

Penerapan Metode *Singular Spectrum Analysis* dalam Peramalan Jumlah Produksi Beras di Kabupaten Gowa

Rezki Amalia Idrus¹, Ruliana², Aswi³

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

Keywords: Time Series Analysis, Singular Spectrum Analysis, Rice Production in Gowa Regency

Abstract:

Total rice production in Gowa Regency from January 2018 to December 2020 has decreased which is not significant every month, so it is necessary to do a forecast to anticipate food shortages in the future. This study aims to determine the yield of rice production in Gowa Regency and to model data from October 2021 to September 2022 using the *Singular Spectrum Analysis* (SSA) method. Based on the results of the analysis, the MAPE value obtained is 6.32% so it can be said that forecasting using the SSA method is very accurate.

1. Pendahuluan

Beras merupakan kebutuhan pangan yang selalu dikonsumsi oleh masyarakat Indonesia di setiap harinya. Kegiatan ekonomi di Kabupaten Gowa masih didominasi oleh sektor pertanian. Saat ini pemerintah sedang gencar melaksanakan berbagai program untuk mendukung pencapaian tujuan kedua *Sustainable Development Goals* (SDG's) yaitu mengakhiri kelaparan melalui upaya mencapai ketahanan pangan, meningkatkan gizi, dan mendukung pertanian berkelanjutan. Salah satu data yang sangat penting untuk pengambilan kebijakan di bidang pangan adalah data luas panen dan produksi beras (BPS Provinsi Sulawesi Selatan, 2021). Perkembangan produksi beras di Kabupaten Gowa selama tiga tahun terakhir dari bulan Januari 2018-Desember 2020 mengalami penurunan yang tidak signifikan setiap bulannya yaitu sebesar 78,31 ton per bulan (Putri, 2021).

Analisis *time series* yaitu analisis yang mempelajari korelasi timbal balik antar deret waktu. Dari analisis *time series* dapat diperoleh ukuran-ukuran yang dapat digunakan untuk membuat keputusan pada saat ini, untuk peramalan, dan untuk merencanakan masa depan. Peramalan adalah teknik untuk memperkirakan nilai atau data pada masa yang akan datang dengan memperhatikan data masa lalu maupun data saat ini (Aswi & Sukarna, 2006).

Singular Spectrum Analysis merupakan metode peramalan yang lebih fleksibel dari metode peramalan lainnya karena menggunakan pendekatan nonparametrik yaitu tidak perlu adanya uji-uji asumsi seperti independensi dan normalitas residual dan cocok digunakan untuk data stationer maupun nonstationer. Ukuran model terbaik dilihat berdasarkan *Mean Absolute Percentage Error* (MAPE). Menurut (Zhang dkk., 2015), nilai MAPE yang kurang dari 10% menunjukkan bahwa peramalan sangat akurat. Sedangkan nilai MAPE antara 10% hingga 20% menunjukkan bahwa peramalan baik. Maka dari itu, pada penelitian ini penulis menggunakan metode *Singular Spectrum Analysis* untuk memodelkan dan mengetahui hasil peramalan jumlah produksi beras di Kabupaten Gowa.

* Corresponding author.

E-mail address: rezkiamaliaidrus@gmail.com



2. Tinjauan Pustaka

2.1 Analisis Deret Waktu (Time Series Analysis)

Deret waktu (*time series*) merupakan serangkaian data pengamatan yang terjadi berdasarkan indeks waktu secara berurutan dengan interval waktu tetap. Analisis deret waktu adalah salah satu prosedur statistika yang diterapkan untuk meramalkan struktur probabilistik keadaan yang akan terjadi di masa yang akan datang dalam rangka pengambilan keputusan. Model deret waktu berupaya untuk meramalkan kondisi masa yang akan datang dengan menggunakan data historis dan mengeksploitasi pola tersebut ke masa depan.

Suatu urutan pengamatan memiliki model deret waktu jika memenuhi hal berikut (Aswi & Sukarna, 2006):

1. Interval waktu antar indeks waktu t dapat dinyatakan dalam suatu waktu yang sama (identik).
2. Adanya ketergantungan antara pengamatan Z_t dengan Z_{t+k} yang dipisahkan oleh jarak berupa waktu kelipatan Δ_t sebanyak k kali (dinyatakan sebagai *lag k*).

Analisis deret waktu biasanya memerlukan waktu periode tertentu baik berdasarkan hari, bulan, triwulan, kuartalan, atau tahun. Hal ini dikenal dengan *lead time*. Misalnya, dalam masalah perkiraan penjualan (Z_t), dimana t menunjukkan waktu dalam bulan dan $Z_{t-1}, Z_{t-2}, Z_{t-3}, \dots$, menunjukkan penjualan untuk bulan sebelumnya, nilai-nilai tersebut dapat digunakan untuk memperkirakan penjualan untuk *lead time* $l = 1, 2, \dots, 12$ bulan ke-depan. Nilai ramalan ini dapat dilambangkan dengan $\hat{Z}_t(l)$. Ramalan dibuat pada waktu t dari penjualan Z_t pada waktu mendatang $t + l$. Selain menghitung nilai ramalan, juga diperlukan perkiraan yang akurat sehingga risiko yang terkait dengan keputusan berdasarkan ramalan dapat dihitung (Box dkk., 2008).

2.2 Singular Spectrum Analysis

SSA merupakan metode deret waktu mutakhir dan cukup *powerfull*, terutama untuk menangani deret waktu yang mengandung pola musiman. Broomhead dan King (1986) telah menunjukkan bahwa *Singular Value Decomposition* (SVD) efektif dalam mengurangi error. Pada dasarnya SSA terdiri dari dua tahap, yaitu: *Dekomposisi dan Rekonstruksi*. Algoritma dasar SSA membagi data deret waktu awal ke dalam data deret waktu yang baru yang terdiri dari *trend*, komponen musiman, dan error.

2.3 Dekomposisi

Pada dekomposisi, terdapat dua tahap yaitu *Embedding* dan SVD. *Embedding* adalah tahap dimana data satu dimensi diubah menjadi data multidimensi dan menghasilkan matriks lintasan. Adapun SVD adalah tahap memisahkan komponen-komponen yang memiliki karakteristik berbeda berdasarkan *eigenvalue*.

2.3.1 Embedding

Pada tahap *embedding*, data deret waktu diubah ke dalam bentuk matriks lintasan (*Trajectory Matrix*) yakni mentransformasi data yang berdimensi satu (vektor) menjadi data yang multidimensional (matriks). Misalkan data deret waktu dengan panjang N , tanpa data hilang dinyatakan dengan $X = \{x_1, x_2, \dots, x_N\}$, data di transformasi ke dalam bentuk matriks berukuran $L \times K$. Dengan L merupakan panjang jendela (*windows length*) dimana $2 < L < N/2$. Belum ada metode khusus untuk menentukan nilai L secara pasti, sehingga untuk menentukan nilai L dilakukan dengan proses coba-coba (*trial and error*) dan $K = N - L + 1$. Dalam bentuk matriks dapat ditulis sebagai berikut:

$$X = [X_1, X_2, \dots, X_K] = \begin{bmatrix} x_1 & x_2 & \dots & x_K \\ x_2 & x_3 & \dots & x_{K+1} \\ \vdots & \dots & \ddots & \vdots \\ x_L & x_{L+1} & \dots & x_N \end{bmatrix} \quad (2.1)$$

Matriks X disebut juga matriks lintasan dimana semua elemen anti diagonalnya bernilai sama. Jadi pada tahap ini output yang diperoleh adalah matriks lintasan yang berukuran $L \times K$.

2.3.2 Singular Value Decomposition (SVD)

Langkah kedua dalam dekomposisi adalah membuat *Singular Value Decomposition* (SVD) dari matriks lintasan. Misalkan $\lambda_1, \dots, \lambda_L$ adalah *eigenvalue* dari matriks S dimana $S = XX^T$ dengan urutan menurut $\lambda_1 \geq \dots \geq \lambda_L \geq 0$ dan U_1, \dots, U_L adalah *eigenvector* dari masing-masing *eigenvalue*. Rank dari matriks X dapat ditunjukkan dengan $d = \max\{i, \lambda_i \geq 0\}$. Jika dinotasikan $V_i = \frac{X^T U_i}{\sqrt{\lambda_i}}$ untuk $i = 1, \dots, d$, maka SVD dari matriks lintasan adalah sebagai berikut:

$$\begin{aligned} X &= X_1 + X_2 + \dots + X_d \\ X &= U_1 \sqrt{\lambda_1} V_1^T + U_2 \sqrt{\lambda_2} V_2^T + \dots + U_d \sqrt{\lambda_d} V_d^T \\ X &= \sum_{i=1}^d U_i \sqrt{\lambda_i} V_i^T \end{aligned} \tag{2.2}$$

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

2.4 Rekonstruksi

Pada tahap rekonstruksi menggunakan parameter *grouping effect* (r). *Grouping effect* (r) merupakan parameter kedua dalam SSA yang berperan penting dalam menentukan pola pada plot data. Setelah penggunaan parameter L dalam dekomposisi, pada hasil SVD akan menyajikan serangkaian seri awal yang telah dipisahkan dengan baik (Sakinah, 2012).

2.4.1 Grouping

Pada Langkah ini dilakukan pengelompokan hasil dekomposisi matriks lintasan yang berukuran $L \times K$ dengan tujuan untuk memisahkan komponen aditif SVD ke dalam beberapa sub kelompok, yaitu *trend*, musiman, dan *noise* (Darmawan, 2016).

2.4.2 Diagonal Averaging

Setelah melakukan *grouping*, tahap selanjutnya dilakukan transformasi dari hasil pengelompokan ke dalam deret baru dengan panjang N . Tujuan dari tahap ini adalah mendapatkan *singular value* dari komponen-komponen yang telah dipisahkan, kemudian selanjutnya digunakan untuk peramalan.

2.5 Peramalan Singular Spectrum Analysis

Terdapat dua metode peramalan dalam SSA, yaitu metode rekuren (*R-forecasting*) dan metode vektor (*V-forecasting*). Metode rekuren adalah metode dasar yang sering digunakan karena relatif lebih mudah (Golyandina dkk., 2001). Metode vektor merupakan hasil modifikasi dari metode rekuren. Dalam peramalan SSA, model dibangun dengan bantuan *Linear Rekuren Formula* (LRF) bentuk *polynomial* sebagai berikut (Golyandina dkk., 2001):

$$x_{i+d} = \sum_{k=1}^d r_k x_{i+d-k} \text{ untuk } 1 \leq i \leq N - d \quad (2.3)$$

Perbedaan antara *R-forecasting* dan *V-forecasting* adalah peramalan dengan *R-forecasting* melakukan kontinuitas secara langsung (dengan bantuan LRF), sedangkan peramalan dengan *V-forecasting* berhubungan dengan *L-continuation*. Hal ini menyebabkan dalam *approximate continuation*-nya biasanya memberikan hasil yang berbeda (Golyandina dkk., 2001). Adapun model SSA yang digunakan untuk mendapatkan nilai perkiraan dapat ditulis sebagai berikut (Ete dkk., 2020):

$$\hat{y}_i = \hat{y}_i^T + \hat{y}_i^S, \text{ untuk } i = 0, 1, 2, 3, \dots, n \quad (2.4)$$

Kedua metode peramalan tersebut, memiliki dua tahapan umum yaitu, *diagonal averaging* dan *continuation*. Pada metode *R-forecasting*, *diagonal averaging* digunakan untuk memperoleh rekonstruksi dan *continuation* dilakukan dengan LRF. Sedangkan pada *V-forecasting*, kedua tahap digunakan dalam urutan terbalik, yaitu peramalan vektor dilakukan terlebih dahulu, kemudian *diagonal averaging* memberikan nilai ramalan. Untuk mendapatkan M periode ke depan, metode *V-forecasting* menggunakan prosedur $M + L - 1$ langkah. Tujuannya untuk melihat kesesuaian variasi di bawah M langkah, sehingga metode ini memiliki $L - 1$ langkah tambahan.

2.6 Produksi Beras Kabupaten Gowa

Produksi beras berarti pergantian input produksi dari biji-bijian sampai jadi beras yang dapat dimanfaatkan serta dinikmati oleh konsumen. Pada sektor pertanian khususnya produksi beras diawali dengan menanam benih padi dalam proses produksinya. Kabupaten Gowa sudah memberi kontribusi nyata dalam mempertahankan swasembada beras pada Sulawesi Selatan dan memberi sumbangan bagi surplus beras Sulawesi Selatan 2 juta ton. Berdasarkan hasil surplus produksi beras Kabupaten Gowa tahun 2017, perhitungan surplus beras tingkat nasional dimana produksi (Gabah kering giling) berkisar 335.152 ton menggunakan kebutuhan benih 1.399 ton sedangkan untuk surplus/minus produksi 86.084 ton, untuk tingkat swasembada (tersedia untuk konsumsi-kebutuhan daerah) 191,71%. Produksi tersebut untuk luas lahan tanam 55.977 hektar (ha) (BPS Kabupaten Gowa, 2017).

3. Metode Penelitian

3.1 Jenis Penelitian

Jenis penelitian yang digunakan dalam penelitian ini adalah penelitian kuantitatif dengan mengambil atau mengumpulkan data yang tersedia di instansi/lembaga dan menganalisisnya dengan menggunakan metode SSA untuk meramalkan jumlah produksi beras di Kabupaten Gowa.

3.2 Sumber Data

Data yang digunakan dalam penelitian ini yaitu data Jumlah Produksi Beras di Kabupaten Gowa yang diperoleh dari publikasi Badan Pusat Statistik Provinsi Sulawesi Selatan melalui link <https://sulsel.bps.go.id/> (BPS Provinsi Sulawesi Selatan, 2021).

3.3 Definisi Operasional Peubah

1. Jumlah Produksi Beras di Kabupaten Gowa (x)

Beras adalah hasil olah dari produk pertanian yang disebut padi (*Oryza sativa*). Beras merupakan komoditas pangan yang dijadikan makanan pokok bagi bangsa Asia, khususnya Indonesia, Thailand, Malaysia, Vietnam, Jepang, dan Myanmar. Biji padi terdiri dari dua bagian, yaitu bagian yang dapat dimakan (*rice caryopsis*) dan kulit (*husk*) (Ambarinanti, 2007).

2. Deret waktu produksi beras di Kabupaten Gowa (t)
Jumlah produksi beras di Kabupaten Gowa dari bulan januari 2018 hingga september 2021

3.4 Teknik Analisis Data

1. Menginput data penelitian ke dalam *Software R*
2. Melakukan peramalan dengan metode SSA yang dilakukan dengan dua tahapan yaitu:
 - a. Dekomposisi, tahap ini dibagi menjadi dua langkah yaitu:
 - 1) *Embedding*, pada langkah ini dibentuk matriks lintasan X berukuran $L \times K$ dari data deret waktu dengan pemilihan *Windows Length* (L) dilakukan secara *trial and error* yang memenuhi $2 < L < \frac{N}{2}$ dan $K = N - L + 1$.
 - 2) *Singular Value Decomposition* (SVD). Pada tahap ini, dihitung nilai *eigenvalue* dari matriks simetris $S = XX^T$
 - b. Rekonstruksi, tahap ini dibagi menjadi dua langkah yaitu:
 - 1) *Grouping*, pada tahap ini dilakukan pengelompokan *eigenvalue* berdasarkan karakteristik setiap komponen.
 - 2) *Diagonal Averaging*, pada tahap ini dilakukan rekonstruksi pada masing-masing matriks yang terdapat pada matriks X_1 menjadi data deret waktu yang baru dengan panjang N .
3. Menghitung hasil peramalan dari data deret waktu hasil *Diagonal averaging* dengan metode *R-forecasting*
4. Menghitung akurasi peramalan dengan menggunakan nilai *Mean Absolute Percentage Error* (MAPE).

4. Hasil dan Pembahasan

4.1. Analisis Deskriptif

Tabel 4.1 Analisis Deskripsi Jumlah Produksi Beras di Kabupaten Gowa

Peubah	Rata-rata	Standar Deviasi	Min	Max
Jumlah Produksi Beras	12212,13	7986,12	1298	30516

Dari Tabel 4.1 dapat dilihat bahwa rata-rata jumlah produksi beras dari Januari 2018 sampai September 2021 sebesar 12212 ton dan standar deviasi sebesar 7986 ton. Adapun jumlah produksi beras terendah yaitu 1298 ton di bulan Januari 2020 dan jumlah produksi beras tertinggi sebesar 30516 ton di bulan Agustus 2018.

4.2 Singular Spectrum Analysis

Pada tahap ini terbagi atas tiga langkah yaitu dekomposisi, rekonstruksi, dan peramalan.

4.2.1 Dekomposisi

Pada tahap ini dilakukan dekomposisi data dengan dua langkah yaitu *embedding* dan *singular value decomposition* (SVD) yang dijelaskan sebagai berikut:

4.2.1.1 Embedding

Pada tahap *embedding* menghasilkan matriks lintasan dimana semua elemen anti diagonalnya bernilai sama. Pada penelitian ini jumlah data sebanyak 45 data runtun waktu sehingga nilai L yang digunakan berada direntang $2 < L < 23$ berkisar mulai $L = 3$ hingga $L = 22$. Melalui proses *trial and error* diperoleh $L = 15$ yang merupakan *Mean Absolute Percentage Error* (MAPE) terkecil dibandingkan L lainnya. Berdasarkan nilai $L = 15$ maka dimensi $K = (45 - L) + 1 = 31$. Matriks lintasan dapat disusun sebagai berikut:

$$X_{15 \times 31} = \begin{bmatrix} 24556 & 24843 & \dots & 16072 & \dots & 7813 \\ 7262 & 24556 & \dots & 18402 & \dots & 19738 \\ \vdots & \vdots & \ddots & \vdots & & \vdots \\ 4773 & 4130 & \dots & 24556 & \dots & 13187 \end{bmatrix}$$

4.2.1.2 Singular Value Decomposition (SVD)

Pada tahap ini adalah membuat *singular value decomposition* dari matriks lintasan. Pada proses SVD akan menghasilkan 15 *eigen triple* dimana terdiri dari *eigenvector*, *singular value*, dan *principal component*. Dengan menggunakan persamaan (2.2) maka didapatkan hasil SVD seperti pada Tabel 4.2.

**Tabel 4.2 Eigen triple
Eigenvector**

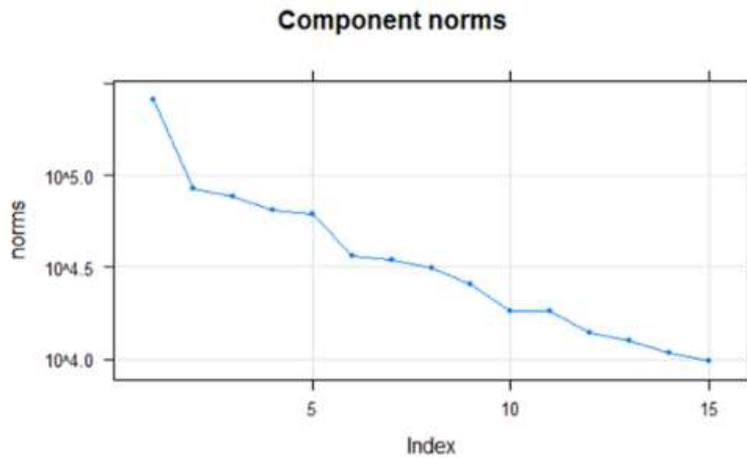
	U_1	U_2	...	U_{15}
1	-0,26971	0,408478	...	-0,01068
2	-0,28807	0,156198	...	-0,115
3	-0,28481	-0,3689	...	-0,03898
\vdots	\vdots	\vdots	\vdots	\vdots
15	-0,27505	-0,32962	...	0,32689
	<i>Singular Value</i>			
i	λ_i		$\sqrt{\lambda_i}$	
1	259608,8		509,5182	
2	84565,23		290,801	
3	76465,99		276,5249	
\vdots	\vdots		\vdots	
15	9739,449		98,68865	
	<i>principal component</i>			
	V_1	V_2	...	V_{15}
1	-0,1851	-0,35252	...	-0,22453
2	-0,21103	-0,19509	...	0,295757
3	-0,21876	0,267191	...	-0,19875
\vdots	\vdots	\vdots	\vdots	\vdots
31	-0,18196	0,242793	...	0,021727

4.2.2 Rekonstruksi

Pada tahap ini dilakukan rekonstruksi data hasil SVD dengan dua langkah yaitu *grouping* dan *diagonal averaging* yang langkah-langkahnya adalah sebagai berikut:

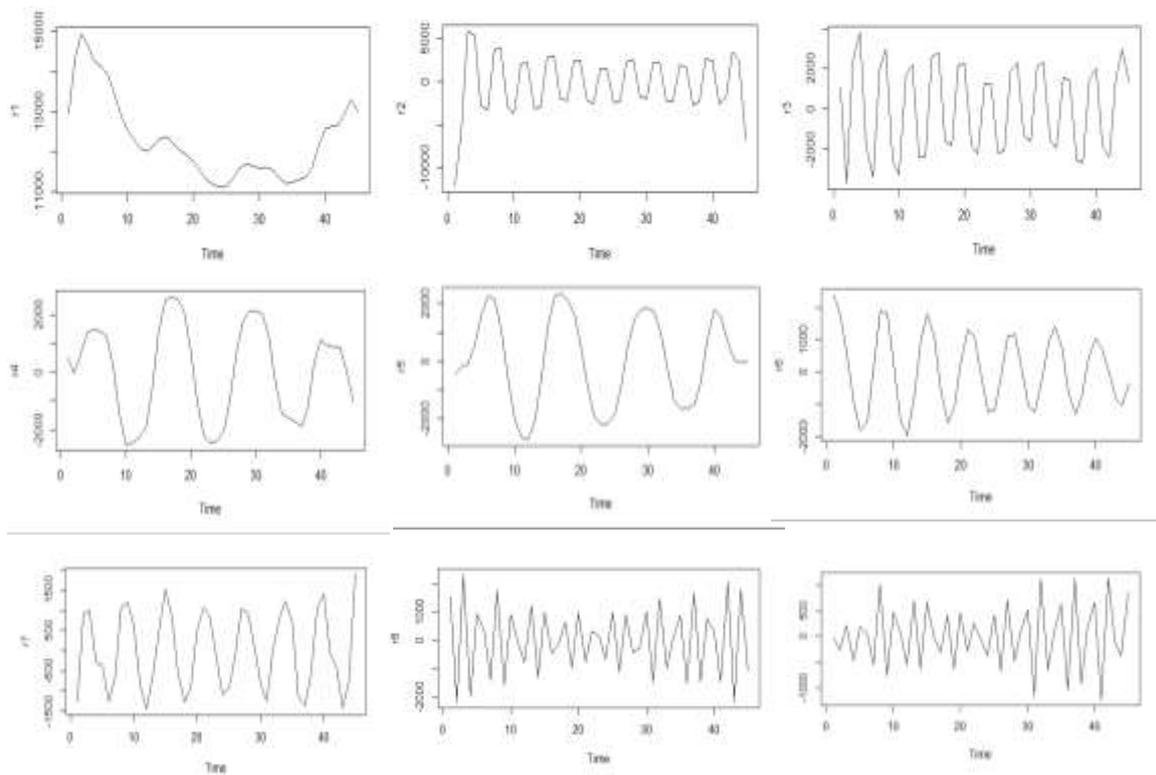
4.2.2.1 Grouping

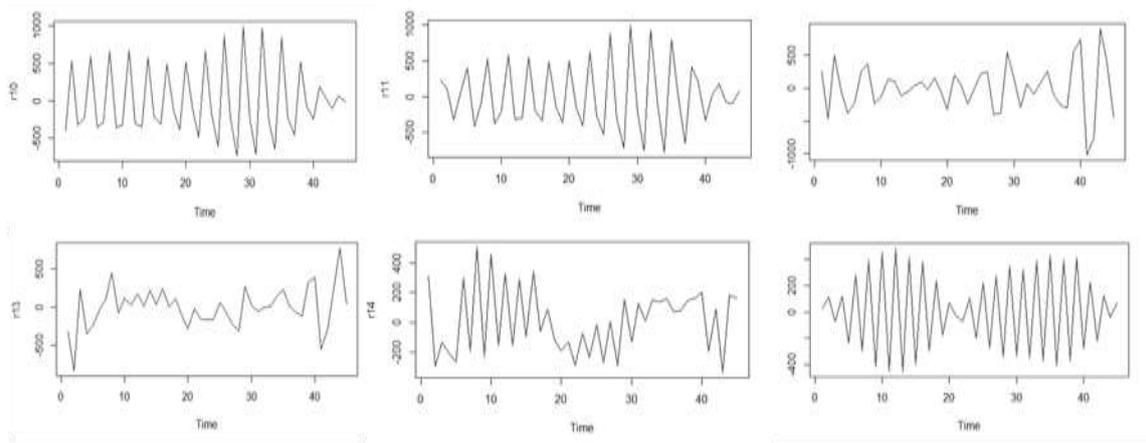
Pada tahap awal *grouping* yaitu melakukan pengelompokan *eigen triple* yang telah diperoleh dari tahap SVD. *Eigen triple* yang memiliki karakteristik hampir sama akan dikelompokkan ke dalam satu kelompok atau komponen. Pengelompokan dilakukan melalui analisis secara grafis, yaitu memunculkan grafik *singular value* dan grafik *eigenvector*.



Gambar 4.2 *Singular Value*

Berdasarkan Gambar 4.2 *singular value* menurun secara lambat pada *singular* 2 sampai 5 yang dimana jika *singular value* menurun secara lambat maka dapat didefinisikan sebagai unsur *noise*, namun untuk melakukan *grouping* dengan lebih spesifik diidentifikasi dengan menggrafikkan *eigenvector* satu persatu. *Eigenvector* yang memiliki karakteristik hampir sama akan dikelompokkan ke dalam satu kelompok atau komponen.





Gambar 4.3 Eigenvector

Adapun kelompok yang dihasilkan ada tiga yaitu *trend*, *seasonal*, dan *noise*. Berdasarkan Gambar 4.3 dapat dilihat *eigenvector* 1 membentuk pola data *trend* yang dimana pola grafik menurun dalam jangka panjang selama periode, *eigenvector* 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, dan 13 membentuk pola data grafik *eigenvector* yang memiliki kemiripan grafik yang bersebelahan dikelompokkan sebagai pola data *seasonal*, dan *eigenvector* lainnya yaitu 14 dan 15 membentuk grafik acak dan tidak memiliki kemiripan dengan lainnya dikelompokkan sebagai pola data *noise*.

4.2.2.2 Diagonal Averaging

Pada tahap ini dilakukan transformasi dari hasil *grouping* ke dalam deret baru. Hasil dari tahap ini merupakan komponen dari data *insampel*. Tujuan dari tahap ini adalah mendapatkan *singular value* dari komponen-komponen yang telah dipisahkan, kemudian digunakan dalam peramalan.

Tabel 4.3 Hasil Diagonal Averaging

Waktu ke-	Rekonstruksi		Diagonal Averaging
	Trend	Seasonal	
1	12961,08	-8521,64	4439,44
2	14309,88	-9995,73	4314,15
3	14928,83	13034,02	27962,85
4	14609,32	6991,63	21600,95
5	14252,67	-2267,17	11985,5
6	14111,53	-6320,88	7790,65
7	13910,21	6598,96	20509,17
8	13452,35	16164,39	29616,74
9	12887,79	-8092,44	4795,35
10	12540,38	-9722,49	2817,89
⋮	⋮	⋮	⋮
45	12992,83	-5410,06	7582,77

Tahap selanjutnya yaitu peramalan dari serangkaian model yang dibentuk melalui pemecahan data deret waktu dengan metode *recurrent* pada SSA.

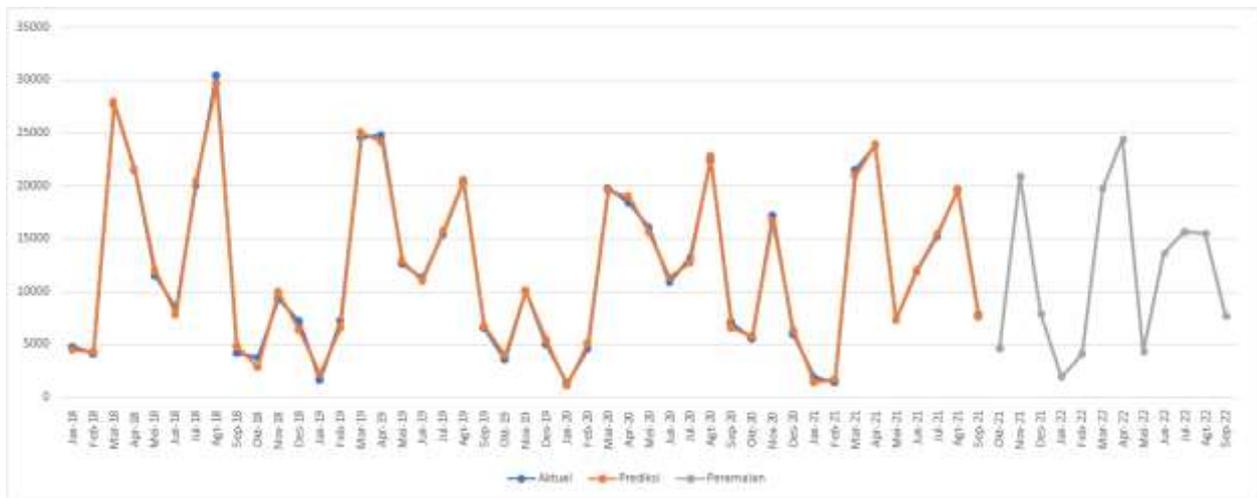
4.2.3 Recurrent Forecasting

Tahap terakhir adalah melakukan peramalan untuk masing-masing komponen dan menjumlahkan hasil peramalan untuk 12 periode selanjutnya yang merupakan *R-Forecasting*.

Tabel 4.4 Hasil Peramalan Jumlah Produksi Beras di Kabupaten Gowa

Bulan	Peramalan		Peramalan Jumlah Produksi Beras di Kabupaten Gowa
	Komponen <i>Trend</i>	Komponen <i>Seasonal</i>	
Okt-21	11932,7	-7327,468	4605,233
Nov-21	11903,8	9039,84	20943,636
Des-21	11882,93	-3993,308	7889,626
Jan-22	11864,92	-9935,793	1929,123
Feb-22	11847,99	-7718,852	4129,141
Mar-22	11842,91	7938,828	19781,736
Apr-22	11858,14	12574,005	24432,147
Mei-22	11886,19	-7577,008	4309,178
Jun-22	11918,37	1725,088	13643,458
Jul-22	11956,35	3719,387	15675,734
Agu-22	11994,1	3519,050	15513,146
Sep-22	12019,02	-4366,536	7652,483

Berdasarkan Tabel 4.4 dapat dilihat bahwa ramalan jumlah produksi beras terbesar terjadi pada bulan April 2022 sebanyak 24432,147 ton dan terjadi penurunan di bulan Januari 2022 yaitu 1929,123 ton.

**Gambar 4.7** Perbandingan data aktual dan data ramalan

Pada Gambar 4.7 memperlihatkan grafik hasil ramalan memiliki kemiripan dengan grafik data faktual. Adapun besaran kesalahan peramalan sebesar 6,32% yang dihitung menggunakan MAPE sehingga dapat dikatakan bahwa untuk melakukan peramalan produksi beras di Kabupaten Gowa, metode SSA memiliki keakuratan model yang sangat baik (Zhang dkk., 2015).

5. Kesimpulan

Peramalan menggunakan metode *Singular Spectrum Analysis* pada data jumlah produksi beras di Kabupaten Gowa menghasilkan kesimpulan yaitu:

1. Jumlah produksi beras di Kabupaten Gowa pada Januari 2018 – September 2021 mengalami peningkatan dan penurunan pada periode-periode tertentu. Dimana rata-rata jumlah produksi beras adalah 12212 Ton dan sebarannya sebesar 7986 Ton. Dari hasil peramalan jumlah produksi beras di Kabupaten Gowa maka dapat disimpulkan bahwa pada bulan Januari 2022 mengalami penurunan yaitu sebesar 1929,123 Ton dan pada bulan April 2022 mengalami peningkatan sebesar 24432,147 Ton.
2. Nilai MAPE yang dihasilkan adalah 6,32%. Dapat dikatakan bahwa untuk melakukan peramalan produksi beras di Kabupaten Gowa, metode *Singular Spectrum Analysis* memiliki keakuratan model yang sangat baik.

References

- Ambarinanti, M. (2007). *Analisis Faktor-Faktor yang Mempengaruhi Produksi dan Ekspor Beras Indonesia*. Program Studi Ekonomi Pertanian dan Sumber Daya. Fakultas Pertanian IPB. Bogor.
- Aswi & Sukarna. (2006). *Analisis deret waktu: teori dan aplikasi*. Andira Publisher.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2008). *Time Series Analysis: Forecasting and Control*. John Wiley & Sons.
- BPS Kabupaten Gowa. (2017). *Kabupaten Gowa dalam Angka 2017*. BPS Kabupaten Gowa.
- BPS Provinsi Sulawesi Selatan. (2021). *Luas panen dan produksi beras di Provinsi Sulawesi Selatan (angka sementara 2021)*. BPS Provinsi Sulawesi Selatan.
- Darmawan, G. (2016). Identifikasi Pola Data Curah Hujan pada Proses Grouping dalam Metode Singular Spectrum Analysis. *Seminar Nasional Pendidikan Matematika*, 1–7.
- Ete, A. A., Suhartono, S., & Atok, R. M. (2020). SSA and ARIMA for Forecasting Number of Foreign Visitor Arrivals to Indonesia. *Inferensi*, 3(1), 55–63. <https://doi.org/10.12962/j27213862.v3i1.6882>
- Golyandina, N., Nekrutkin, V., & Zhigljavsky, A. (2001). *Analysis of Time Series Structure: SSA and Related Techniques*. Chapman & Hall/crc. <https://doi.org/10.1017/cbo9780511608339.006>
- Putri, A. K. (2021). *Analisis Keseimbangan Produksi dan Konsumsi Beras di Kabupaten Gowa*. Universitas Muhammadiyah Makassar.
- Sakinah, A. M. (2012). *Perbandingan Stabilitas Hasil Peramalan Suhu dengan R-Forecasting dan V-Forecasting SSA untuk Long-Horizon*. Universitas Padjajaran. Bandung.
- Zhang, T., Wang, K., & Zhang, X. (2015). Modeling and analyzing the transmission dynamics of HBV epidemic in Xinjiang, China. *PLoS ONE*, 10(9), 1–14. <https://doi.org/10.1371/journal.pone.0138765>