

Penerapan Metode Hybrid Ssa-Arima Pada Peramalan Indeks Harga Kebutuhan Pertanian Yang Dibayar Petani Di Provinsi Sulawesi Selatan

Muhammad Fahmuddin, Ruliana*, Muh Imam Shadiq

Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Makassar

Keywords: Hybrid SSA-ARIMA, IHDP, Forecasting

Abstract:

This study aims to determine the results and accuracy of forecasting the farmer's price index (IHDP) in South Sulawesi Province using Hybrid SSA-ARIMA. Hybrid SSA-ARIMA is a combination of two good time series methods to improve forecasting accuracy, especially for IHDP data that contains trend and seasonal elements. The data used is the South Sulawesi IHDP data from January 2019 to June 2024 which is sourced from the official website of the Central Statistics Agency. The results of the IHDP forecast in South Sulawesi for the next 12 months from July 2023 to June 2024 tend to increase with the largest increase in September 2024 of 1.184 with a forecast accuracy based on the Mean Absolute Percentage Error (MAPE) of 1.59%. This shows that Hybrid SSA-ARIMA has very good forecasting capabilities.

1. Pendahuluan

Indeks harga yang dibayar petani (IHBP) merupakan salah satu indikator penting dalam mengukur tingkat kesejahteraan petani, terutama dalam konteks stabilitas ekonomi sektor pertanian. Menurut data Badan Pusat Statistik (BPS), dalam 10 tahun terakhir, IHBP di Sulawesi Selatan terus mengalami kenaikan, yang berdampak pada penurunan pendapatan petani dan stabilitas ekonomi sektor pertanian. Fenomena ini menuntut analisis yang mendalam untuk memahami pola dan faktor-faktor yang memengaruhi perubahan IHBP, sehingga dapat dirumuskan kebijakan yang lebih efektif dalam mendukung kesejahteraan petani.

Dalam konteks analisis data deret waktu, teknik hybrid yang menggabungkan dua atau lebih metode peramalan telah terbukti efektif dalam meningkatkan akurasi prediksi. Salah satu kombinasi yang populer adalah penggunaan Singular Spectrum Analysis (SSA) dan Autoregressive Integrated Moving Average (ARIMA). SSA dikenal karena kemampuannya mengidentifikasi dan memisahkan komponen-komponen penting seperti tren, musiman, dan noise dalam data deret waktu, sementara ARIMA efektif dalam menangkap pola autoregressive dan moving average. Dengan menggabungkan kedua metode ini, model hybrid SSA-ARIMA mampu menghasilkan peramalan yang lebih akurat dan komprehensif, terutama dalam menghadapi data yang kompleks dan dinamis (Arumsari et al., 2021). Pendekatan ini diharapkan dapat memberikan solusi dalam menganalisis dan memprediksi IHBP, sehingga dapat mendukung perencanaan kebijakan yang lebih tepat guna dalam meningkatkan kesejahteraan petani.

Penelitian terdahulu menunjukkan efektivitas metode hybrid SSA-ARIMA dalam berbagai konteks. Menurut penelitian yang dilakukan oleh Arumsari, Wahyuningsih, dan Siringoringo (2021), Hybrid SSA-ARIMA menghasilkan peramalan yang lebih akurat dibandingkan metode tunggal SSA atau ARIMA saja, khususnya dalam konteks data inflasi. Penelitian tersebut menunjukkan bahwa kombinasi ini mampu mengurangi kesalahan peramalan secara signifikan,

* Corresponding author.

E-mail address: ruliana.t@unm



berkat kemampuan SSA dalam menangkap pola data yang lebih halus dan ARIMA dalam menangani komponen residual yang stasioner.

Studi lain oleh Fajar (2019) yaitu perbandingan dalam kinerja peramalan pertumbuhan ekonomi indonesia dengan ARIMA, SSA, dan hybrid SSA-ARIMA. Hasil ini diperoleh metode hybrid SSA-ARIMA menunjukkan kinerja yang lebih baik dalam peramalan pertumbuhan ekonomi indonesia. Hasil penelitian menunjukkan bahwa hybrid SSA-ARIMA mampu menangkap peramalan yang lebih tepat.

Adapun penelitian yang dilakukan oleh (Darmawan et al.,2022) yaitu Model Hybrid Singular Spectrum Analysis dan ARIMA untuk data deret waktu musiman. Penelitian tersebut membahas mengenai analisis data musiman menggunakan hybrid SSA-ARIMA dengan dua pengelompokan otomatis. Hasil dari penelitian ini diperoleh untuk pola musiman aditif, metode hybrid SSA-ARIMA dengan Alexandrov auto grouping lebih akurat (MAPE=0,13%) kemudian untuk pola musiman multiplikatif metode hybrid SSA-ARIMA dengan alternatif auto grouping lebih akurat (MAPE=3,63%).

2. Tinjauan Pustaka

Jika ada. Batang tubuh teks menggunakan font: Times New Roman 10, spasi before 6pt, after 6pt).

2.1. Singular Spectrum Analysis

Menurut Hassani (2007) tujuan utama dari SSA adalah menguraikan serial asli data menjadi sejumlah kecil komponen yang dapat diidentifikasi seperti tren, musiman, dan noise, kemudian diikuti oleh rekonstruksi dari serial aslinya. Menurut Golyandina dkk., (2001) algoritma dasar SSA terdiri dari dua tahap utama yakni dekomposisi embedding & singular value decomposition dan rekonstruksi grouping & diagonal averaging yang dijelaskan sebagai berikut:

2.1.1. Embedding

Langkah pertama dalam dekomposisi adalah embedding, di mana data deret waktu awal diubah menjadi matriks lintasan (T_x). Penentuan nilai Window Length (L) sangat penting dalam proses ini, karena menentukan dimensi matriks lintasan. Matriks lintasan memiliki dimensi $L \times K$, di mana L adalah window length. Matriks lintasan ini memiliki pola khusus dimana semua elemen pada anti diagonalnya memiliki nilai yang sama, membentuk matriks Hankel. Penentuan nilai L biasanya dilakukan melalui uji coba dan penyesuaian, dengan rentang umum antara $2 < L < \frac{N}{2}$. Matriks trajectory (T_x) matriks trajectory (T_x) yang terbentuk merupakan matriks Hanke (Yundari, 2019). Matriks Hankel adalah matriks yang semua elemen di sepanjang diagonal konstan artinya setiap kemiringan diagonal dari kiri ke kanan adalah konstan. Matriks trajectory dapat dituliskan sebagai berikut

$$T_x = (T_{ij})_{L \times K} = \begin{bmatrix} x_1 & x_2 & \dots & x_K \\ x_2 & x_3 & \dots & x_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & \dots & x_N \end{bmatrix} \quad (1)$$

2.1.2. Singular Value Decomposition (SVD)

SVD dimulai dengan menentukan nilai eigenvalue dari matriks $T_x T_x^T$ dalam urutan menurut nilai eigenvalue dari yang terbesar hingga terkecil. Principal component direpresentasikan oleh matriks V, yang merupakan hasil normalisasi dari matriks eigenvector dan singular value. SVD dimulai dengan menentukan nilai eigenvalue ($\lambda_1, \lambda_2, \dots, \lambda_L$) dari matriks S.

$$S = T_x T_x^T \quad (2)$$

Dalam urutan menurut nilai eigenvalue dari yang terbesar hingga terkecil, dinotasikan sebagai $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L \geq 0$ dan $U_1, U_2, \dots, U_L$ adalah eigenvector dari masing-masing eigenvalue. Sedangkan principal component dinotasikan sebagai

$$\mathbf{V} = \frac{\mathbf{T}_x^T \mathbf{U}_p}{\sqrt{\lambda_p}} \quad (3)$$

untuk $p = 1, 2, \dots, d$, SVD dari matriks lintasan dituliskan sebagai $\mathbf{T}_{xp} = \mathbf{T}x_1 + \mathbf{T}x_2 + \dots + \mathbf{T}x_d$. Matriks $\mathbf{T}_{xp}$ mempunyai rank 1, karena merupakan matriks elementer. Kumpulan dari $(\sqrt{\lambda_p}, \mathbf{U}_p, \mathbf{T}_x^T)$ disebut eigentriple ke p dari SVD (Golyadina dkk, 2001). SVD dari matriks lintasan adalah sebagai berikut.

$$\begin{aligned} \mathbf{T}_{xp} &= T_{x1} + T_{x2} + \dots + T_{xd} \\ \mathbf{T}_{xp} &= U_1 \sqrt{\lambda_1} V_1^T + U_2 \sqrt{\lambda_2} V_2^T + \dots + U_d \sqrt{\lambda_d} V_d^T \\ \mathbf{T}_{xp} &= \sum_{i=1}^d U_i \sqrt{\lambda_i} V_i^T \end{aligned} \quad (4)$$

Konsep dasar pada tahap ini adalah mendapatkan barisan matriks dari matriks $\mathbf{S}$, dimana pada masing-masing matriks dalam barisan tersebut mengandung eigenvector ($\mathbf{U}_i$), singular value ($\sqrt{\lambda_i}$) dan komponen utama ($\mathbf{V}_i^T$) yang menggambarkan karakteristik pada masing-masing matriks barisan tersebut.

2.1.3. Grouping

Tahap rekonstruksi adalah proses grouping, dimana komponen-komponen aditif seperti tren, musiman, dan noise pada data deret waktu dipisahkan. Dasar dari pengelompokan ini adalah eigenvector. Pada tahap ini, hasil dekomposisi dari matriks lintasan yang memiliki dimensi $L \times K$ akan dikelompokkan dengan tujuan memisahkan komponen aditif dari SVD ke dalam beberapa kelompok, termasuk tren, musiman, dan noise (Fitri et al., 2017). Matriks $\mathbf{X}_i$ akan dipartisi ke m disjoint subset dilambangkan dengan $\mathbf{I}_x = \mathbf{I}_1 + \mathbf{I}_2 + \dots + \mathbf{I}_m$. Matriks ini dihitung untuk $\mathbf{I} = \mathbf{I}_1 + \dots + \mathbf{I}_m$, sehingga menjadi:

$$\mathbf{T} \mathbf{I} \mathbf{x} = \mathbf{T} \mathbf{I}_1 + \mathbf{T} \mathbf{I}_2 + \dots + \mathbf{T} \mathbf{I}_m$$

2.1.4. Averaging

Tujuan dari langkah ini adalah untuk mendapatkan singular value dari komponen-komponen yang telah dipisahkan, yang akan digunakan dalam proses peramalan. Hasil dari tahap ini akan menghasilkan sebuah matriks baru (Fitri et al., 2017).

$$\mathbf{F} = \begin{bmatrix} f_{11} & f_{21} & \dots & f_K \\ f_{12} & f_{22} & \dots & f_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ f_{L1} & f_{L+1} & \dots & f_N \end{bmatrix} \quad (6)$$

Diagonal Average dirumuskan sebagai berikut.

$$g_k = \begin{cases} \frac{1}{k} \sum_{m=1}^k f_{m,k-m+1}^* & \text{untuk } 1 \leq k < L^* \\ \frac{1}{L^*-1} \sum_{m=1}^{L^*-1} f_{m,k-m+1}^* & \text{untuk } L^* \leq k < K^* + 1 \\ \frac{1}{N-k+1} \sum_{m=k-K^*+1}^{N-K^*+1} f_{m,k-m+1}^* & \text{untuk } K^* + 1 \leq k \leq N \end{cases} \quad (7)$$

dimana $L^* = \min(L, K)$ dan $K^* = \max(L, K)$. Dari persamaan diatas jika diaplikasikan kedalam matriks resultan $\mathbf{X}_{im}$ maka akan membentuk deret baru $\tilde{\mathbf{Y}}^{(K)} = (\tilde{y}_1^{(k)}, \tilde{y}_2^{(k)}, \dots, \tilde{y}_N^{(k)})$. Oleh karena itu akan didekomposisi menjadi jumlah dari deret.

$$\tilde{\mathbf{Y}}_n = \sum_{k=1}^m \tilde{y}_n(k) \quad (8)$$

2.2. Autoregressive Integrated Moving Average

Model ARIMA merupakan model time series yang tidak stasioner terhadap mean dan memerlukan proses differencing sebanyak d agar stasioner. Secara umum bentuk model ARIMA (p, d, q) dirumuskan sebagai berikut (Aswi & Sukarna, 2006) :

$$\phi_p(B) (1 - B)^d Z_t = \theta_q(B) a_t \quad (9)$$

p, d, q = Orde autoregressive (AR), differencing, moving average (MA)
 B = Backshift operator (operator mundur)
 $\phi_p(B)$ = Operator AR non-musiman
 $(1 - B)^d$ = Orde differencing non-musiman
 $\theta_q(B)$ = Operator MA non-musiman

Tahap pertama yang dilakukan adalah mengidentifikasi model dengan tujuan untuk mengetahui data yang digunakan stasioner atau tidak stasioner. Apabila data tidak stasioner terhadap rata-rata maka dilakukan proses differencing dan jika data tidak stasioner terhadap variansi maka dilakukan transformasi Box-Cox. Selanjutnya identifikasi model ARIMA dengan melihat plot ACF dan plot PACF dari data yang sudah stasioner untuk menentukan model awal. Setelah diperoleh dugaan model awal ARIMA (p, d, q), selanjutnya parameter dari model tersebut ditaksir sehingga didapatkan besaran koefisien model. Selanjutnya dilakukan pemeriksaan model untuk membuktikan bahwa model tersebut cukup memadai. Pemeriksaan diagnostik dapat dibagi kedalam dua bagian, yaitu uji signifikan parameter menggunakan uji t , dan uji kesesuaian model (meliputi uji asumsi white noise menggunakan uji Ljung-Box dan residual berdistribusi normal menggunakan uji Shapiro Wilk). Kemudian jika terdapat lebih dari satu model yang memenuhi kriteria maka dilakukan perbandingan nilai AIC. Model yang memiliki nilai AIC terkecil akan dipilih menjadi model terbaik. Setelah itu, dilakukan peramalan.

2.3. Hybrid Autoregressive Integrated Moving Average – Singular Spectrum Analysis

Hasil peramalan model Hybrid SSA-ARIMA ($\hat{X}_t$), (Arumsari dkk., 2021):

$$\hat{X}_t = \hat{f}_t + \hat{Z}_t \quad (10)$$

dengan $\hat{f}_t$ adalah hasil peramalan dari metode SSA sedangkan $\hat{Z}_t$ adalah hasil peramalan dari metode ARIMA dengan data yang digunakan adalah data komponen noise.

2.4. Mean Absolute Percentage Error (Mape)

Nilai MAPE dapat dihitung menggunakan rumus berikut (Wulandari & Yurinanda, 2021) :

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{X_i - F_i}{X_i} \right|}{n} \times 100\% \quad (11)$$

Dimana,

X_i = data deret waktu aktual

F_i = data hasil peramalan

n = jumlah data

Tabel 1 Range MAPE

Range MAPE	Arti Nilai
< 10%	Kemampuan model peramalan sangat baik
10% – ≤ 20%	Kemampuan model peramalan baik
> 20% – ≤ 50%	Kemampuan model peramalan layak
> 50%	Kemampuan model peramalan buruk

3. Metode Penelitian

3.1. Prosedur analisis

Prosedur dalam penelitian ini terdiri dari beberapa tahapan. Pertama mengumpulkan data dan informasi terkait IHDP, menganalisis data menggunakan metode Hybrid SSA-ARIMA dan melakukan peramalan.

3.2. Teknik analisis data

Adapun teknik analisis data yang akan dilakukan pada penelitian yaitu

- (1). Melakukan analisis deskriptif indeks harga yang dibayar petani .
- (2). Melakukan analisis deret waktu Singular Spectrum Analysis (SSA)
 - (a). Embedding, data yang digunakan diubah menjadi matriks lintasan.
 - (b). Singular Value Decomposition (SVD), menentukan nilai eigentriple yang meliputi singular value $\sqrt{\lambda_i}$, eigenvector U_i , principal components V_i^T .
 - (c). Grouping, dilakukan dengan cara mengelompokkan eigentriple yang diperoleh pada tahap SVD ke dalam beberapa komponen, yaitu tren, musiman, dan noise.
 - (d). Diagonal Averaging, tahap ini dilakukan dengan cara menghitung nilai rata-rata diagonal dari komponen-komponen yang telah dipisahkan yaitu tren dan musiman untuk mendapatkan singular value yang akan digunakan pada tahap peramalan.
- (3). Melakukan analisis deret waktu dengan ARIMA pada data komponen noise dari hasil rekonstruksi metode SSA, dengan tahapan sebagai berikut:
 - (a). Membuat plot time series
 - (b). Mengecek stasioneritas data komponen noise,
 - (c). Membuat plot FAK dan FAKP untuk identifikasi bentuk model ARIMA.
 - (d). Mengestimasi parameter untuk melihat hasil uji signifikansi parameter berdasarkan model yang terpilih.
 - (e). Melakukan pemeriksaan diagnostik, uji signifikan parameter, white noise dan Shapiro Wilk
 - (f). Jika diperoleh lebih dari satu model ARIMA, maka dilakukan pemilihan model terbaik dengan menggunakan MAPE.
 - (g). Melakukan peramalan dengan model ARIMA.
- (4). Melakukan peramalan model Hybrid SSA-ARIMA dengan cara menggabungkan hasil peramalan SSA dan ARIMA
- (5). Menghitung akurasi peramalan dengan menggunakan MAPE dari model


4. Hasil dan Pembahasan

4.1. Analisis Deskripsi

Tabel 2 Analisis Deskripsi Indeks Harga yang Dibayarkan Petani di Provinsi Sulawesi Selatan.

Peubah	Min	Max	Mean	Standar Deviasi
Indeks Harga yang Dibayarkan	101,5	118,1	108,7	107,5

Dari Tabel diatas dapat diketahui sejak Januari 2019 sampai Juni 2024 rata-rata nilai indeks harga adalah 108,7 dan sebarannya sebesar 107,5. Adapun nilai indek harga yang dibayarkan petani terendah atau mengalami deflasi senilai 101,5 pada bulan maret 2019 dan nilai indeks harga tertinggi pada bulan juni 2024 sebesar 118,1. Berikut plot time series dari data tingkat IHDP di Sulawesi Selatan yang ditunjukkan pada Gambar 1.



Gambar 1 Indeks Harga yang Dibayarkan Petani di Provinsi Sulawesi Selatan Januari 2019 – Juni 2024.

Grafik pada Gambar 1 menunjukkan bahwa indeks harga yang dibayarkan oleh petani di Provinsi Sulawesi Selatan mengalami kenaikan yang cenderung stabil dari Januari 2019 hingga Juni 2024. Kenaikan ini mengindikasikan bahwa biaya yang dikeluarkan petani terus meningkat secara konsisten selama periode tersebut, mencerminkan perubahan harga barang dan jasa yang mereka butuhkan untuk aktivitas pertanian mereka.

4.2. Singular Spectrum Analysis

4.2.1. Embedding

Pada tahap embedding ini akan menghasilkan matriks lintasan yang diketahui semua elemen anti diagonalnya bernilai sama. Data yang digunakan pada penelitian ini sebanyak 54 rata runtun waktu sehingga nilai L yang digunakan adalah 27 maka dimensi $K = (54 - L) + 1 = 28$. Matriks lintasan dapat disusun sebagai berikut:

$$\mathbf{T}_x = \mathbf{T}_{i,j(27 \times 28)} = \begin{bmatrix} 106,29 & 106,25 & \cdots & 101,92 \\ 106,82 & 106,29 & \cdots & 101,75 \\ \vdots & \vdots & \ddots & \vdots \\ 114,69 & 114,46 & \cdots & 106,82 \end{bmatrix} \quad (12)$$

4.2.2. Singular Value Decomposition (SVD)

Sebelum mencari nilai Singular Value Decomposition (SVD) tahap yang harus dilakukan adalah membentuk matriks baru S sesuai persamaan (2.2) menggunakan matriks $\mathbf{T}_x$ yang sudah diperoleh. Berdasarkan persamaan (2.2) diperoleh matriks S sebagai berikut.

$$\mathbf{S}_{i,j(27 \times 27)} = \begin{bmatrix} 302147,7 & 302698,3 & 303257,6 & \cdots & 320734,3 \\ 30269,3 & 303251,9 & 303812,3 & \cdots & 321321,3 \\ 303257,6 & 303812,3 & 304375,6 & \cdots & 321917,2 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 320734,3 & 321321,3 & 321917,2 & \cdots & 340507,3 \end{bmatrix} \quad (13)$$

Langkah kedua dalam dekomposisi adalah membuat singular value decomposition (SVD) dari matriks lintasan. Pada proses SVD akan terdiri dari eigenvector, singular value dan komponen utama. Tabel dari hasil SVD dapat dilihat pada lampiran 2. Eigentriple tersebut akan digunakan pada tahap berikutnya, yaitu sebagai dasar pengelompokkan (grouping).

4.2.3. Grouping

Pada tahap awal dari grouping adalah melakukan pengelompokan eigentriple yang telah diperoleh pada tahap SVD. Eigentriple yang memiliki karakteristik hampir sama akan dikelompokkan ke dalam satu kelompok atau komponen. Pengelompokan dilakukan melalui analisis secara grafis, yang memunculkan grafik eigenvector.

Gambar 2 Grafik Eigenvectors



Menurut Ete (2017), Tren adalah suatu komponen yang bervariasi secara lambat dari suatu deret waktu yang tidak mengandung komponen oscillatory. Semua komponen yang bervariasi secara lambat pada plot dari deret yang direkonstruksi diidentifikasi sebagai komponen tren. Sedangkan musiman dilakukan berdasarkan kemiripan nilai singular dari dua eigentriple yang berurutan. Pada plot dari deret yang direkonstruksi, kemiripan nilai singular mengakibatkan deret yang direkonstruksi oleh suatu eigentriple memiliki pola musiman yang sama dan periode musiman yang sama dengan deret yang direkonstruksi oleh eigentriple yang lainnya. Selanjutnya dilakukan pengelompokan eigentriple ke dalam komponen musiman yang dilakukan berdasarkan kemiripan eigentriple yang berurutan. Berdasarkan Gambar 4.2 memperlihatkan bahwa deret direkonstruksi oleh eigentriple 1 dan 2 memuat komponen tren yang bervariasi lambat dan untuk musiman berdasarkan Gambar 4.2 diketahui bahwa terlihat beberapa pasang eigentriple berurutan yang memiliki kemiripan pola yaitu eigentriple 8 dan 9, serta eigentriple 11 dan 12. Dengan demikian sisa eigentriple yang tidak dikelompokkan ke dalam kelompok tren dan musiman akan dikelompokkan ke dalam kelompok noise.

4.2.4. Diagonal Averaging

Pada tahap ini hasil dari grouping ditransformasi ke dalam deret baru. Tahapan ini menghasilkan komponen dari data. Mendapatkan singular value dari komponen-komponen yang telah dipisahkan merupakan tujuan pada tahap ini, kemudian digunakan dalam peramalan. Hasil Diagonal averaging ditunjukkan pada Tabel 3.

Tabel 3 Diagonal Avernging

Waktu ke-	Rekontruksi		Diagonal Averaging
	Trend	Seasonal	
1	101,411	-0,018	101,392
2	101,546	0,032	101,578
3	101,698	-0,019	101,67
4	101,872	-0,054	101,817
5	102,055	0,0597	102,115
⋮	⋮	⋮	⋮
54	115,261	0,2477	115,509

4.2.5. Peramalan Singular Spectrum Analysis (SSA)

Pada tahap ini dilakukan peramalan SSA menggunakan metode rekuren (R-forecasting). Peramalan dilakukan untuk 12 periode selanjutnya.

Tabel 4 Hasil Peramalan Indeks Harga yang Dibayarkan Petani di Provinsi Sulawesi Selatan

Bulan	Peramalan		Indeks Harga yang Dibayarkan Petani di Provinsi Sulawesi Selatan
	Komponen Tren	Komponen Musiman	
Jul-23	115,86	-0,06	115,79
Aug-23	116,30	-0,10	116,20
Sep-23	116,74	-0,07	116,82
Oct-23	117,19	-0,01	117,18
Nov-23	117,64	0,04	117,68
Dec-23	118,09	-0,05	118,03
Jan-24	118,54	-0,03	118,51
Feb-24	119,00	0,01	119,01
Mar-24	119,46	0,17	119,64
Apr-24	119,93	-0,16	119,77
May-24	120,40	-0,12	120,27
Jun-24	120,88	0,23	121,11


Pada Tabel 4.3 memperlihatkan hasil ramalan SSA dari juli 2023 sampai dengan juni 2024. Adapun besaran kesalahan peramalan sebesar 1,82% yang dihitung menggunakan MAPE.

4.3. Hybrid SSA-Arima

Data yang digunakan adalah data komponen noise yang telah diperoleh pada metode SSA. Berikut langkah-langkah analisis ARIMA.

4.3.1. Stasioneritas

Stasioneritas dari data noise dapat dilihat dengan beberapa cara salah satunya adalah meliaht diagram pencar deret waktu seperti pada Gambar 3.




Gambar 3. Plot Deret Waktu Komponen Noise

Berdasarkan Gambar 4.3 pertama data akan dilakukan pemeriksaan kestasioneran dalam rata-rata dengan menggunakan uji Phillips Perron. Data dikatakan stasioner dalam rata-rata apabila $p\text{-value} < \alpha (0,05)$. P-value yang didapatkan adalah $0,04218 < \alpha (0,05)$, sehingga dapat dikatakan bahwa data stasioner terhadap rata-rata. Selanjutnya, kita akan melakukan pemeriksaan kestasioneran dalam variansi menggunakan transformasi Box-Cox. Data dikatakan stasioner dalam

variansi apabila nilai λ mendekati atau bernilai 1. Berdasarkan hasil analisis diperoleh nilai $\lambda = 1,093213$ yang mendekati nilai 1, sehingga dapat disimpulkan bahwa data komponen noise sudah stasioner secara variansi.

4.3.2. Identifikasi Model

Dalam melakukan identifikasi model dalam ARIMA dimulai dengan mengidentifikasi plot Autocorrelation Function (ACF) dan plot Partial Autocorrelation Function (PACF).



Gambar 4. Plot ACF dan PACF

Berdasarkan Gambar 4.4 diketahui bahwa plot ACF membentuk pola dies down, Sedangkan pada PACF membentuk pola cut off after lag 1. Sehingga model ARIMA sementara adalah ARIMA (1,0,0).

4.3.3. Penaksiran parameter

Berdasarkan Tabel 4.4 terlihat bahwa model signifikan yakni model ARIMA (1,0,0) dan parameternya memiliki p-value = $< \alpha$ (0,05) yang dapat diartikan bahwa parameter dari model tersebut signifikan. Setelah didapatkan model terbaik, selanjutnya dilakukan uji white noise dan uji residual berdistribusi normal.

Tabel 5 Penaksiran Parameter ARIMA

Model	Parameter	Estimasi	P-Value	Signifikan parameter
ARIMA (1,0,0)	ϕ_1	0,77389	2,918e-14 ***	Signifikan

4.3.4. Diagnostik Model

Uji diagnostik model meliputi uji residual white noise dan Residual Berdistribusi normal menggunakan uji Shapiro wilk.

Tabel 6 Hasil Pengujian Asumsi White Noise

Model	p-value
ARIMA (1,0,0)	0,1993

Berdasarkan hasil uji white noise yang diperoleh terlihat pada Tabel 4.5 nilai p-value model diatas lebih besar dari α (0,05) berarti gagal tolak H_0 yang diartikan bahwa model ARIMA (1,0,0) residualnya telah memenuhi asumsi white noise.

Table 7 Hasil Uji Shapiro Wilk

Model	Shapiro Wilk	P-Value
ARIMA (1,0,0)	0,98976	0,9244

Berdasarkan hasil uji Shapiro Wilk yang diperoleh terlihat pada Tabel 4.6 nilai p-value model lebih besar dari α (0,05) berarti gagal tolak H_0 dan dapat diartikan bahwa model ARIMA (1,0,0) residualnya telah berdistribusi normal.

4.3.5. Pemilihan Model Terbaik

Setelah melakukan penaksiran parameter dan diagnostik model dapat disimpulkan ARIMA (1,0,0) dapat digunakan untuk peramalan. Secara matematis model ARIMA (1,0,0) dapat ditulis sebagai berikut:

$$Z_t = 0,77389Z_{t-1} + a_t \quad (14)$$

4.3.6. Peramalan ARIMA dan Hybrid SSA-ARIMA

Langkah selanjutnya adalah melakukan peramalan 12 bulan ke depan untuk ARIMA (1,0,0) sebagai berikut.

Tabel 8 Hasil Peramalan ARIMA (1,0,0)

Waktu	Peramalan
Juli 2023	-0,6341
Agustus 2023	-0,9407
September 2023	-0,3797
Oktober 2023	-0,2929
November 2023	-0,2274
Desember 2023	-0,1760
Januari 2024	-0,1362
Februari 2024	-0,1054
Maret 2024	-0,0815
April 2024	-0,0631
Mei 2024	-0,0488
Juni 2024	-0,0378

Setelah melakukan tahapan SSA dan ARIMA langkah selanjutnya adalah melakukan peramalan dan melihat akurasi untuk hybrid SSA-ARIMA, diperoleh dengan cara menjumlahkan hasil peramalan dari model SSA dan model ARIMA (1,0,0).

Tabel 9 Hasil Peramalan Hybrid SSA-ARIMA (1,0,0) Data Out-Sample Indeks Harga yang Dibayarkan Petani di Provinsi Sulawesi Selatan.

Waktu	SSA	ARIMA (1,0,0)	Hybrid SSA-ARIMA (1,0,0)
Juli 2023	115,79	-0,6341	115,1616
Agustus 2023	116,20	-0,9407	115,2605
September 2023	116,82	-0,3797	116,4450
Oktober 2023	117,18	-0,2929	116,8875
November 2023	117,68	-0,2274	117,4619
Desember 2023	118,03	-0,1760	117,8595
Januari 2024	118,51	-0,1362	118,3824
Februari 2024	119,01	-0,1054	118,9125
Maret 2024	119,64	-0,0815	119,5621
April 2024	119,77	-0,0631	119,7096
Mei 2024	120,27	-0,0488	120,2310
Juni 2024	121,11	-0,0378	121,0807


4.3.7. Akurasi Peramalan Hybrid SSA-ARIMA

Berikut ditampilkan tabel hasil pengukuran akurasi peramalan SSA dan Hybrid SSA-ARIMA berdasarkan nilai MAPE yang diperoleh yaitu :

Tabel 10 Hasil Pengukuran Akurasi Peramalan Berdasarkan MAPE

Mode	MAPE
SSA	1,820814006
SSA-ARIMA	1,594910291

Berdasarkan Tabel 4.9 diatas terlihat akurasi peramalan model Hybrid SSA-ARIMA (1,0,0) memiliki nilai MAPE sebesar 1,59% lebih kecil dibandingkan dengan model SSA dan termasuk ke dalam kategori kemampuan peramalan sangat baik. Secara grafis perbedaan antara nilai aktual dan peramalan dapat digambarkan pada Gambar 4.5 terlihat bahwa nilai peramalan pada data out-sample cenderung mengikuti nilai aktual.

**Gambar 4** Grafik Data Aktual dan Data Peramalan.

5. Kesimpulan

Berdasarkan analisis yang telah dilakukan maka dapat disimpulkan bahwa Hasil peramalan Hybrid SSA-ARIMA dalam meramalkan Indeks Harga Yang Dibayarkan Petani di Provinsi Sulawesi Selatan selama 12 bulan dari Juli 2023 sampai dengan Juni 2024 menunjukkan nilai inflasi terendah terjadi pada bulan Desember sebesar 0,89 dan nilai inflasi tertinggi terjadi pada bulan Maret sebesar 4,80. Akurasi peramalan diperoleh nilai MAPE untuk Singular Spectrum Analysis sebesar 56,26797 dan Hybrid SSA-ARIMA sebesar 18,88851. Hal ini menunjukkan bahwa Hybrid SSAARIMAmemiliki kemampuan peramalan yang lebih baik dibandingkan dengan Singular Spectrum Analysis dalam meramalkan tingkat inflasi di Indonesia.

References

- Amalia Idrus, R. (2022). Penerapan Metode Singular Spectrum Analysis dalam Peramalan Jumlah Produksi Beras di Kabupaten Gowa. *VARIANSI: Journal of Statistics and Its Application on Teaching and Research*, 4(2), 49–58. <https://doi.org/10.35580/variasiunm40>.
- Andhika, G. B., sumarjaya, I. W., & srinadi, I. G. A. M. (2020). Peramalan Nilai Tukar Petani menggunakan Metode Singular Spectrum Analysis. *E-Jurnal Matematika*, 9(3), 171. <https://doi.org/10.24843/mtk.2020.v09.i03.p295>.
- Arumningsih, L. D., & Darsyah, M. Y. (2018). Peramalan Indeks Harga Konsumen Kota Malang Tahun 2014–2016 dengan menggunakan Metode Moving Average dan Exponential Smoothing Holt-Winter. *Prosiding Seminar Nasional ...*, 1(January 2018), 310–315.

- Arumsari, M., Wahyuningsih, S., & Siringoringo, M. (2021). Inflation Forecasting for East Kalimantan Province Using Hybrid Singular Spectrum Analysis- Autoregressive Integrated Moving Average Model. *Jurnal Matematika, Statistika dan Komputasi*, 18(1), 78–92. <https://doi.org/10.20956/j.v18i1.14284>
- Asmara, R., & Hanani, N. (2016). Tingkat Kesejahteraan Petani Kabupaten Jombang: Pendekatan Nilai Tukar Petani. *Seminar Nasional Pembangunan Pertanian 2016*, 78–83.
- Asrof, A. (2017). Peramalan Produksi Cabai Merah di Jawa Barat Menggunakan Metode Singular Spectrum Analysis (SSA). *STATISTIKA: Journal of Theoretical Statistics and Its Applications*, 17(2), 77–87. <https://doi.org/10.29313/jstat.v17i2.2839>.
- Aswi, & Sukarna. (2006). Analisis deret waktu: Teori dan aplikasinya. Andira Publisher.
- Ayu, R., Gernowo, R., Fisika, D., Sains, F., Diponegoro, U., & E-, S. (2019). Metode Autoregressive Integrated Movingaverage (Arima) Dan Metode Adaptive Neuro Fuzzy Inference System (Anfis) Dalam Analisis Curah Hujan. *Berkala Fisika*, 22(1), 41–48.
- Box, G. E. P., & Jenkins, G. M. (1976). *Time Series Analysis: Forecasting and Control*. Holden-Day.
- Darmawan, G., Rosadi, D., & Ruchjana, B. N. (2022). Hybrid Model of Singular Spectrum Analysis and ARIMA for Seasonal Time Series Data. *CAUCHY: Jurnal Matematika Murni dan Aplikasi*, 7(2), 302–315. <https://doi.org/10.18860/ca.v7i2.14136>.
- Darmawan, G. (2016). Identifikasi Pola Data Curah Hujan pada Proses Grouping dalam Metode Singular Spectrum Analysis. *Seminar Nasional Pendidikan Matematika*, 1–7.
- Darmawan, G., Hendrawati, T., & Arisanti, R. (2015). Model Auto Singular Spectrum Untuk Meramalkan. *Prosiding Seminar UNY 2015*, 1, 457–462.
- Endrayani, N. K. E., & Dewi, M. H. U. (2016). Analisis Faktor-Faktor yang Mempengaruhi Tingkat Kemiskinan Kabupaten/Kota Di Provinsi Bali. *E-Jurnal Ekonomi dan Bisnis Universitas Undayana*, 5(1), 63–88.
- Fajar, M. (2019). Perbandingan Kinerja Peramalan Pertumbuhan Ekonomi Indonesia dengan ARIMA , SSA dan Hybrid ARIMA-SSA. *ResearchGate*, 1–7. <https://doi.org/10.13140/RG.2.2.28620.26244>
- Fitri, F., Gamayanti, N. F., & Gunawan, G. (2017). Metode SSA Pada Data Produksi Perikanan Tangkap di Provinsi Jawa Barat. *Jurnal Ilmiah Matematika dan Pendidikan Matematika*, 9(2), 95. <https://doi.org/10.20884/1.jmp.2017.9.2.2870>.
- Golyandina, N., Nekrutkin, V., & Zhigljavsky, A. (2001). *Analysis of Time Series Structure: SSA and Related Techniques*. Chapman & Hall/CRC.
- Hartati, H. (2017). Penggunaan Metode Arima Dalam Meramal Pergerakan Inflasi. *Jurnal Matematika Sains dan Teknologi*, 18(1), 1–10. <https://doi.org/10.33830/jmst.v18i1.163.2017>
- Irwan, Adnan Sauddin, & Anita Kaimuddin. (2022). Proyeksi Produksi Padi Kabupaten Pinrang dengan Metode Singular Spectrum Analysis. *Jurnal MSA (Matematika dan Statistika Serta Aplikasinya)*, 10(1), 100–109. <https://doi.org/10.24252/msa.v10i1.29869>
- Martha, S., & Si, S. (2010). Peramalan Data Time Series Menggunakan Metode Box-Jenkins. *Statistika*.
- Nirmala, A., Hanani, N., & Muhaimin, A. (2016). Analisis Faktor Faktor yang Mempengaruhi Nilai Tukar Petani Tanaman Pangan di Kabupaten Jombang. *Habitat*, 27(2), 66–71. <https://doi.org/10.21776/ub.habitat.2016.027.2.8>
- Nurfadila, K., & Ilham Aksan. (2020). Aplikasi Metode Arima Box-Jenkins Untuk Meramalkan Penggunaan Harian Data Seluler. *Journal of Mathematics: Theory and Applications*, 2(1), 5–10. <https://doi.org/10.31605/jomta.v2i1.749>
- Permata, E., Putri, S., Zukhronah, E., & Susanti, Y. (2023). Model Hibrida Singular Spectrum Analysis (SSA) dan Autoregressive Integrated Moving Average (ARIMA) untuk Peramalan Indeks Harga Konsumen. 72–81.
- Qadrini, L., Asrirawan, A., Mahmudah, N., Fahmuddin, M., & Amri, I. F. (2020). Forecasting Bank Indonesia currency

- inflow and outflow using arima, time series regression (tsr), arimax, and nn approaches in Lampung. *Jurnal Matematika, Statistika Dan Komputasi*, 17(2), 166–177. <https://doi.org/10.20956/jmsk.v17i2.11803>
- Rachmat, M. (2013). Nilai tukar petani : konsep, pengukuran dan relevansinya sebagai indikator kesejahteraan petani Farmers' Terms of Trade: The Concept, Estimation, and Relevance for Farmers' Welfare Indicators. *Jurnal Agro Ekonomi*, 31(2), 113.
- Rebeka Pardosi, A. (2024). Analisis Perencanaan Peramalan dan Safety Stock Sprite 250ML dengan Metode Time Series Di PT. XYZ. *Teknik Elektro dan Informatika*, 2(2), 10–21. <https://doi.org/10.61132/jupiter.v2i2.84>
- RM, D. A. P., & Adhar, D. (2023). Penerapan Metode Autoregressive Integrated Moving Average (ARIMA) untuk Prediksi Jumlah Siswa Baru Pada MTs Swasta Tahfidzul Qur'an Nurul Azmi. *Jurnal Rekayasa Sistem (JUREKSI)*, 1(1), 82–93. <https://kti.potensiutama.org/index.php/JUREKSI/article/view/312>
- Sumartini, Hayati, M. N., & Wahyuningsih, S. (2017). Peramalan Menggunakan Metode Fuzzy Time Series Cheng. *Jurnal EKSPONENSIAL*, 8, 51–56.
- Thamrin, S. (2016). Faktor-Faktor Yang Mempengaruhi Produksi Usahatani Kopi Arabika di Kabupaten Enrekang Sulawesi Selatan. *Agric*, 26(1), 1. <https://doi.org/10.24246/agric.2014.v26.i1.p1-6>
- Udhar, N. A. A. (2020). The Effect Of The Dynamic Of Economic Sectors to Income Inequality In South Sulawesi.
- Yundari, A. W. H. (2019). Prediksi Outflow Uang Kartal di Kalimantan Barat dengan Metode Singular Spectrum Analysis (Ssa). *Bimaster: Buletin Ilmiah Matematika, Statistika dan Terapannya*, 8(3), 545–554. <https://doi.org/10.26418/bbimst.v8i3.33903>.