

Application of Singular Spectrum Analysis (SSA) Method to Forecast Rice Production in West Sumatra

Nazifatul Azizah, Fadhilah Fitri*, Dodi Vionanda, Zamahsary Martha

Departemen, Statistika, Universitas Negeri Padang, Indonesia

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

Submitted : 09 Mei 2023

Revised : 10 Mei 2023

Accepted : 12 Mei 2023

ABSTRACT

The imbalance between the population and rice production will cause various negative impacts such as food crises and increasing poverty, so forecasting needs to be done to maintain food availability in the future. This study aims to determine the results of rice production in West Sumatra Province for 12 periods in 2023 using the SSA method. Based on the results of the analysis, rice production in 2023 for 12 periods tends to decrease compared to the previous year. Forecasting rice production using the SSA method with $L=21$ can be said to be accurate with a MAPE obtained of 17.69%.

Keywords: Rice Production, Forecasting, Singular Spectrum Analysis (SSA).



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

Provinsi Sumatra Barat merupakan salah satu provinsi penghasil produksi padi tertinggi di Indonesia. Berdasarkan data yang dipublikasi oleh Badan Pusat Statistik (BPS) pada tahun 2021 Provinsi Sumatra Barat berada pada peringkat ke-sepuluh dengan total produksi padi mencapai 1,32 juta ton. Namun pada tahun 2022, peringkat produksi padi menurun menjadi peringkat ke-sebelas meskipun produksi padi meningkat menjadi 1,4 juta ton. Penurunan ini disebabkan oleh meningkatnya produksi padi di sepuluh provinsi yang sebelumnya juga termasuk kedalam peringkat produksi padi tertinggi di Indonesia. Oleh karena itu, produksi padi di Provinsi Sumatera Barat masih lebih rendah dibandingkan dengan Provinsi Jawa Timur yang merupakan penghasil produksi padi tertinggi di Indonesia dengan selisih 8,1 juta ton (BPS, 2022).

Selain itu penduduk Provinsi Sumatra Barat dari tahun ke tahun mengalami peningkatan. Makin meningkat jumlah penduduk maka kebutuhan akan padi juga ikut meningkat sedangkan lahan pertanian cenderung tidak bertambah dari tahun ke tahun (BPS, 2022). Hal ini menyebabkan terjadinya ketidakseimbangan antara jumlah penduduk dengan produksi padi. Jika jumlah penduduk lebih besar daripada hasil produksi padi, maka akan mengakibatkan dampak negatif seperti krisis pangan dan meningkatnya angka kemiskinan. Ismail (2019) menyatakan bahwa hingga tahun 2036 masyarakat Indonesia akan terus mengalami permasalahan dalam meningkatnya permintaan dan kebutuhan pangan. Oleh karena itu, diperlukan adanya aktivitas untuk mengetahui lebih awal mengenai produksi padi yaitu dengan melakukan peramalan. Hal tersebut bertujuan untuk mengantisipasi apabila pada periode berikutnya mengalami penurunan sehingga pemerintah dapat mengambil kebijakan yang dipandang mampu untuk menjaga ketersediaan pangan.

Singular Spectrum Analysis (SSA) merupakan metode peramalan yang fleksibel sehingga banyak digunakan. Hal ini dikarenakan SSA menggunakan pendekatan non parametrik dalam analisisnya sehingga terbebas dari pemenuhan asumsi-asumsi. Berbeda dengan metode *Seasonal Autoregressive Integrated Moving Average (SARIMA)* karena metode ini menggunakan pendekatan parametrik di mana dalam prosesnya harus memenuhi beberapa asumsi-asumsi sehingga akan memakan waktu dan akan susah apabila salah satu asumsi tidak terpenuhi. Tujuan dari penelitian ini adalah untuk mengetahui hasil peramalan produksi padi di Provinsi Sumatra Barat periode berikutnya. Beberapa penelitian terdahulu terkait pada permasalahan di atas antara lain, Ruhiat (2020) menerapkan metode SSA dan SARIMA pada data debit Sungai Citarum dan diperoleh kesimpulan bahwa metode SSA cukup andal dibandingkan SARIMA untuk data yang mengandung musiman dengan *Mean Absolute Percentage (MAPE)* SSA dan SARIMA berturut-turut adalah 0,00000457% dan 36,94%. Kemudian Fitri (2017) menerapkan metode SSA pada data produksi perikanan tangkap di Provinsi Jawa Barat dan diperoleh MAPE sebesar 6,19% artinya metode SSA sangat

akurat digunakan untuk peramalan data musiman. Dan Sauddin (2022) menerapkan metode SSA pada peramalan Produksi padi di Kabupaten Pinrang dan diperoleh MAPE sebesar 4,97%.

II. METODE PENELITIAN

Penelitian ini menggunakan data sekunder yang diperoleh dari publikasi Badan Pusat Statistik (BPS). Data sekunder

tersebut merupakan hasil produksi padi di Provinsi Sumatra Barat pada Januari 2018 sampai dengan Desember 2022 sebanyak 60 observasi. Data tersebut dianalisis menggunakan bantuan *software Rstudio*.

Singular Spectrum Analysis (SSA) merupakan salah satu metode analisis data deret waktu yang sering digunakan untuk peramalan. Elsner dan Tsonis (1999) mendefinisikan istilah *singular* sebagai dekomposisi dari matriks lintasan. Sedangkan *spectrum* didefinisikan sebagai jumlah dari himpunan nilai eigen setelah dekomposisi spektral. Metode SSA bertujuan untuk mendekomposisikan data deret waktu asli menjadi suatu penjumlahan dari sejumlah komponen independen seperti trend, musiman dan *noise* (Golyandina, 2018: 4).

SSA terbagi menjadi 2 tahap dasar yaitu tahap dekomposisi dan tahap rekonstruksi. Tahap dekomposisi terbagi dalam dua langkah yaitu langkah *embedding* dan *Singular Value Decomposition* (SVD). Pada tahap rekonstruksi juga terbagi menjadi dua langkah yaitu *grouping* dan *diagonal averaging*. Sebelum melakukan analisis data menggunakan metode SSA, data terlebih dahulu dibagi menjadi dua bagian yaitu data latih dan data uji. Data latih akan digunakan untuk menganalisis data. Sedangkan data uji digunakan untuk mengukur tingkat keakuratan hasil peramalan. Adapun data latih yang digunakan yaitu dari Januari 2018 sampai dengan Desember 2021. Sedangkan data uji dimulai dari Januari 2022 sampai dengan Desember 2022. Adapun langkah-langkah peramalan menggunakan metode SSA sebagai berikut:

1. Dekomposisi

Dekomposisi merupakan tahapan pertama pada SSA di mana pada tahap ini data akan dipecah menjadi beberapa pola, dan diidentifikasi pola-pola tersebut secara terpisah, sehingga menghasilkan peramalan dengan tingkat akurat yang tinggi (Makridakis, 1999:150). Adapun langkah-langkah dekomposisi sebagai berikut.

Embedding

Pada langkah *embedding*, data deret waktu yang mulanya satu dimensi dibentuk menjadi matriks lintasan X berdimensi $L \times K$. L dapat didefinisikan sebagai *window length* yang diperoleh dengan cara *trial and error* (Hassani, 2007). Belum terdapat kriteria khusus dalam menentukan nilai L , namun nilai L terletak pada rentang $2 < L < N/2$. K menunjukkan banyaknya kolom pada matriks yang diperoleh dari $K = N - L + 1$. Matriks lintasan X disebut juga sebagai matriks hankel dimana seluruh elemen diagonalnya bernilai sama dan dinyatakan dalam bentuk berikut (Khaeri, 2017):

$$X = [X_1 : X_2 : \dots : X_K] = (x_{ij}^{L,K}) = \begin{bmatrix} x_1 & x_2 & x_3 & \dots & x_K \\ x_2 & x_3 & x_4 & \dots & x_{K+1} \\ x_3 & x_4 & x_5 & \dots & x_{K+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & x_{L+2} & \dots & x_N \end{bmatrix} \quad (1)$$

Singular Value Decomposition (SVD)

Pada langkah ini akan dicari nilai *eigentriple* dari matriks lintasan X yang telah disusun pada langkah *embedding* dengan membentuk matriks simetris dengan rumus $S = XX^T$. *Eigentriple* terdiri dari nilai singular ($\sqrt{\lambda_i}$), vektor eigen (U_1, \dots, U_L) dan komponen utama V_i untuk $i = 1, 2, \dots, d$ dimana $d = \max\{i\}$ (Wicaksono, 2019). Nilai *singular* diperoleh dari mengakarakan nilai eigen dengan ketentuan $\sqrt{\lambda_i} > 0$. Selanjutnya menghitung komponen utama dengan menggunakan persamaan berikut:

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

Sehingga diperoleh SVD dari matriks lintasan X yaitu:

$$X_i = \sum_{i=1}^d \sqrt{\lambda_i} U_i V_i^T \quad (3)$$

$$X_i = X_1 + X_2 + \dots + X_d$$

2. Rekonstruksi

Pada tahap ini, nilai-nilai yang diperoleh dari hasil tahapan sebelumnya yaitu pada tahap dekomposisi akan direkonstruksi melalui proses *grouping* dan *diagonal averaging* menjadi data deret waktu yang baru (Fitri, 2017). Hasil pada tahapan ini akan mendekati hasil peramalan dengan data aslinya. Adapun langkah rekonstruksi sebagai berikut.

Grouping

Pada langkah *grouping* nilai *eigen triple* yang diperoleh dari tahap dekomposisi akan dikelompokkan berdasarkan karakteristik tertentu yang ada pada setiap komponen seperti kelompok *trend*, musiman dan *noise*. Proses *grouping* dilakukan dengan mempartisi himpunan dari indeks pada $\{1, \dots, d\}$ menjadi m subset $I = I_1, I_2, \dots, I_m$ dimana $m = d$. Lalu matriks X_i disesuaikan dengan himpunan I sehingga Persamaan (3) menjadi sebagai berikut:

$$X = X_{I_1} + \dots + X_{I_m}$$

Menentukan anggota himpunan dari masing-masing kelompok dilakukan secara trial and error berdasarkan plot dari vektor eigen dari X_i . Plot *eigen vector* ini bersifat subjektif. Apabila plot vektor eigen memiliki bentuk yang sama maka dapat diasumsikan bahwa komponen-komponen dari *eigen vector* memiliki karakteristik yang hampir sama.

Diagonal Averaging

Pada langkah ini, hasil pengelompokkan pada langkah *grouping* yang dimisalkan dengan matriks Y akan diubah menjadi data deret waktu yang baru dengan panjang N dengan cara mencari rata-rata diagonal matriksnya dengan menggunakan persamaan berikut (Golyandina, 2013:13).

$$g_K = \begin{cases} \frac{1}{k+1} \sum_{m=1}^{k+1} y_{m,k-m+2}^* & ; 0 \leq k < L^* - 1 \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m,k-m+2}^* & ; L^* - 1 \leq k < K^* \\ \frac{1}{N-k} \sum_{m=k-K^*+2}^{N-K^*+1} y_{m,k-m+2}^* & ; K^* \leq k < N \end{cases} \quad (4)$$

g_K merupakan rata-rata dari elemen matriks di sepanjang diagonal $i + j = K + 2$. Dimana $L^* = \min(L, K)$; $K^* = \max(L, K)$, $N = L + K - 1$.

3. Peramalan

Peramalan pada SSA menggunakan algoritma *R-forecasting* yang berkaitan dengan penaksiran koefisien *Linier Recurrent Formula* (LRF) atau a_j . Koefisien LRF diperoleh berdasarkan nilai vektor eigen pada tahap SVD. Data yang digunakan pada peramalan ini yaitu data yang diperoleh pada langkah *diagonal averaging*. Peramalan SSA menggunakan model persamaan berikut.

$$g_i = \begin{cases} \tilde{g}_i & ; i = 0, \dots, n - 1 \\ \sum_{j=1}^{i-1} a_j \tilde{g}_{i-j} & ; i = n, \dots, n + p - 1 \end{cases} \quad (5)$$

4. Akurasi Peramalan

Salah satu cara untuk mengukur tingkat keakuratan hasil peramalan adalah dengan menggunakan nilai MAPE (Montgomery et al., 2015:67).

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

Y_t merupakan data deret waktu asli dan \hat{Y}_t merupakan data hasil peramalan. MAPE digunakan dalam penelitian ini dikarenakan nilai MAPE dinilai lebih mudah untuk diinterpretasikan yang mana hasilnya merupakan persentase dari keseluruhan (Fitri, 2017). Berikut tabel interpretasi dari nilai MAPE (Lewis, 1982).

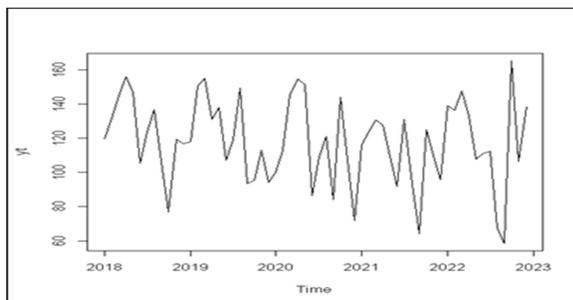
Tabel 1. Interpretasi Nilai MAPE

| MAPE (%) | Interpretasi |
|----------|----------------------|
| <10 | Prediksi sangat baik |
| 10-20 | Prediksi yang baik |
| 20-50 | Prediksi layak |
| >50 | Prediksi tidak layak |

III. HASIL DAN PEMBAHASAN

A. Deskripsi Data

Sebelum melakukan analisis menggunakan metode SSA, terlebih dahulu melakukan identifikasi kecenderungan pola data.



Gambar 1. Pola Data Produksi Padi

Dari Gambar 1 dapat dilihat bahwa data produksi padi di Provinsi Sumatera Barat mengalami kenaikan dan penurunan secara berulang. Setiap awal tahun produksi padi selalu mengalami kenaikan dan mengalami penurunan setiap akhir tahun. Oleh karena itu, data tersebut dapat diidentifikasi berpola musiman sehingga metode SSA cocok diterapkan.

B. Analisis Data Menggunakan Metode SSA

1. Dekomposisi

Embedding

Pada penelitian ini menggunakan data uji sebanyak $N = 48$ observasi sehingga L dipilih dalam rentang $2 < L < 24$. Cara mendapatkan nilai L dapat dilakukan secara *trial and error* dengan melihat nilai MAPE terkecil karena belum ada kriteria khusus dalam menentukannya. Setelah melakukan *trial and error* diperoleh $L = 21$ dengan MAPE paling terkecil dibandingkan L yang lain. Berdasarkan $L = 21$ maka $K = (48 - 21) + 1 = 28$. Sehingga matriks lintasan dapat disusun seperti Persamaan (1) dan diperoleh hasil matriks $X_{21 \times 28}$

$$X_{21 \times 28} = \begin{bmatrix} 119,68 & 131,53 & \cdots & 154,48 \\ 131,53 & 144,71 & \cdots & 151,28 \\ \vdots & \vdots & \ddots & \vdots \\ 93,98 & 95,34 & \cdots & 95,64 \end{bmatrix}$$

Singular Value Decomposition (SVD)

Pada langkah ini akan dicari nilai *eigen triple* dari matriks lintasan X dengan membentuk matriks simetris sehingga didapatkan matriks S dan diperoleh matriks $S_{21 \times 21}$

$$S_{21 \times 21} = \begin{bmatrix} 440097,9 & 436786,9 & \cdots & 385283 \\ 436786,9 & 448660,2 & \cdots & 383775,8 \\ \vdots & \vdots & \ddots & \vdots \\ 385283,1 & 383775,8 & \cdots & 357589,5 \end{bmatrix}$$

Setelah diperoleh matriks S , selanjutnya menghitung nilai *eigen triple* (nilai *eigen* (λ_i), nilai singular ($\sqrt{\lambda_i}$) dan komponen utama (V_i^T) dengan $i = 1, 2, \dots, 21$). Cara mendapatkan nilai singular maka terlebih dahulu mencari nilai *eigen*. Setelah diperoleh nilai *eigen*, kemudian nilai *eigen* tersebut diakar kuadratkan. Hasil dari mengakarkan nilai *eigen* tersebut merupakan nilai *Singular*. Hasil nilai *eigen* dan nilai *singular* disajikan pada Tabel 2.

Tabel 2. Nilai Eigen dan Nilai *Singular*

| <i>i</i> | λ_i | Nilai <i>Singular</i> |
|----------|-------------|-----------------------|
| 1 | 8205885,79 | 2864,59 |
| 2 | 51286,65 | 226,47 |
| 3 | 42790,90 | 206,86 |
| ⋮ | ⋮ | ⋮ |
| 21 | 297,16 | 17,24 |

Selanjutnya, menghitung nilai vektor eigen. Vektor eigen berguna dalam pengelompokan data berdasarkan kemiripan karakteristik. Dari hasil perhitungan diperoleh nilai eigen vektor yang disajikan pada Tabel 3.

Tabel 3. Vektor Eigen

| <i>i</i> | U_1 | U_2 | ... | U_{21} |
|----------|---------|---------|-----|----------|
| 1 | -0,2284 | -0,2425 | ... | -0,0799 |
| 2 | -0,0230 | -0,3599 | ... | -0,0475 |
| 3 | -0,2276 | -0,2764 | ... | 0,0429 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| 21 | -0,2046 | 0,2619 | ... | 0,0070 |

Selanjutnya menghitung komponen utama berdasarkan nilai singular dan vektor eigen yang diperoleh sebelumnya dengan menggunakan Persamaan (2). Hasil perhitungan disajikan pada Tabel 4.

Tabel 4. Komponen Utama

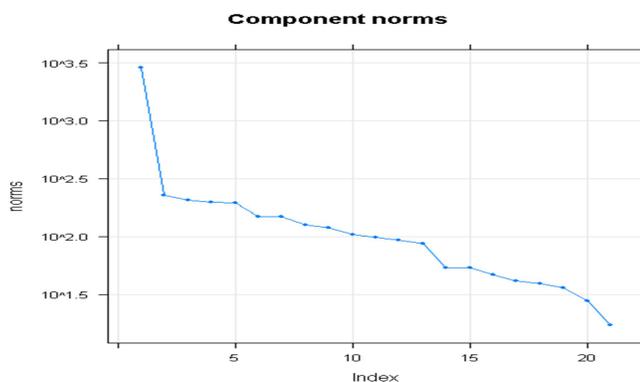
| <i>i</i> | V_1 | V_2 | ... | V_{21} |
|----------|---------|--------|-----|----------|
| 1 | -577,57 | -31,42 | ... | -2,04 |
| 2 | -572,78 | -57,25 | ... | 1,21 |
| 3 | -568,50 | -46,51 | ... | 0,95 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| 28 | -513,40 | -30,12 | ... | 0,94 |

Hasil pada langkah SVD akan berguna pada tahap rekontruksi.

2. Rekontruksi

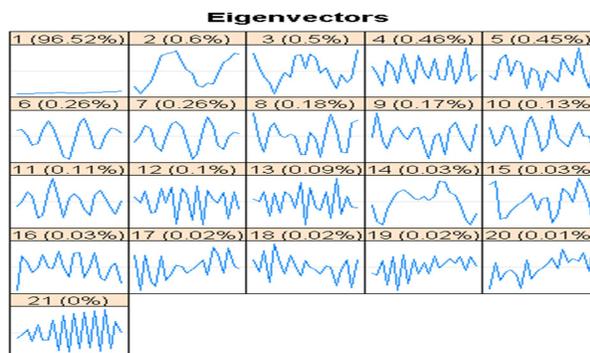
Grouping

Pada langkah ini akan dikelompokkan nilai *eigen triple* yang diperoleh pada langkah *diagonal averaging* pada tahap SVD berdasarkan kemiripan sifat-sifat setiap komponen. Pengelompokan tersebut diperoleh dengan cara *trial and error* dengan memunculkan grafik dari vektor eigen.



Gambar 2. Grafik Nilai *Singular*

Gambar 2 menunjukkan bahwa nilai *singular* secara lambat mengalami penurunan pada *singular* 2 sampai 5. Jika nilai *Singular* mengalami penurunan secara lambat maka dapat dikatakan sebagai unsur *noise*. Namun untuk mengelompokkan secara spesifik dapat dilihat dari menggrafikkan nilai vektor eigen. Nilai vektor eigen yang memiliki kemiripan karakteristik dapat dikelompokkan ke dalam satu kelompok.



Gambar 3. Grafik Vektor Eigen

Berdasarkan Gambar 3 dengan menggunakan *window length* sebesar 21 sehingga diperoleh parameter *grouping* yang optimal yaitu pada $m = 3$. Artinya nilai *eigen triple* tersebut dikelompokkan ke dalam 3 kelompok. Kelompok 1 yaitu *trend* dengan anggota kelompoknya terdiri dari nilai eigen vektor 1, Kelompok 2 yaitu *seasonal 1* dengan anggota kelompoknya terdiri dari nilai eigen vektor 2, 3, 4, 5, dan kelompok 3 yaitu *seasonal 2* dengan anggota kelompoknya terdiri dari nilai vektor eigen 6, 7, 8, 9 serta sisanya merupakan *noise*.

Diagonal Averaging

Pada langkah ini dilakukan rekonstruksi pada setiap kelompok yang diperoleh pada langkah *grouping*. *Diagonal Averaging* dilakukan dengan menggunakan Persamaan (4) yaitu dengan cara menjumlahkan rata-rata hasil rekonstruksi pada setiap kelompok. Hasil rekonstruksi disajikan pada Tabel 5.

Tabel 5. Hasil Rekonstruksi

| No | Data | Hasil Rekonstruksi | | | Diagonal Averaging |
|----|--------|--------------------|------------|------------|--------------------|
| | | Trend | Seasonal 1 | Seasonal 2 | |
| 1 | 119,68 | 131,88 | -11,24 | 7,85 | 128,49 |
| 2 | 131,53 | 131,94 | 10,84 | -11,10 | 131,68 |
| 3 | 144,71 | 131,09 | 15,92 | 1,64 | 148,65 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| 48 | 138,21 | 105,03 | -12,07 | 4,79 | 97,75 |

Selanjutnya melakukan peramalan dari hasil *diagonal averaging*. Hasil dari *diagonal averaging* berupa data deret waktu baru dengan panjang $N = 48$.

3. Peramalan

Terlebih dahulu menghitung koefisien *Linier Recurrent Formula* (LRF) atau a_j . Koefisien LRF yang diperoleh dari hasil perhitungan yang disajikan pada Tabel 6.

Tabel 6. Koefisien LRF

| Koefisien | Nilai |
|-----------|-------|
| a_1 | 0,30 |
| a_2 | 0,08 |
| a_3 | -0,15 |
| ⋮ | ⋮ |
| a_{20} | 0,06 |

Setelah mendapatkan koefisien LRF, selanjutnya melakukan peramalan dengan menggunakan model peramalan pada Persamaan (5) sebagai berikut:

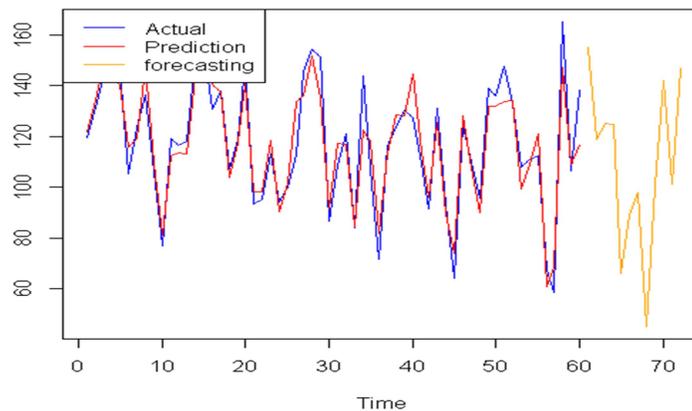
$$g_i = \begin{cases} \tilde{g}_i & ; i = 0,1,2, \dots, 48 \\ \sum_{j=1}^{l-1} a_j \tilde{g}_{i-j} & ; i = 49,50, \dots, 60 \end{cases}$$

Hasil peramalan produksi padi di Provinsi Sumatera Barat 12 periode berikutnya pada tahun 2023 disajikan pada Tabel 7.

Tabel 7. Hasil Peramalan pada Tahun 2023

| Bulan | Data Hasil Peramalan |
|----------------|----------------------|
| Januari 2023 | 154,92 |
| Februari 2023 | 118,74 |
| Maret 2023 | 125,09 |
| April 2023 | 124,81 |
| Mei 2023 | 66,03 |
| Juni 2023 | 89,19 |
| Juli 2023 | 97,84 |
| Agustus 2023 | 45,21 |
| September 2023 | 100,39 |
| Oktober 2023 | 141,89 |
| November 2023 | 101,37 |
| Desember 2023 | 146 |
| MAPE | 17,69% |

Tabel 7 menunjukkan bahwa produksi padi di Provinsi Sumatera Barat pada tahun 2023 cenderung mengalami penurunan dibandingkan pada tahun 2022. Total produksi padi pada tahun 2022 adalah sebesar 1,3 juta ton sedangkan pada tahun 2022 total produksi padi sebesar 1,4 juta ton. Secara visual, perbandingan data hasil peramalan dan data aktual produksi padi di Provinsi Sumatera Barat ditunjukkan pada Gambar 4.



Gambar 4. Perbandingan Hasil Peramalan dengan Data Aktual

Dapat dilihat bahwa plot hasil peramalan memiliki kemiripan dengan plot data aktual atau dengan kata lain pola hasil peramalan mengikuti pola data aktual.

4. Akurasi Peramalan

Akurasi peramalan dapat dihitung menggunakan Persamaan (6) dan interpretasi nilai MAPE dapat dilihat pada Tabel 1. Berdasarkan Tabel 7 diperoleh nilai MAPE hasil peramalan Produksi Padi di Provinsi Sumatera Barat menggunakan $L = 21$ adalah sebesar 17,69%, maknanya metode SSA yang digunakan dalam peramalan adalah akurat sehingga dapat digunakan dalam meramalkan produksi padi pada periode berikutnya.

KESIMPULAN

produksi padi di Provinsi Sumatera Barat 12 periode pada tahun 2023 cenderung mengalami penurunan dibandingkan hasil produksi padi pada tahun 2022. Oleh karena itu, diharapkan dengan menggunakan hasil peramalan ini pemerintah dapat mengambil kebijakan lebih awal mengenai produksi padi di Provinsi Sumatera Barat kedepannya untuk menjaga ketersediaan pangan di masa mendatang. Peramalan produksi padi menggunakan metode SSA dengan $L = 21$ akurat dengan MAPE yang diperoleh sebesar 17,69%. Saran yang dapat diberikan untuk penelitian berikutnya yaitu dengan menambah banyak data dan juga dapat mengaplikasikan metode SSA lainnya seperti SSA *V-forecasting* pada data produksi padi.

DAFTAR PUSTAKA

- Badan Pusat Statistik. (2021). Produk Domestik Bruto (PDB) Lapangan Usaha Pertanian Atas Dasar Harga Berlaku (ADHB). Jakarta:Badan pusat statistik.
- _____ (2022). *Luas Panen dan Produksi Padi di Sumatera Barat 2022*. BPS Provinsi Sumatera Barat.
- Elsner, J. B., & Tsonis, A. A. (1996). *Singular spectrum analysis: a new tool in time series analysis*. Springer Science & Business Media.
- 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), 95-110.
- Golyandina, N., dan Zigljavsky, A. 2013. *Singular Spectrum Analysis For Time Series*, Springer Heidelberg New York Dordrecht London.
- _____ (2018). *Singular spectrum analysis with R*. Springer Berlin Heidelberg.
- Hassani, H. (2007), "Singular Spectrum Analysis: Methodology and Comparison," *Journal od Data Science*, 5, 239-257.
- Ismail, E. (2019). "Sektor Pertanian Pengungkit Pertumbuhan Ekonomi", *Republika.*, Agustus 2019. <https://republika.co.id/berita/pw976t453/sektor-pertanian-pengungkit-pertumbuhan-ekonomi>. (di Akses tanggal 20 Januari 2023).
- Khaeri, H., Yulian, E., & Darmawan, G. (2018). Penerapan Metode SingularSpectrum Analysis (SSA) Pada Peramalan Jumlah Penumpang Kereta Api di Indonesia Tahun 2017. *Euclid*, 5(1), 8-20.
- 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*. John Wiley & Sons.
- Prasekti, Y. H. (2018). Analisa Ekonomi Usaha Penangkar Benih Padi Ciherang (di Kelurahan Tamanan kec. Tulungagung). *JurnalAgribisnis*, 4(2), 1-11.
- 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.
- Sauddin, A., & Kaimuddin, A. (2022). Proyeksi Produksi Padi Kabupaten Pinrang Dengan Metode Singular Spectrum Analysis. *Jurnal MSA (Matematika dan Statistika serta Aplikasinya)*, 10(1), 100-109.
- Wicaksono, A., & Helmi, Y. Prediksi Outflow Uang Kartal di Kalimantan Barat dengan Metode Singular Spectrum Analysis (SSA). *Bimaster: Buletin Ilmiah Matematika, Statistika dan Terapannya*, 8(3).