Gambar 3, Grafik ACF menunjukkan pola tailing off, di mana nilai autokorelasi menurun secara perlahan seiring bertambahnya lag. Sementara itu, grafik PACF menunjukkan pola cut-off pada lag ke-2, yang mengindikasikan bahwa komponen autoregressive orde 2 (AR(2)). Selain itu, terdapat indikasi pola musiman pada lag

ke-12, yang menunjukkan adanya pengaruh musiman tahunan. Hal ini konsisten dengan karakteristik inflasi yang sering dipengaruhi oleh faktor musiman seperti periode hari besar keagamaan dan akhir tahun (Komara Rifai & Zhahirulhaq, 2024). Berdasarkan pengamatan tersebut, dilakukan pengujian pada beberapa kandidat model untuk memperoleh model terbaik. Berdasarkan hasil identifikasi awal melalui grafik ACF dan PACF, diperoleh beberapa alternatif model non-musiman, seperti ARIMA(2,0,0), ARIMA(2,0,1), dan ARIMA(1,0,1). Selain itu, mengingat adanya indikasi pola musiman pada lag ke-12, maka dilakukan juga pengujian model musiman yaitu ARIMA(2,0,1)(1,0,1)[12].

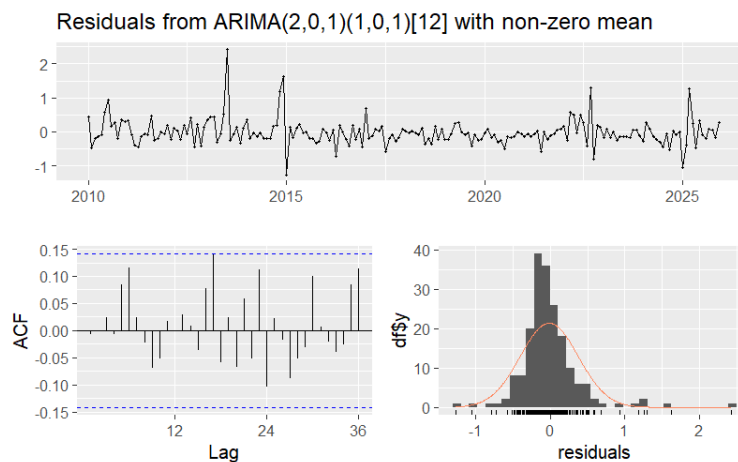
Setiap kandidat model yang diusulkan kemudian diestimasi dan dibandingkan berdasarkan nilai AIC serta hasil uji diagnostik residual. Hasil perbandingannya diuraikan dalam tabel berikut:

Tabel 3. Nilai AIC Kandidat Model

Model	AIC
ARIMA(2,0,0)	213,9908
ARIMA(2,0,1)	215,9803
ARIMA(1,0,1)	221,5939
ARIMA(2,0,0)(1,0,0)[12].	202,9572
ARIMA(2,0,1)(1,0,1)[12].	199,425

Berdasarkan tabel 3, diperoleh hasil bahwa model ARIMA(2,0,0) merupakan model non-musiman terbaik karena memiliki nilai AIC paling kecil dibandingkan kandidat non-musiman lainnya. Namun demikian, ketika dibandingkan dengan model musiman, diperoleh bahwa model ARIMA(2,0,1)(1,0,1)[12] memberikan nilai AIC yang paling kecil sehingga model ini lebih baik dalam menangkap pola data, khususnya dalam mengakomodasi komponen musiman yang terdapat pada data inflasi bulanan.

Dengan demikian, model ARIMA(2,0,1)(1,0,1)[12] dipilih sebagai model akhir karena tidak hanya memiliki kriteria statistik yang lebih baik, tetapi juga mampu merepresentasikan karakteristik data secara lebih komprehensif. Setelah memperoleh nilai AIC terkecil, dilakukan pemeriksaan diagnostik residual, yakni memastikan apakah residual telah memenuhi asumsi *white noise*. Hasil *Ljung-Box test* pada residual diperoleh nilai p-value = 0,3705 ($> 0,05$) sehingga dapat disimpulkan bahwa residual sudah memenuhi asumsi *white noise*.




Gambar 4. Diagnostik Residual

Berdasarkan gambar 4 diatas, hasil diagnostik residual menunjukkan bahwa residual berfluktuasi secara acak di sekitar nol tanpa pola tertentu. Plot ACF residual menunjukkan tidak adanya autokorelasi yang signifikan karena semua batang sudah berada didalam batas signifikansi, hal ini juga didukung oleh hasil uji Ljung-Box dengan nilai p-value sebesar 0,3705 ($> 0,05$). Selain itu, distribusi residual juga terlihat telah mendekati normal yang tercermin dari bentuk kurva yang berbentuk lonceng. Hal ini menunjukkan bahwa model yang digunakan telah memenuhi asumsi *white noise* dan layak digunakan untuk peramalan.

4.2.3. Peramalan

Hasil peramalan inflasi menggunakan model ARIMA(2,0,1)(1,0,1)[12] disajikan dalam gambaran visual berbentuk grafik pada gambar 5 dan nilai numerik hasil peramalannya disajikan pada tabel 4.

Forecasts from ARIMA(2,0,1)(1,0,1)[12] with non-zero mean



Gambar 5. Hasil Peramalan ARIMA

Berdasarkan Gambar 5 diatas, hasil peramalan ARIMA menunjukkan bahwa inflasi diperkirakan bergerak relatif stabil dengan kecenderungan meningkat secara moderat. Tidak terdapat lonjakan yang signifikan pada hasil peramalan, yang mengindikasikan bahwa inflasi diperkirakan tetap berada dalam kondisi yang terkendali. Selain itu, terlihat bahwa interval prediksi semakin melebar pada periode yang lebih jauh, yang menunjukkan bahwa tingkat ketidakpastian meningkat seiring dengan bertambahnya waktu. Pola peramalan yang relatif halus ini juga mencerminkan bahwa model telah mampu menangkap dinamika inflasi dengan baik.

Selanjutnya, hasil peramalan secara numerik disajikan pada Tabel 4 berikut ini:

Tabel 4. Hasil Peramalan ARIMA

Bulan	Point Forecast	Lo 95	Hi 95
Januari	0,18761374	-0,5866969	0,9619244
Februari	0,07661416	-0,7411333	0,8943617
Maret	0,59653599	-0,2312162	1,4242881
April	0,51863049	-0,3130823	1,3503433
Mei	0,11483332	-0,7170111	0,9466778
Juni	0,23248706	-0,5996156	1,0645897
Juli	0,24551591	-0,5865868	1,0776186
Agustus	0,10255904	-0,7295564	0,9346745
September	0,23827154	-0,5938443	1,0703874
Oktober	0,22422197	-0,6078944	1,0563383
November	0,27988993	-0,5522265	1,1120063
Desember	0,45949911	-0,3726173	1,2916155

Berdasarkan Tabel 4, hasil peramalan inflasi menunjukkan bahwa nilai prediksi (*forecast*) pada periode mendatang berada pada kisaran yang relatif stabil antar periode. Interval kepercayaan 95% menunjukkan rentang kemungkinan nilai inflasi aktual, di mana nilai batas bawah dan batas atas semakin besar seiring waktu. Hal ini menegaskan bahwa meskipun inflasi diperkirakan stabil, tetap terdapat potensi variasi akibat faktor eksternal yang tidak dapat diprediksi secara pasti.

Secara keseluruhan, hasil peramalan ini konsisten dengan hasil analisis sebelumnya menggunakan HP Filter yang menunjukkan adanya tren inflasi yang meningkat secara bertahap dengan fluktuasi jangka pendek yang terkendali. Dengan demikian, model ARIMA yang digunakan tidak hanya mampu menangkap pola historis, tetapi juga menghasilkan prediksi yang realistis terhadap kondisi inflasi di masa mendatang.

5. Kesimpulan

Penelitian ini bertujuan untuk menganalisis struktur inflasi serta melakukan peramalan inflasi bulanan di Indonesia. Hasil analisis menunjukkan bahwa inflasi memiliki pola tren jangka panjang yang relatif stabil, tetapi juga mengalami fluktuasi jangka pendek yang mencerminkan respons terhadap berbagai shock ekonomi. Temuan penting dalam penelitian ini menunjukkan bahwa inflasi tidak sepenuhnya bersifat acak, melainkan memiliki pola yang dapat dijelaskan dan dimodelkan secara sistematis. Inflasi memiliki komponen musiman dan pengaruh masa lalu yang membuatnya memiliki karakter berulang yang dapat diprediksi dalam batas tertentu. Hasil peramalan menunjukkan bahwa inflasi ke depan cenderung mengikuti pola historisnya dengan kecenderungan yang relatif stabil. Meskipun tetap terdapat ketidakpastian yang meningkat seiring waktu, inflasi berada dalam kondisi yang cukup terkendali, namun tetap sensitif terhadap perubahan kondisi ekonomi. Dengan demikian, penelitian ini menegaskan bahwa analisis struktural dan pemodelan deret waktu memberikan pemahaman yang lebih komprehensif terhadap inflasi. Kombinasi ini mampu menghasilkan prediksi yang relevan untuk mendukung pengambilan keputusan yang tepat dalam menghadapi inflasi di Indonesia.

References

- Badan Pusat Statistik. (2022). *Indeks Harga Konsumen 90 Kota di Indonesia (2018=100) 2021*.
<https://www.bps.go.id/id/publication/2022/04/12/94319f7cdb3fdad9ad3ed742/indeks-harga-konsumen-90-kota-di-indonesia--2018-100--2021.html>
- Bank Indonesia. (2020). *Inflasi*. <https://www.bi.go.id/id/fungsi-utama/moneter/inflasi/default.aspx>
- Box, G. E. P., & Jenkins, G. M. (1976). *Time Series Analysis Forecasting and Control*. Holden-Day.
- Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (2008). *Time Series Analysis : Forecasting and Control* (4th Edition). J. Wiley & Sons.
- Enders, W. (2014). *Applied Econometric Time Series* (4th Edition). University of Alabama. www.time-series.net.
- Hamilton, J. D. (1994). *Time Series Analysis*. Princeton University Press. <https://doi.org/10.1515/9780691218632>
- Hodrick, R. J., & Prescott, E. C. (1997). Postwar U.S. Business Cycles: An Empirical Investigation. *Journal of Money, Credit and Banking*, 29(1), 1–16.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice*. OTexts.
- Komara Rifai, N. A., & Zhahirulhaq, M. A. (2024). Forecasting Inflation in Indonesia Using The Autoregressive Integrated Moving Average Method. *Parameter: Journal of Statistics*, 4(1), 37–45.
<https://doi.org/10.22487/27765660.2024.v4.i1.17130>
- Monahov, A. (2023). *hpfilter: An R Implementation of the One-and Two-Sided Hodrick-Prescott Filter* GitHub R Package Repository.
<https://github.com/alexandrumonahov/hpfilter/Electroniccopyavailableat:https://ssrn.com/abstract=4387670>
- Ravn, M. O., & Uhlig, H. (2002). On Adjusting The Hodrick-Prescott Filter for The Frequency of Observations. *The Review of Economics and Statistics*, 84(2), 371–380.
- Saputra, J. E., & Febrianti, W. (2025). Application of Autoregressive Integrated Moving Average (ARIMA) for Forecasting Inflation Rate in Indonesia. *Jurnal Matematika, Statistika Dan Komputasi*, 21(2), 382–396.
<https://doi.org/10.20956/j.v21i2.36609>
- Widyaningsih, R. E. (2024). Analisis dan Proyeksi Tingkat Inflasi Tahunan di Indonesia dengan Model ARIMA. *Jurnal Volatility*, 1(2), 205–217. <https://doi.org/10.46306/vola.v1i2>