

PERAMALAN INDEKS HARGA PERDAGANGAN BESAR KELOMPOK KOMODITAS PERTANIAN MENGGUNAKAN METODE SINGULAR SPECTRUM ANALYSIS

I Made Praba Esha Suksemawan^{1§}, I Wayan Sumarjaya², I Gusti Ayu Made Srinadi³

¹Program Studi Matematika, Fakultas MIPA – Universitas Udayana[Email: madeesha58@gmail.com]

²Program Studi Matematika, Fakultas MIPA – Universitas Udayana[Email: sumarjaya@unud.ac.id]

³Program Studi Matematika, Fakultas MIPA – Universitas Udayana[Email: srinadi@unud.ac.id]

[§]Corresponding Author

ABSTRACT

The wholesale price index (WPI) is an index used to measure the average price change over time of a package of goods in wholesale trade. This price index is an indicator to view general economic developments and material for market and monetary analysis. Related to WPI as material for market and monetary analysis, forecasting of WPI is very much needed, especially in agricultural commodities, which are a vital sector. The WPI in the agricultural commodity group in this study was forecasted using the singular spectrum analysis (SSA) method. The data used in forecasting is WPI data from January 2005 to December 2022. Forecasting accuracy level is determined by using vector singular spectrum analysis (VSSA) method. Forecasting results show that the best SSA model is obtained with the window length value $L = 12$ and MAPE value is 1,9%. This shows that the SSA method can predict the WPI of agricultural commodities very accurately.

Keywords: wholesale price index, singular spectrum analysis, vector singular spectrum analysis

1. PENDAHULUAN

Pertumbuhan ekonomi Indonesia pada tahun 2020, menurut Badan Pusat Statistik (BPS), tercatat mengalami penurunan sebesar 2,07% jika dibandingkan dengan tahun 2019. Indikator ini menunjukkan bahwa pertumbuhan ekonomi mengalami penurunan. Salah satu alat ukur yang dapat digunakan sebagai deflator Indeks Harga Perdagangan Besar (IHPB) digunakan sebagai parameter dalam mengukur pertumbuhan ekonomi melalui Produk Domestik Bruto (PDB).

IHPB merupakan suatu metode yang dipergunakan untuk menilai perubahan harga rata-rata antar periode tertentu pada beragam jenis barang dalam transaksi grosir. Sebagai salah satu parameter penting, indeks ini memainkan peran dalam evaluasi keseluruhan perkembangan ekonomi, selain berfungsi sebagai alat analisis pasar dan keuangan.

Saat ini terdapat berbagai metode yang berkembang yang digunakan dalam meramal deret waktu. Salah satu metode baru yang digunakan adalah *Singular Spectrum Analysis*, biasa disebut SSA, adalah suatu pendekatan

yang digunakan dalam menganalisis urutan data waktu yang mengintegrasikan konsep-konsep dari analisis Statistik yang melibatkan beberapa variabel, geometri dalam ruang multi-dimensi, perubahan sistem seiring waktu, dan pengolahan sinyal merupakan bidang-bidang yang saling terkait, tujuannya adalah untuk melakukan perubahan menyeluruh memisahkan data awal menjadi beberapa komponen kecil yang independen, memfasilitasi proses interpretasi dengan lebih mudah (Golyandina, 2001).

Beberapa peneliti sebelumnya telah mengadakan studi dengan menerapkan pendekatan Analisis Spektrum Tunggal (SSA). Contohnya, Siregar (2017) yang menginvestigasi proyeksi pertumbuhan ekonomi Indonesia dengan memanfaatkan metode SSA, menghasilkan tingkat kesalahan persentase absolut rata-rata (MAPE) sebesar 0,82%; kemudian, tim peneliti Yundari dkk (2019) menyelidiki peramalan aliran uang tunai di Kalimantan Barat dengan pendekatan SSA, dan mencatatkan nilai MAPE sekitar 18,63%; pada tahun 2019, Sari dkk melakukan kajian

peramalan kunjungan turis asing ke Bali, menggunakan model SSA dengan MAPE sekitar 7,65% dengan panjang jendela ($L = 94$).

Pada penelitian ini, peneliti melakukan penelitian dengan menerapkan pendekatan SSA untuk menyusun model dan memproyeksikan Indeks Harga Perdagangan Besar (IHPB) dari Komoditas Pertanian di Indonesia.

2. METODE PENELITIAN

2.1 Sumber Data dan Jenis Data

Data yang diperoleh untuk penelitian ini merupakan data sekunder yang diperoleh dari situs web Badan Pusat Statistik, berupa data tentang Indeks Harga Perdagangan Besar (IHPB) dalam kelompok Komoditas Pertanian. Data yang dipergunakan mencakup data bulanan dari bulan Januari 2005 hingga Desember 2022. Data ini dibagi menjadi dua kelompok, yaitu data yang digunakan dalam sampel. yang terdiri dari 216 entri mencakup rentang waktu dari Januari 2005 hingga Desember 2021; serta data out-sample yang terdiri dari 12 entri mencakup periode dari Januari 2022 hingga Desember 2022.

2.2 Metode Analisis Data

Dalam penelitian ini, teknik yang digunakan untuk menganalisis data adalah metode SSA dengan dukungan perangkat lunak R Studio. Langkah-langkah prosesnya dapat dijelaskan sebagai berikut:

1. Mempersiapkan data *in-sample* IHPB kelompok komoditi Pertanian periode 2005-2022;
2. Menjalankan *plotting* data guna mengidentifikasi dan mengungkap pola yang terdapat dalam data;
3. Tahap dekomposisi, terdapat dua proses dalam dalam tahapan ini yaitu :

a. *Embedding*

Pada tahap *embedding*, data deret waktu awal akan dikonversi menjadi matriks lintasan. Setelah itu, Data yang awalnya dalam satu dimensi akan diubah menjadi data yang memiliki beberapa dimensi. Matriks lintasan ini merupakan hasil dari proses *embedding* mempunyai dimensi $L \times K$, dimana L merupakan *Window Length* yang pemilihannya dilakukan secara *trial and error* yang memenuhi $2 \leq L \leq \frac{N}{2}$ dimana $N = 204$ dan $K = N - L + 1$.

b. *Singular Value Decomposition (SVD)*

Langkah ini merupakan Langkah penting dalam melakukan dekomposisi pada matriks trajektori \mathbf{X} diuraikan sebagai hasil penjumlahan matriks yang dibentuk dari pasangan eigen. Tiap hasil dari SVD matriks trajektori tersebut. \mathbf{X} ($\mathbf{X}_1, \dots, \mathbf{X}_d$) dapat dinyatakan dengan $\mathbf{X}_i = \sqrt{\lambda_i} U_i V_i^T$. Kemudian kumpulan $\sqrt{\lambda_i} U_i V_i^T$ disebut sebagai *eigentriple* matriks \mathbf{X}_i dari SVD.

4. Tahap rekonstruksi, tahapan yang juga terbagi dalam dua langkah, yaitu:

a. *Grouping*

Pada langkah *grouping*, terdapat proses dimana matriks yang telah didekomposisi dan telah dipartisi akan dikelompokkan, selanjutnya akan dilakukan penjumlahan kelompok matriks yang dinyatakan dengan $\mathbf{X} = \mathbf{X}_{l_1} + \dots + \mathbf{X}_{l_m}$. kemudian dilakukan pengelompokkan komponen tren, musiman, dan *noise* dengan menggunakan plot nilai singular.

b. *Diagonal Averaging*

Pada langkah *diagonal average* akan dibentuk deret baru dengan panjang N menjadi deret yang sesuai dengan masing-masing hasil dari *grouping* komponen tren dan musiman.

5. Membentuk model SSA; dengan melakukan peramalan menggunakan *Vector Singular Spectrum Analysis (VSSA)*.
6. Menghitung nilai *error* peramalan dengan menggunakan nilai MAPE;
7. Melakukan interpretasi terhadap hasil peramalan dan menarik kesimpulan.

3. HASIL DAN PEMBAHASAN

Penulis pada bagian ini akan membahas penerapan metode SSA untuk meramalkan IHPB kelompok komoditi pertanian. Berikut adalah plotting data IHPB pada medio Januari 2005-Desember 2021



Gambar 1. Plot Data IHPB periode Januari 2005 hingga Desember 2021

Gambar 1 menunjukkan bahwa pada data terlihat pola tren naik dari tahun 2005, kemudian pada tahun 2009 pola tren menurun dan mulai naik lagi Di tahun 2010, hal ini menunjukkan bahwa pada data tersebut terdapat kenaikan dan penurunan IHPB. Selain itu juga terlihat data dengan Pola yang berulang menunjukkan adanya keberadaan pola musiman dalam data..

3.1 Dekomposisi

Langkah awal yang dilakukan pada tahap dekomposisi adalah *embedding* atau disebut juga penyematan. Pertama akan ditentukan nilai *window length* (L) secara *trial and error*. Pada kasus ini jumlah data yang digunakan adalah 204 data. Sehingga nilai L yang akan digunakan dicoba berada pada rentang $2 \leq L \leq 102$. Untuk nilai L yang dipilih yang dilakukan secara *trial and error* yaitu $L = 12$ sedangkan nilai $K = 204$. Dengan demikian dieproleh bentuk matriks lintasan X sebagai berikut:

$$X = L \times K = 12 \times 193$$

$$= \begin{bmatrix} 145,60 & 144,35 & \dots & 155,39 \\ 144,35 & 144,65 & \dots & 159,63 \\ \vdots & \vdots & \ddots & \vdots \\ 155,39 & 159,63 & \dots & 151,48 \end{bmatrix}$$

Langkah berikutnya yaitu menjalankan proses singular value decomposition (SVD), yang dilakukan pada tahap ini adalah Dengan melakukan dekomposisi matriks lintasan X menjadi 12 pasangan eigen Mencakup dua belas nilai eigen serta dua belas vektor eigen

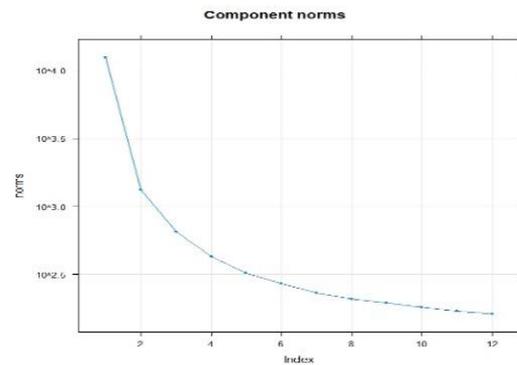
3.2 Rekonstruksi

Pada tahap rekonstruksi ini, penulis melakukan dua fase tahapan yaitu pengelompokan dan diagonal averaging.

3.2.1 Grouping

Tindakan pertama yang dijalankan pada fase rekonstruksi adalah pengelompokan pasangan eigen yang berkaitan dengan unsur tren, musiman, dan kebisingan. Pengaturan yang dimanfaatkan untuk mengontrol jumlah pasangan eigen yang akan dimanfaatkan dalam identifikasi komponen tren dan musiman adalah efek pengelompokan (r).

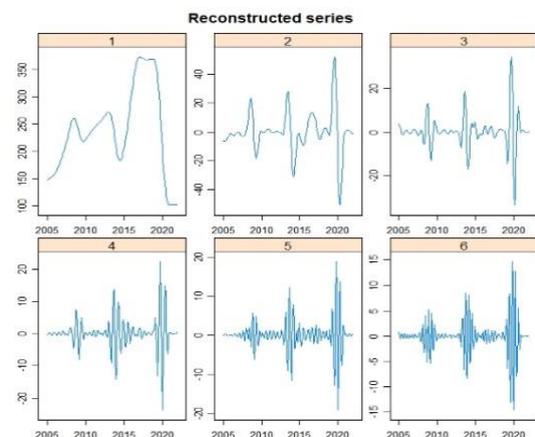
Penentuan nilai r dilakukan dengan memperhatikan jumlah pasangan eigen yang tidak mencerminkan *noise* pada grafik nilai singular r .



Gambar 2. Plot Nilai Singular

Grafik yang memvisualisasikan nilai Singular dari 12 pasangan eigen terpampang dalam Gambar 2. Gambar tersebut menunjukkan bahwa terjadi penurunan perlahan dalam nilai singular seiring dengan nomor pasangan eigen 6. Dari hal tersebut akan menjelaskan bahwa *eigen triple* 6 hingga *eigen triple* 12 dapat diidentifikasi sebagai unsur kebisingan, maka nilai parameter r adalah 6. Dengan begitu, jumlah pasangan eigen enam pasang eigen akan digunakan untuk memisahkan unsur tren dan musiman. Jika dilihat pada plot nilai Singular pada gambar 2, maka terdapat kemungkinan adanya *eigen triple* yang mencerminkan komponen *noise* dari enam *eigen triple* tersebut. Hal ini nampak jelas pada gambar plot tersebut yang *eigen triple* yang masih ada tidak menunjukkan adanya komponen tren maupun musiman..

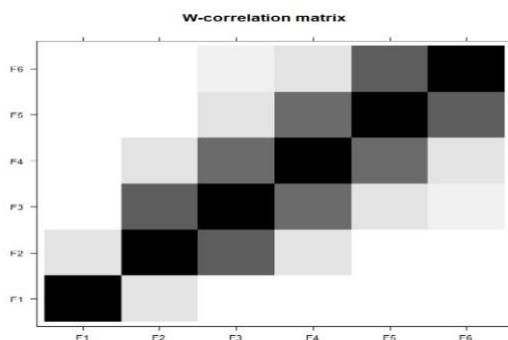
Ada enam pasangan eigen yang akan dipakai untuk mengenali unsur tren dan musiman. Keenam pasangan eigen ini merupakan yang terpilih untuk mengenali unsur tren dan musiman. 1,2, ...,6.



Gambar 3. Plot deret yang direkonstruksi

Diagram pada Gambar 3 mengindikasikan bahwa deret yang direkonstruksi menggunakan pasangan eigen pertama menunjukkan variasi yang berkembang secara perlahan, maka pasangan eigen pertama bisa dianggap sebagai bagian dari unsur tren. Kemudian, pengelompokkan pasangan eigen yang terkait dengan unsur musiman dilakukan dengan mempertimbangkan kesamaan nilai singular dari pasangan eigen berturut-turut. Di dalam plot deret ini, kita bisa mengidentifikasi kesamaan nilai singular, yang menyebabkan urutan deret yang direkonstruksi melalui satu pasangan eigen menunjukkan pola dan durasi yang mirip dengan urutan yang dipulihkan melalui pasangan eigen yang lain..

Apabila diperhatikan pada Gambar 3, terdapat pola yang serupa pada beberapa pasang eigen berturut-turut, yaitu pasangan eigen kedua dan ketiga, pasangan eigen ketiga dan keempat, pasangan eigen keempat dan kelima, serta pasangan eigen kelima dan keenam. Penulis juga menerapkan metode ESPRIT sehingga mendapatkan deret yang direkonstruksi oleh pasangan eigen ketiga dan keempat dengan Periode musiman yang sama, selama dua belas bulan, menjadi komponen dari unsur musiman. Setelahnya, rangkaian yang dipulihkan oleh pasangan eigen kelima dan keenam menunjukkan siklus musiman yang hampir serupa, yaitu selama lima bulan. Walaupun begitu terdapat perbedaan; meskipun deret yang direkonstruksi oleh pasangan eigen kelima dan keenam walaupun keduanya memiliki pola musiman yang serupa, namun keduanya tidak termasuk dalam kategori ini karena perbedaan periode musiman antara kedua rangkaian data, sehingga tidak dapat dimasukkan sebagai data bulanan.



Gambar 4. Plot keterpisahan (W-correlation)

Selain menilai struktur yang direkonstruksi, langkah identifikasi eigentriple yang mencerminkan pola tren dan musiman juga bisa dilakukan dan diamati melalui diagram pemisahan (w-korelasi). Diagram pemisahan (w-korelasi) yang dimaksudkan dipakai untuk menaksir tingkat korelasi antar eigentriple. Hal ini nampak dengan jelas dalam Gambar 4, di mana semakin tua warna pada diagram pemisahan (w-korelasi) dari keenam eigentriple, semakin tinggi pula tingkat korelasinya.

Apabila diperhatikan pada Gambar 4, terlihat bahwa keterhubungan antara pasangan eigentriple 2 dan 3, eigentriple 3 dan 4, eigentriple 4 dan 5, serta eigentriple 5 dan 6 menunjukkan tingkat signifikansi yang cukup tinggi jika dibandingkan dengan pasangan eigentriple 1 dan 2. Meskipun demikian, untuk mengidentifikasi unsur musiman, hanya mengevaluasi plot tersebut tidaklah cukup. Oleh karena itu, penggunaan agar dapat menentukan periode musiman dari rangkaian yang direkonstruksi oleh dua pasang eigentriple, diperlukan penerapan metode ESPRIT. Data tersebut terdokumentasi dalam Tabel 1. selanjutnya akan memberikan detail lengkap tentang pasangan eigentriple dan periode musiman yang mereka tunjukkan

Tabel 1. *Eigentriple* dan Periode Musimannya

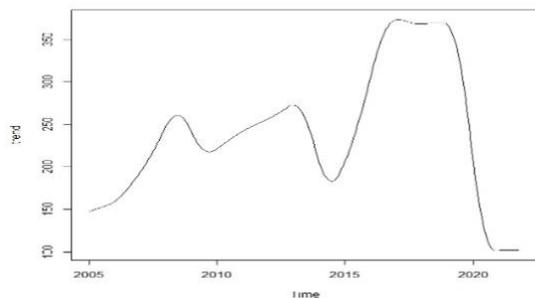
<i>Eigentriple</i>	Periode	<i>Eigentriple</i>	Periode
2	23	4	8
3	23	5	8
3	12	5	5
4	12	6	5

Sumber : data diolah 2023

Tabel 1 menggambarkan pasangan *eigentriple* dan periode musimannya. Dari Tabel tersebut terlihat bahwa Pasangan eigen yang termasuk dalam kategori musiman adalah pasangan eigen 3 dan 4. Oleh karena itu, pasangan eigen yang dapat dinyatakan sebagai komponen musiman adalah pasangan eigen 3 dan 4, sementara pasangan eigen yang tidak termasuk dalam unsur tren dan musiman dianggap sebagai sumber kebisingan..

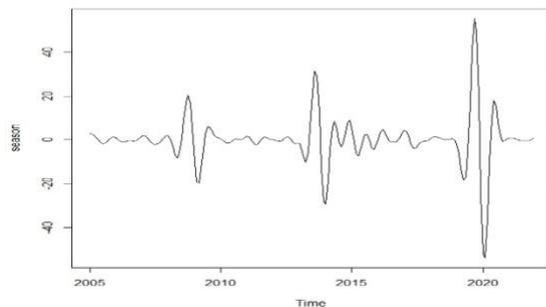
3.2.2 *Diagonal averaging*

Saat melaksanakan proses diagonal averaging, masing-masing komponen dapat Direkonstruksi kembali dengan menggunakan setiap pasangan eigen yang sesuai. hasil dari komponen tren yang telah direkonstruksi dapat dilihat dalam Gambar 5.



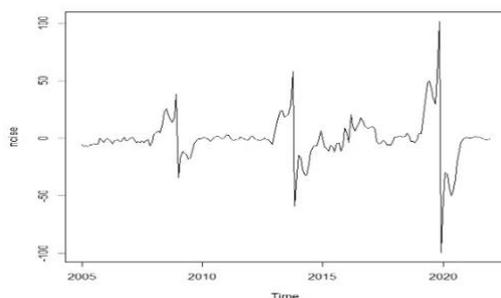
Gambar 5. Komponen Tren Direkonstruksi

Gambar 6 menunjukkan komponen musiman yang direkonstruksi dengan menggunakan pasangan eigen 3 dan 4. Visualisasi dari komponen musiman yang direkonstruksi dapat diamati seperti berikut ini:



Gambar 6. Komponen Musiman Direkonstruksi

Selanjutnya pada Gambar 7 merupakan ilustrasi plot dari hasil komponen *noise* yang sudah direkonstruksi.



Gambar 7. Komponen Noise Direkonstruksi

3.3 Peramalan

Setelah proses rekonstruksi selesai dilakukan, hal ini dapat diindikasikan dari sudah terpisahkannya seluruh komponen pada proses rekonstruksi, maka langkah berikutnya adalah masuk pada tahapan peramalan terhadap komponen tren dan musiman. Proses peramalan disini menggunakan VSSA.

Data *in-sample* yang digunakan adalah sebanyak $N = 204$, sehingga diperoleh peramalan dengan data *out-sample* pada selang $h = 12$ yaitu sebanyak $\tilde{X}_{204}, \dots, \tilde{X}_{216}$. Dari sini kemudian diperoleh rumus *vector* sebagai berikut:

$$Z_i = \begin{cases} \tilde{X}_i, & i = 1, \dots, 204 \\ \theta^{(v)} Z_{i-1}, & i = 205, \dots, 216 \end{cases}$$

Z_1, \dots, Z_{216} adalah representasi dari nilai-nilai deret yang telah direkonstruksi, sedangkan $\theta^{(v)}$ menunjukkan koefisien dari metode VSSA.

Penjelasan tentang model SSA yang digunakan untuk meramalkan komponen tren dapat dijelaskan dengan persamaan SSA sebagai berikut:

$$Z_i^T = 102,22Z_1^T + 102,17Z_2^T + \dots + 101,77Z_{11}^T$$

Adapun model SSA yang digunakan dalam memprediksi komponen musiman dapat dituliskan seperti berikut:

$$Z_i^S = 0,2Z_1^S + 0,2Z_2^S + \dots + 0,2Z_{11}^S$$

Dengan menjumlahkan hasil prediksi data out-sampel dari komponen tren dan hasil prediksi data out-sampel dari komponen musiman, maka kita akan mendapatkan hasil nilai ramalan secara total terhadap data out-sampel secara keseluruhan. Model SSA yang digunakan untuk merumuskan nilai ramalan data *out-sample* secara keseluruhan dapat dijelaskan secara matematis sebagai berikut:

$$Z_i = Z_i^T + Z_i^S, \text{ untuk } i = 194, \dots, 216$$

Setelah memperoleh model SSA yang digunakan untuk peramalan, langkah berikutnya adalah melakukan prediksi pada data *out-sample* dengan menggunakan model yang telah diperoleh. Akurasi hasil prediksi pada data *out-sample* dapat dinilai dengan menggunakan nilai MAPE. Pada tabel 2 disajikan hasil peramalan data *out-sample* dari komponen tren dan musiman dalam rentang dua belas bulan ke depan.

Nilai MAPE yang kurang dari 10% menunjukkan bahwa peramalan sangat akurat. Sedangkan apabila nilai MAPE yang berada pada kisaran 10% hingga 20% mengindikasikan bahwa peramalan baik. Hal ini berdasarkan pada penelitian yang telah dilakukan oleh Zhang dkk, (2015).

Jika dilihat dari Tabel 2, terbaca dengan jelas nilai MAPE pada data *out-sample* sebesar 0,01902908 atau 1,9%. Dari data tersebut dapat ditarik kesimpulan bahwa metode SSA dengan nilai $L = 12$ dapat meramalkan IHPB pada

kelompok komoditi pertanian dengan sangat akurat.

Tabel 2. Hasil Data Ramalan dan Data Aktual

Bulan	Hasil ramalan	Data aktual	Persentase galat
Januari	102,4325	102,97	0,005220
Februari	102,3975	101,80	0,0058694
Maret	102,3054	103,35	0,0101073
April	102,1795	103,68	0,0144722
Mei	102,0469	103,79	0,0167940
Juni	101,9311	105,82	0,0367505
Juli	101,8463	106,44	0,0431576
Agustus	101,7964	103,71	0,0184511
September	101,7757	103,90	0,0204455
Oktober	101,7722	102,62	0,0082612
November	101,7722	103,05	0,0123997
Desember	101,7637	105,61	0,0364196
Nilai MAPE			0,01902908

4. SIMPULAN DAN SARAN

Merujuk pada hasil peramalan dan pembahasan sebelumnya dapat diperoleh model SSA yang dipergunakan untuk melakukan peralaman komponen tren dalam dua belas bulan kedepan adalah seperti berikut ini:

$$Z_i^T = 269,2Z_1^T + 269,5Z_2^T + \dots + 299,5Z_{101}^T$$

Sementara permodelan SSA yang digunakan dalam melakukan peramalan terhadap komponen musiman untuk dua belas bulan ke depan adalah seperti berikut:

$$Z_i^S = 4,5Z_1^S + 4,5Z_2^S + \dots + 2,5Z_{101}^S$$

Permodelan tersebut adalah model SSA terbaik dengan nilai *window length* $L = 12$ serta dengan nilai MAPE sebesar 1,9%. Dari Nilai yang diperoleh tersebut, menunjukkan bahwa metode SSA dapat melakukan peramalan IHPB pada kelompok komoditi pertanian dengan sangat akurat.

Berdasarkan simpulan yang penulis dapatkan pada penelitian ini bahwa proses

pengelompokan pada komponen tren dan komponen musiman menggunakan plot deret yang telah direkonstruksi dan plot keterpisahan (*w-correlation*).

Pada penelitian selanjutnya disarankan dapat kiranya menambahkan komponen lain maupun menggunakan método berbeda sesuai dengan perkembangan dan kebutuhan seperti analisis *periodegram* dan *pairwise scatterplot*.

DAFTAR PUSTAKA

- Ete, A. A., Agus, S., & Suhartono. (2017). *forecasting the amount of foreign tourist travelers to indonesia by entrance guide using singular spectrum analysis and arima forecasting the amount of foreign tourist travelers to indonesia by entrance guide using singular spectrum.*
- Nina Golyandina, Vladimir Nekrutkin, A. A. Z. (2001). *Analysis of Time Series Structure: SSA and Related Techniques.*
- Sari, Mira Ayu Novita, I Wayan Sumarjaya, and Made Susilawati. 2019. "Peramalan Jumlah Kunjungan Wisatawan Mancanegara Ke Bali Menggunakan Metode Singular Spectrum Analysis." *E-Jurnal Matematika*, 8(4), 303.
- Siregar, R. S. K., Prariesa, D., & Darmawan, G. (2017). Aplikasi Metode Singular Spectral Analysis (SSA) dalam Peramalan Pertumbuhan Ekonomi Indonesia Tahun 2017. *Jurnal Matematika "MANTIK,"* 3(1), 5–12.
- Yundari, Ageng Wicaksono, 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.