

Application of Singular Spectrum Analysis for Predicting Indonesia's Total Export Value

Ronald Rinaldo, Yenni Kurniawati*, Dony Permana, dan Dina Fitria

Departemen Statistika, Universitas Negeri Padang, Padang, Indonesia

*Corresponding author: yennikurniawati@fmipa.unp.ac.id

Submitted : 18 Mei 2025

Revised : 28 Mei 2025

Accepted : 30 Mei 2025

ABSTRACT

Forecasting export data presents unique challenges due to seasonal fluctuations and complex global economic dynamics. Inaccurate forecasts may lead to misguided economic policies, particularly in the export sector, which plays a critical role in national economic growth. This study aims to forecast the total export value of two major sectors in Indonesia from January to December 2024 using the Singular Spectrum Analysis (SSA) method. Forecasting is essential in supporting economic policy planning and strategic decision-making. SSA is chosen for its ability to decompose time series data into interpretable components such as trend, seasonality, and noise. The forecasting model's performance is evaluated using the Mean Absolute Percentage Error (MAPE), which provides an intuitive accuracy interpretation in percentage terms. The optimal parameter for SSA was found at $L=28L = 28L=28$, yielding a MAPE of 16.63%, indicating good forecasting accuracy. The forecasted export values show that the highest export is expected in December 2024 (USD 39,578.67 million), and the lowest in January 2024 (USD 21,689.14 million). These findings suggest that SSA is effective in forecasting economic time series data, particularly Indonesia's export values. This study contributes to the practical application of SSA in economics and serves as a reference for future research and policymakers in formulating export strategies.

Keywords: Economic Forecasting, Export, Mean Absolute Percentage Error, Singular Spectrum Analysis, Time Series



This is an open access article under the Creative Commons 4.0 Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited. ©2022 by author and Universitas Negeri Padang.

I. PENDAHULUAN

Ekspor merupakan salah satu pilar utama dalam perekonomian Indonesia, di mana kegiatan pengiriman barang ke luar negeri, baik dari sektor migas maupun nonmigas, telah memberikan kontribusi signifikan terhadap pertumbuhan ekonomi nasional. Dalam beberapa tahun terakhir, khususnya periode 2018 hingga 2023, nilai ekspor Indonesia menunjukkan pola fluktuasi yang cukup tajam, dipengaruhi oleh faktor musiman, tren, serta kejadian seperti pandemi COVID-19 yang menyebabkan penurunan ekspor pada awal 2020. Setelah masa krisis tersebut, ekspor Indonesia sempat pulih dan mencapai puncaknya di awal 2022, namun kembali mengalami fluktuasi dan cenderung menurun di akhir 2023. Kondisi ini menegaskan pentingnya peramalan (*forecasting*) yang akurat untuk membantu pemerintah dan pelaku ekonomi dalam mengantisipasi perubahan, menyusun strategi, serta mengambil kebijakan yang tepat guna menjaga stabilitas dan meningkatkan kinerja ekspor nasional.

Metode peramalan yang umum digunakan seperti ARIMA memiliki keterbatasan, terutama karena memerlukan data yang stasioner dan kurang mampu menangani data dengan pola tren, musiman, dan *noise* yang kompleks seperti yang terjadi pada data ekspor Indonesia. Oleh karena itu, *Singular Spectrum Analysis* (SSA) dipilih sebagai alternatif yang lebih fleksibel dan efektif. SSA merupakan metode nonparametrik yang tidak memerlukan asumsi stasioneritas, serta mampu mendekomposisi data deret waktu menjadi komponen tren, musiman, dan *noise* secara lebih detail (Sulandari et al., 2020). Keunggulan ini telah dibuktikan dalam berbagai penelitian terdahulu, seperti Ruhiat et al. (2020) menerapkan metode SSA dan SARIMA pada data debit Sungai Citarum dan diperoleh kesimpulan bahwa metode SSA cukup handal dibandingkan SARIMA untuk data yang mengandung musiman, data non linier dengan *Mean Absolute Percentage Error* (MAPE) SSA sebesar 0,00000457%. Serta Irwan et al. (2022) menerapkan metode SSA pada peramalan produksi padi diperoleh MAPE sebesar 4,97%. Dari berbagai penelitian di atas maka terlihat bahwa metode SSA memiliki tingkat akurasi yang tinggi dalam menangani beberapa kasus dalam peramalan.

Berdasarkan latar belakang tersebut, penelitian ini dikembangkan untuk menganalisis kontribusi dan ketergantungan ekonomi Indonesia terhadap ekspor migas dan nonmigas, serta melakukan peramalan total nilai ekspor kedua sektor tersebut untuk periode Januari hingga Desember 2024 menggunakan metode SSA. Penelitian ini juga bertujuan untuk mengukur tingkat akurasi hasil peramalan yang dihasilkan oleh metode SSA. Dengan demikian, penelitian ini diharapkan tidak hanya memberikan kontribusi dalam pengembangan ilmu pengetahuan, khususnya dalam penerapan metode SSA pada data ekonomi, tetapi juga memberikan manfaat praktis sebagai referensi bagi peneliti selanjutnya dan sebagai bahan pertimbangan bagi pengambil kebijakan dalam merumuskan strategi ekspor Indonesia di masa mendatang.

II. METODE PENELITIAN

A. Jenis Penelitian dan Sumber Data

Penelitian ini merupakan penelitian terapan yang bertujuan untuk menguji dan menerapkan metode *Singular Spectrum Analysis* (SSA) dalam meramalkan nilai ekspor Indonesia. Penelitian terapan dipilih karena fokus utamanya adalah pada pemanfaatan metode statistik dan matematis secara langsung untuk memecahkan permasalahan praktis, dalam hal ini peramalan nilai ekspor nasional. Data yang digunakan dalam penelitian ini adalah data sekunder berupa total nilai ekspor migas dan nonmigas Indonesia pada periode Januari 2019 hingga 2023. Data tersebut diperoleh dari dua sumber resmi, yaitu Badan Pusat Statistik (BPS) dan Sistem Informasi Kementerian Perdagangan Republik Indonesia, yang dapat diakses melalui tautan: <https://satudata.kemendag.go.id/data-informasi/perdagangan-luar-negeri/ekspor-impor>.

B. Teknik Analisis Data

Analisis data dalam penelitian ini mengimplementasikan metode *Singular Spectrum Analysis* (SSA) dengan mengacu pada prosedur yang dikembangkan oleh Fitri (2020). Tahapan analisis dijelaskan secara komprehensif sebagai berikut:

1. Eksplorasi Data

Tahap awal dilakukan dengan memvisualisasikan data deret waktu total ekspor migas dan nonmigas Indonesia periode Januari 2019–Desember 2023 dalam bentuk *plot*. Visualisasi ini bertujuan mengidentifikasi pola dasar data seperti tren, musiman, atau fluktuasi acak sebelum dilakukan pemrosesan lebih lanjut.

2. Pemisahan Data Latih dan Data Uji

Data dibagi menjadi dua subset dengan rasio 80:20, di mana 80% data latih mencakup periode Januari 2018–Oktober 2022, sedangkan 20% data uji meliputi November 2022–Desember 2023. Pembagian ini memungkinkan evaluasi kinerja model pada data yang belum pernah diproses selama pelatihan.

3. *Embedding*

Pada tahap ini, data deret waktu satu dimensi diubah menjadi matriks multidimensi (*trajectory matrix*) berukuran $L \times K$, di mana L (*window length*) ditentukan melalui *trial and error* pada rentang $2 \leq L \leq N/2$ (Hassani, 2018:3). Nilai L optimal dipilih berdasarkan *Mean Absolute Percentage Error* (MAPE) terkecil, sementara K dihitung menggunakan persamaan (1).

$$K = N - L + 1 \quad (1)$$

Matriks *trajectory* yang dihasilkan memiliki struktur sebagai berikut:

$$X = [X_1 \quad X_2 \quad \dots \quad X_K] = (x_{ij})_{i,j=1}^{L,K}$$

$$X_{L \times K} = \begin{bmatrix} x_1 & x_2 & \dots & x_K \\ x_2 & x_3 & \dots & x_{K+1} \\ x_3 & x_4 & \dots & x_{K+2} \\ \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & \dots & x_N \end{bmatrix}$$

4. *Singular Value Decomposition (SVD)*

Proses ini menghasilkan himpunan komponen yang dikenal sebagai *eigentriple*, yaitu berupa pasangan nilai dan vektor: *eigenvector* (U_i), *singular value* ($\sqrt{\lambda_i}$), serta *principal component* (V_i). Nilai U_i dan $\sqrt{\lambda_i}$ diturunkan dari dekomposisi terhadap matriks kovarians $S = XX^T$, sedangkan nilai V_i diperoleh melalui persamaan (2) berikut:

$$V_i = \frac{X^T U_i}{\sqrt{\lambda_i}} \quad (2)$$

Berdasarkan hasil tersebut, matriks X dapat direpresentasikan sebagai penjumlahan dari komponen-komponen *rank*-satu:

$$X = \sum_{i=1}^d \sqrt{\lambda_i} U_i V_i^T$$

Dengan demikian, struktur data dapat dipahami sebagai gabungan berbagai pola yang terekstraksi dari matriks asli.

5. *Grouping*

Tahapan selanjutnya adalah mengelompokkan komponen-komponen hasil dekomposisi ke dalam beberapa kategori seperti tren, pola musiman, dan gangguan (*noise*). Tujuan dari tahapan ini adalah untuk memisahkan komponen antara *signal* dan *noise* (Hassani, 2018) Proses ini dilakukan secara eksploratif untuk menentukan kelompok mana yang memiliki keterkaitan logis dan signifikan terhadap struktur data. Setiap kelompok hasil pengelompokan dilambangkan sebagai:

$$X_{Ij} = X_{I1} + \dots + X_{Im}$$

yang merepresentasikan penjumlahan beberapa komponen terpilih hasil dekomposisi.

6. *Diagonal Averaging*

Diagonal averaging adalah proses transformasi matriks hasil *grouping* kembali menjadi deret waktu satu dimensi dengan panjang yang sama seperti data awal (Isnawati, 2018). Misalkan matriks hasil *grouping* adalah Y berukuran $L \times K$ dengan elemen y_{ij} , maka proses ini menghasilkan deret waktu baru g_0, g_1, \dots, g_{N-1} dengan persamaan (3) sebagai berikut (Golyandina, 2013)

$$g_k = \frac{\sum_{(l,m) \in A_k} y_{lm}}{|A_k|} \quad (3)$$

di mana A_k adalah himpunan indeks elemen pada diagonal ke- k dan $|A_k|$ adalah jumlah elemen pada diagonal tersebut. Contohnya, untuk $k = 1, g_1 = y_{11}$; untuk $k = 2, g_2 = \frac{(y_{12} + y_{21})}{2}$, dan seterusnya. Proses ini menghasilkan deret waktu yang telah dipisahkan berdasarkan komponen yang diinginkan (*tren, musiman, noise*).

7. Peramalan dengan *Linear Recurrent Formula (LRF)*

Untuk membangun model peramalan, digunakan pendekatan *Linear Recurrent Formula (LRF)*, yang koefisiennya dihitung berdasarkan komponen utama hasil dekomposisi. Koefisien LRF dihitung menggunakan persamaan (4).

$$\mathfrak{R} = (a_{L-1}, \dots, a_1)^T = \frac{1}{1 - v^2} \sum_{i=1}^r \pi_i U_i^{\bar{v}} \quad (4)$$

Dimana $U = (u_1, u_2, \dots, u_{L-1}, u_L)^T, U^{\bar{v}} = (u_1, u_2, \dots, u_{L-1})^T, \pi_i$ merupakan komponen terakhir dari vector U dan $v^2 = \sum_{i=1}^r \pi_i^2$.

Model peramalan RSSA diperoleh dengan menggunakan persamaan berikut.

$$g_i = \begin{cases} \hat{y}_i & ; \text{untuk } i = 0, \dots, N \\ \sum_{j=1}^{L-1} a_j g_{i-j} & ; \text{untuk } i = N + 1, \dots, N + h \end{cases}$$

8. Evaluasi Akurasi

Untuk menilai seberapa baik model melakukan prediksi, digunakan indikator *Mean Absolute Percentage Error* (MAPE) (Montgomery dkk., 2015), yang dihitung menggunakan persamaan (5) berikut:

$$MAPE = \frac{\sum_{i=1}^t \left| \frac{y_t - \hat{y}_t}{y_t} \right|}{N} \times 100\% \tag{5}$$

dengan y_t sebagai nilai aktual dan \hat{y}_t sebagai nilai prediksi. MAPE dipilih dalam penelitian ini karena dianggap lebih mudah dipahami, mengingat hasilnya disajikan dalam bentuk persentase dari total keseluruhan data (Fitri, 2017). Adapun interpretasi tingkat akurasi berdasarkan nilai MAPE dapat dilihat pada Tabel 1 berikut, sebagaimana dikemukakan oleh Lewis (1982).

Tabel 1. Interpretasi Nilai MAPE

MAPE (%)	Interpretasi
< 10	Prediksi sangat baik
10 – 20	Prediksi baik
20 – 50	Prediksi layak
>50	Prediksi tidak layak

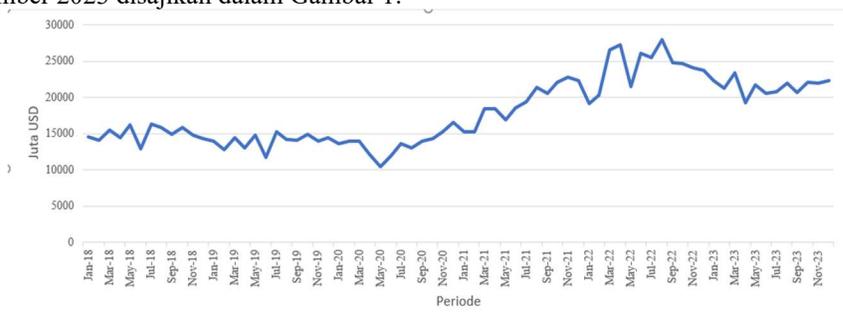
9. Implementasi Final

Seluruh prosedur di atas diaplikasikan untuk meramalkan total nilai ekspor migas dan nonmigas Indonesia, dengan memvalidasi hasil ramalan terhadap data uji periode November 2022–Desember 2023.

III. HASIL DAN PEMBAHASAN

A. Identifikasi Pola Data

Sebelum menerapkan metode *Singular Spectrum Analysis* (SSA), dilakukan terlebih dahulu identifikasi terhadap kecenderungan pola pada data. Langkah ini penting untuk memperoleh gambaran awal mengenai struktur data, sehingga proses analisis selanjutnya dapat dilakukan secara lebih tepat dan terarah. Grafik total ekspor Indonesia dari Januari 2018 hingga Desember 2023 disajikan dalam Gambar 1.



Gambar 1. Total Ekspor Indonesia 2018-2023

Berdasarkan Gambar 1 terlihat bahwa data bersifat fluktuatif dengan kecenderungan pola tertentu. Pada awal periode hingga awal tahun 2020, nilai ekspor menunjukkan pergerakan yang relatif stabil dengan sedikit penurunan. Pada pertengahan tahun 2020, terjadi tren peningkatan yang signifikan hingga mencapai puncaknya pada pertengahan tahun 2022. Setelah itu, nilai ekspor mengalami penurunan secara bertahap dan mulai menunjukkan pola stabil di kisaran 20.000 juta USD sepanjang tahun 2023. Pola ini mengindikasikan adanya kombinasi antara tren naik, fluktuasi musiman, dan fase stabilisasi pada data ekspor Indonesia.

B. Singular Spectrum Analysis (SSA)

1. Dekomposisi

a. *Embedding*

Langkah awal dalam tahap *embedding* dilakukan dengan menetapkan nilai *window length* (L). Berdasarkan hasil eksplorasi melalui metode *trial and error*, ditemukan bahwa nilai L yang memberikan nilai MAPE terendah adalah 28. Selanjutnya, nilai K dihitung menggunakan Persamaan (1) dan diperoleh sebesar 31. Dengan demikian, matriks

trajectory yang dihasilkan berukuran 28×31 . Hasil dari pembentukan matriks *trajectory* berdasarkan parameter yang telah ditentukan dapat dilihat pada tampilan berikut.

$$X_{28 \times 31} = \begin{bmatrix} 14576,3 & 14132,4 & \dots & 13689,9 \\ 14132,4 & 15510,6 & \dots & 13055,28 \\ 15510,6 & 14496,2 & \dots & 13956,18 \\ \vdots & \vdots & \ddots & \vdots \\ 12159,09 & 10452,63 & \dots & 24726,29 \end{bmatrix}$$

b. *Singular Value Decomposition (SVD)*

Pada tahap ini, dilakukan proses perhitungan untuk memperoleh nilai *eigen triple* dari matriks *trajectory* $X_{(28 \times 31)}$. Langkah pertama yang ditempuh adalah membentuk matriks simetris $S = XX^T$, yang diperoleh dari hasil perkalian antara matriks $X_{(28 \times 31)}$ dengan transposenya $X^T_{(31 \times 28)}$. Hasil dari perkalian tersebut menghasilkan matriks simetris berukuran (28×28) , yang selanjutnya digunakan dalam perhitungan nilai-nilai *eigen triple*.

$$S = \begin{bmatrix} 6233760135 & 6174325774 & 6180933065 & \dots & 8322016386 \\ 6174325774 & 6191731949 & 6150529509 & \dots & 8283229334 \\ 6180933065 & 6150529509 & 6186782180 & \dots & 8291931829 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 8322016386 & 8283229334 & 8291931829 & \dots & 12247109592 \end{bmatrix}$$

Untuk memperoleh *singular value* ($\sqrt{\lambda_i}$), tahap awal yang dilakukan adalah menentukan nilai *eigen* terlebih dahulu. Setelah itu, dilakukan penghitungan akar kuadrat dari masing-masing nilai *eigen* yang telah diperoleh. Hasil dari proses ini berupa *singular value*, yang kemudian disajikan dalam Tabel 2.

Tabel 2. Nilai *eigen* dan *Singular value*

<i>i</i>	<i>Eigenvalues</i>	<i>Singular values</i>
1	2. 18e+11	467214.917
2	2. 49e+09	49866.680
3	3. 30e+08	18174.233
⋮	⋮	⋮
28	2. 94e+06	1715.894

Setelah memperoleh nilai *eigen*, langkah selanjutnya adalah menghitung *eigenvector* (U_i). Vektor ini berperan penting dalam mengelompokkan data berdasarkan kemiripan karakteristik antar elemen. Nilai vektor *eigen* hasil perhitungan ditampilkan dalam Tabel 3.

Tabel 3. *Eigenvector*

<i>i</i>	U_1	U_2	...	U_{28}
1	-0.1656532	-0.27294858	...	-0.0455722565
2	-0.1650749	-0.27506356	...	0.0543608106
3	-0.1651201	-0.27552144	...	0.0309444249
⋮	⋮	⋮	⋮	⋮
28	-0.2341374	0.25209569	...	0.2177859836

Berikutnya, *principal component* (V_i) dihitung dengan menggunakan *singular value* dan *eigenvector* yang telah diperoleh sebelumnya, sesuai dengan Persamaan (2). Hasil dari perhitungan ini disajikan pada Tabel 4.

Tabel 4. *Principal Component*

<i>i</i>	V_1	V_2	...	V_{28}
1	-0.1606520	-0.2258048	...	-0.005771642
2	-0.1586667	-0.2428720	...	-0.139049148
3	-0.1576587	-0.2560071	...	-0.254772822
⋮	⋮	⋮	⋮	⋮

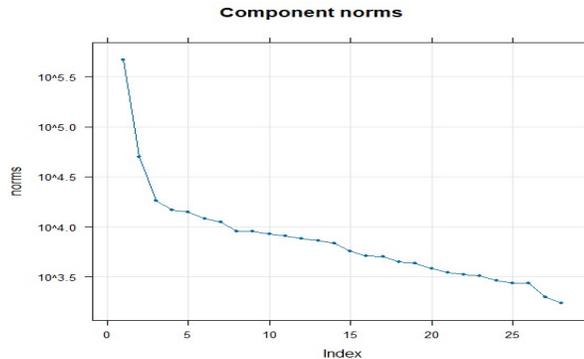
31	-0.2311139	0.19257096	...	0.069916270
----	------------	------------	-----	-------------

Secara keseluruhan, hasil dari proses SVD ini digunakan untuk mengidentifikasi masing-masing komponen, yang kemudian menjadi dasar dalam tahap selanjutnya, yaitu proses *grouping*.

2. Rekonstruksi

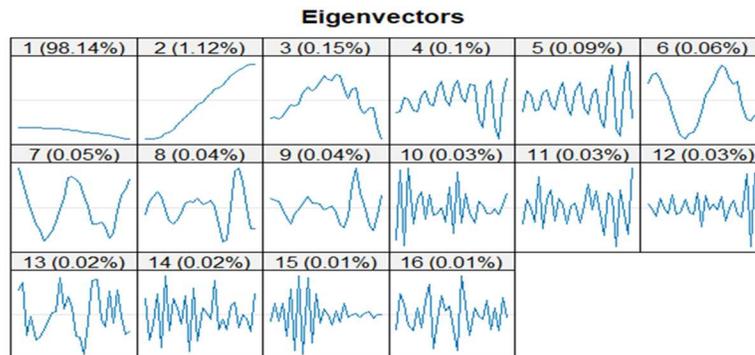
a. *Grouping*

Pada tahap ini, nilai *eigen triple* yang diperoleh dari proses *diagonal averaging* pada tahap SVD dikelompokkan berdasarkan kemiripan karakteristik masing-masing komponen. Proses pengelompokan dilakukan secara eksploratif melalui pendekatan *trial and error* dengan bantuan visualisasi grafik eigenvektor.



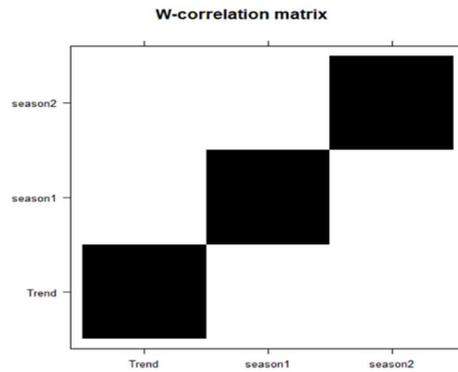
Gambar 2. Plot *Singular Values*

Seperti ditunjukkan pada Gambar 2, nilai singular secara perlahan menurun mulai dari komponen singular ke-10 hingga ke-23. Penurunan nilai singular yang berlangsung secara lambat mengindikasikan bahwa komponen tersebut kemungkinan merupakan elemen *noise*. Namun, untuk menentukan klasifikasi secara lebih spesifik, perlu dilakukan analisis melalui grafik eigenvektor. Komponen dengan pola karakteristik yang serupa dapat dikelompokkan ke dalam satu kategori.



Gambar 3. Grafik *Eigenvektor*

Mengacu pada Gambar 3, dengan penggunaan *window length* sebesar 28, diperoleh hasil pengelompokan optimal dengan jumlah grup $m = 3$. Artinya, nilai-nilai *eigen triple* terbagi ke dalam tiga kelompok utama. Kelompok pertama merupakan komponen tren yang terdiri atas eigenvektor ke-1. Kelompok kedua mencerminkan pola musiman pertama (*seasonal 1*) yang mencakup eigenvektor ke-2, ke-3, ke-4, dan ke-5. Sementara itu, kelompok ketiga mengacu pada pola musiman kedua (*seasonal 2*), yang terdiri dari eigenvektor ke-11 dan ke-12. Adapun komponen lainnya dikategorikan sebagai *noise*.



Gambar 4. W-Correlation

Gambar 4 menyajikan grafik w-korelasi yang berfungsi untuk mengevaluasi sejauh mana pemisahan antar kelompok terjadi. Kriteria pengelompokan yang baik ditunjukkan oleh tidak adanya korelasi kuat antara kelompok-kelompok yang terbentuk, yang dapat diamati melalui gradasi warna yang berbeda antar kelompok. Berdasarkan visualisasi pada Gambar 4, dapat disimpulkan bahwa tidak terdapat korelasi antara kelompok tren dengan musiman, demikian pula antara kelompok musiman pertama dan musiman kedua.

b. *Diagonal Averaging*

Pada tahap ini, dilakukan rekonstruksi terhadap masing-masing kelompok yang telah diperoleh dari proses pengelompokan sebelumnya. Rekonstruksi dilakukan menggunakan metode *Diagonal Averaging* sebagaimana dijelaskan dalam Persamaan (3), yakni dengan menghitung rata-rata elemen pada arah diagonal dari setiap hasil rekonstruksi kelompok. Output dari proses ini ditampilkan dalam Tabel 5.

Tabel 5. Hasil *Diagonal Averaging*

No	Data	Hasil Rekontruksi			<i>Diagonal averaging</i>
		<i>Trend</i>	<i>Seasonal 1</i>	<i>Seasonal 2</i>	
1	14576.3	12433.77	2555.64	-35.2187	14954.20
2	14132.4	12335.24	2703.82	211.2010	15250.27
3	15510.6	12277.70	2895.89	-163.2465	15010.35
⋮	⋮	⋮	⋮	⋮	⋮
58	24726.29	25282,12	-1106.26	-624.2321	23551.62

Hasil Rekonstruksi terdiri dari tiga komponen, Trend, Seasonal 1, dan Seasonal 2. Komponen Trend merepresentasikan pola jangka panjang dari data, yang mencerminkan arah umum pergerakan nilai ekspor. Sementara itu, Seasonal 1 dan Seasonal 2 menggambarkan fluktuasi musiman yang terjadi secara periodik, di mana Seasonal 1 biasanya menunjukkan pola dominan, dan Seasonal 2 mengindikasikan fluktuasi tambahan yang lebih halus atau tidak terlalu konsisten. Nilai-nilai ini kemudian dijumlahkan untuk menghasilkan kolom *Diagonal Averaging*, yaitu hasil rekonstruksi akhir dari data yang diperoleh dengan menjumlahkan semua komponen rekonstruksi (Trend + Seasonal 1 + Seasonal 2). Kolom ini menjadi hasil prediksi dari SSA yang kemudian dibandingkan dengan data asli guna menilai akurasi model. Misalnya, pada baris pertama, komponen Trend sebesar 12.433,77 ditambah dengan Seasonal 1 sebesar 2.555,64 dan Seasonal 2 sebesar -35,22 menghasilkan nilai rekonstruksi akhir sebesar 14.954,20 yang sangat mendekati data asli sebesar 14.576,3. Setelah proses rekonstruksi selesai, tahap berikutnya adalah melakukan peramalan menggunakan data yang dihasilkan dari *Diagonal Averaging*. Proses ini menghasilkan deret waktu baru dengan observasi sebanyak $N = 58$.

3. *R-Forecasting*

Proses peramalan pada metode SSA dilakukan dengan memanfaatkan koefisien dari *linear recurrent formula* (LRF). Nilai koefisien LRF tersebut diperoleh melalui perhitungan menggunakan Persamaan (4), dan hasilnya disajikan pada Tabel 6.

Tabel 6. Koefisien LRF

Koefisien	Nilai
α_1	0.9813
α_2	0.9925
\vdots	\vdots
α_{27}	0.9999

Hasil dari koefisien LRF dapat dilihat sudah cukup baik karna memiliki nilai 0.9813, dimana nilai sudah mendekati satu artinya dengan eigen vektor pertama aja sudah bisa menjelaskan sebagian besar perilaku data. Koefisien LRF yang telah diperoleh kemudian digunakan untuk melakukan proses peramalan terhadap data uji. Hasil dari peramalan tersebut ditampilkan dalam Tabel 7.

Tabel 7. Hasil Peramalan Data Uji

Periode	Data Asli	Data Hasil Prediksi
Januari 2023	22323,84	27212,35
Februari 2023	21321,28	26689,02
Maret 2023	23415,99	21350,54
April 2023	19284,08	21550,01
Mei 2023	21706,83	25401,75
Juni 2023	20601,31	26595,36
Juli 2023	20862,23	21772,06
Agustus 2023	21997,98	19040,77
September 2023	20746,71	26110,64
Oktober 2023	22146,71	29350,24
November 2023	21998,25	21285,23
Desember 2023	22392,15	20235,73

Tabel 7. Menyajikan hasil perbandingan antara data asli dan hasil prediksi dari data uji pada periode Januari hingga Desember 2023. Tabel ini digunakan untuk mengevaluasi kinerja model SSA dalam meramalkan nilai ekspor berdasarkan data yang tidak digunakan dalam proses data uji, yang mana pada kolom Periode menjelaskan data asli sedangkan data hasil prediksi merupakan hasil peramalan yang dihasilkan oleh model SSA.

C. Akurasi Peramalan

Dalam penelitian ini, nilai MAPE dihitung menggunakan persamaan (4), dan diperoleh hasil sebesar 16,63%. Berdasarkan ketentuan yang terdapat dalam Tabel 1, dapat disimpulkan bahwa penggunaan nilai parameter $L=28$ pada metode *Singular Spectrum Analysis* (SSA) memberikan performa peramalan yang baik terhadap total nilai ekspor Indonesia. Berikut merupakan hasil peramalan total nilai ekspor Indonesia untuk periode Januari – Desember 2024 yang disajikan dalam Tabel 8.

Tabel 8. Hasil Peramalan Total Nilai Ekspor Indonesia Tahun 2024

Periode	Data Hasil Peramalan
Januari 2024	21689,14
Februari 2024	23968,39
Maret 2024	26688,50
April 2024	28610,65
Mei 2024	27548,91
Juni 2024	29495,60
Juli 2024	33536,19
Agustus 2024	34543,54
September 2024	34398,79
Oktober 2024	35209,11
November 2024	39502,93
Desember 2024	39578,67

Pada Tabel 8, diperlihatkan bahwa hasil peramalan menunjukkan bahwa nilai total ekspor Indonesia selama tahun 2024 cenderung mengalami peningkatan. Dimulai dari 21.689,14 juta USD pada Januari, nilai ekspor naik secara bertahap dengan beberapa fluktuasi kecil di pertengahan tahun, dan mencapai puncaknya pada Desember 2024 sebesar 39.578,67 juta USD.

IV. KESIMPULAN

Hasil penelitian menunjukkan bahwa metode SSA dengan nilai $L=28$ mampu memberikan hasil peramalan yang baik, dengan nilai MAPE sebesar 16,63%. Berdasarkan hasil peramalan, nilai ekspor tertinggi diperkirakan terjadi pada bulan Desember sebesar 39.578,67 juta USD, sedangkan nilai terendah terjadi pada bulan Januari sebesar 21.689,14 juta USD. Hal ini menunjukkan bahwa SSA efektif digunakan untuk meramalkan data ekspor. Untuk penelitian selanjutnya, disarankan untuk membandingkan SSA dengan metode lain dan mempertimbangkan faktor-faktor eksternal yang dapat memengaruhi nilai ekspor, agar hasil peramalan lebih akurat dan mendalam.

DAFTAR PUSTAKA

- Badan Pusat Statistik (BPS). (2022). *Laporan ekspor Indonesia April 2022*. Jakarta: Badan Pusat Statistik.
- Fitri, F., Rahmat, R., & Pengestuti, A. D. (2020, May). Forecasting of rainfall in Sumatera Barat: singular spectrum analysis (SSA) application. In *Journal of Physics: Conference Series* (Vol. 1554, No. 1, p.012047). IOP Publishing.
- Golyandina, N., & Zhigljavsky, S. A. (2013). *Singular Spectrum Analysis for Time Series*. Springer Heidelberg New York Dordrecht London.
- Hassani, H., Mahmoudvand, R. (2018). *Singular Spectrum Analysis Using R*. Palgrave Macmillan, doi: 10.1057/978-1-137-40951-5
- Isnawati, Salafyah. (2018). "Model Hibrida Singular Spectrum Analysis dan Automatic ARIMA untuk Peramalan Air Terjual di PDAM Giri Tirta Sari Kabupaten Wonogiri Jawa Tengah", Tugas Akhir, 165 Hal., *Institut Teknologi Sepuluh Nopember*, Surabaya, Indonesia, Januari 2018.
- Lewis, C. (1982). *International and Business Forecasting Methods*, Butterworths: London.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction to Time Series Analysis and Forecasting*. Hoboken, NJ: Wiley. Hal 1-67.
- Ruhiat, D., Andiani, D., & Kamilah, W. N. (2020). Forecasting data runtun waktu musiman menggunakan metode singular spectrum analysis (ssa). *Teorema: Teori dan Riset Matematika*, 5(1), 47-60.
- Sulandari, W., Subanar, Lee, M. H., & Rodrigues, P. C. (2020). Indonesian electricity load forecasting using singular spectrum analysis, fuzzy systems and neural networks. *Energy*, 190, 116408.