

Peramalan Inflasi Kota Balikpapan Menggunakan Metode *Singular Spectrum Analysis*

Forecasting Inflation for Balikpapan City Using Singular Spectrum Analysis Method

Andrean Sergio^{1,a)}, Sri Wahyuningsih^{2,b)}, dan Meiliyani Siringoringo^{2,c)}

¹Laboratorium Statistika Ekonomi dan Bisnis, Jurusan Matematika, FMIPA Universitas Mulawarman

²Program Studi Statistika, Jurusan Matematika, FMIPA Universitas Mulawarman

^{a)}Corresponding author: andreanserg@gmail.com

^{b)}swahyuningsih@fmipa.unmul.ac.id

^{c)}meiliyanisiringoringo@fmipa.unmul.ac.id

ABSTRACT

Singular Spectrum Analysis (SSA) is a nonparametric forecasting method capable of separating time series data into interpretable trend, seasonal, cycle, and noise. Methods with component separation are suitable for characterizing economic and business data trends that tend to contain stationary, trend, cycle, and seasonal factors. One of the economic data that can be used in research is inflation. The purpose of this study is to obtain the results of inflation forecast in Balikpapan City from November 2022 to October 2023. Based on the forecasting results of the SSA method on inflation in Balikpapan City, the MAAPE value was 23.53% which showed that the forecasting results were quite accurate. Based on the results of inflation forecast from November 2022 to October 2023, there was a decrease in inflation in November 2022 by -0.64% or it could be said that there would be deflation by 0.64%. Over the next period, inflation tends to increase where the highest inflation will occur in June 2023, which is 1.96%.

Keywords: Forecasting, Inflation, SSA

1. Pendahuluan

Peramalan dapat diartikan sebagai teknik dalam memperkirakan suatu kejadian yang belum terjadi atau akan terjadi di masa mendatang berdasarkan data di masa lampau. Peramalan didasarkan pada data yang telah ada sebelumnya dengan mempertimbangkan pemilihan metode peramalan secara tepat untuk menghasilkan angka ramalan yang valid dan akurat (Dewi & Listiowarni, 2020).

Langkah penting dalam memilih metode peramalan yang tepat adalah dengan mengidentifikasi jenis pola data secara tepat berdasarkan plot runtun waktu, di mana data dipetakan dari waktu ke waktu. Pola data runtun waktu dapat dibedakan menjadi empat jenis yaitu stasioner, musiman, siklus, dan tren (Juliana dkk., 2019). Dalam proses memodelkan data runtun waktu, sering dijumpai suatu data runtun waktu mengandung keempat pola dasar tersebut. Pola tersebut dapat dipisahkan untuk menunjukkan tiap-tiap komponen runtun waktu melalui proses dekomposisi. Tujuan dari pemisahan komponen runtun waktu adalah untuk meningkatkan keakuratan peramalan (Sukiyono & Rosdiana, 2018). Salah satu metode dekomposisi yang mampu memisahkan komponen dasar suatu data runtun waktu adalah *Singular Spectrum Analysis (SSA)*.

SSA merupakan metode nonparametrik yang tidak memerlukan adanya asumsi tertentu yaitu kestasioneran dan kenormalan data runtun waktu (Ruhiat dkk., 2020). SSA mampu memisahkan data runtun waktu menjadi komponen penyusunnya yaitu tren, musiman, siklus, dan *noise* yang dapat diinterpretasikan. Algoritma SSA terdiri dari dua tahap yang saling berkaitan satu sama lain yaitu tahap dekomposisi dan tahap rekonstruksi. Hasil peramalan yang diperoleh merupakan penggabungan dari komponen musiman dan tren pada tahap rekonstruksi (Hidayat dkk., 2020).

Terdapat beberapa penelitian yang telah menggunakan metode SSA. Irwan dan Kaimuddin (2022), melakukan penelitian terhadap produksi padi di Kabupaten Pinrang yang menunjukkan bahwa metode SSA sangat akurat digunakan dalam peramalan dengan tingkat akurasi *Mean Absolute Percentage Error (MAPE)* sebesar 4,97%. Ruhiat dkk. (2020), melakukan penelitian terhadap debit Sungai Citarum PDA Nanjung yang menunjukkan bahwa metode SSA memberikan hasil peramalan dengan tingkat akurasi MAPE yang lebih kecil dibandingkan model *Seasonal Autoregressive Integrated Moving Average (SARIMA)* yaitu 0,00000457%.

Berdasarkan penelitian Seftiansyah dkk. (2013), metode dengan pemisahan komponen cocok untuk mencirikan runtun data ekonomi dan bisnis yang cenderung memuat faktor stasioner, tren, siklus, dan musiman. Salah satu data ekonomi yang dapat digunakan dalam penelitian adalah inflasi. Inflasi merupakan kecenderungan harga-harga yang mengalami kenaikan secara terus menerus dan mengakibatkan kenaikan sebagian besar dari barang-barang lain (Boediono, 2016). Inflasi tidak hanya menjadi fenomena di suatu negara, namun inflasi juga seringkali terjadi di ruang lingkup kabupaten/kota, sesuai dengan objek pada penelitian ini yaitu Kota Balikpapan.

Kota Balikpapan merupakan kota terbesar kedua setelah Kota Samarinda sekaligus merupakan salah satu dari tiga gerbang menuju Ibu Kota Negara (IKN) baru yang berada di Provinsi Kalimantan Timur. Menurut Hasibuan dan Aisa (2020), penetapan IKN di Kalimantan Timur memicu terjadinya peningkatan inflasi, baik di skala provinsi maupun nasional. Berdasarkan data yang dipublikasikan oleh Badan Pusat Statistik (BPS) Kalimantan Timur, diketahui bahwa Kota Balikpapan merupakan penyumbang inflasi tertinggi di Provinsi Kalimantan Timur, yaitu sebesar 2,28% pada tahun 2021 (Abdillah, 2021).

Berdasarkan latar belakang tersebut, maka perlu dilakukan peramalan jangka menengah inflasi di Kota Balikpapan untuk menekan pergerakan laju inflasi agar tetap dalam kondisi stabil dan tidak berdampak terhadap pertumbuhan perekonomian sehingga memberikan kemudahan perencanaan-perencanaan yang telah ditetapkan untuk menjaga stabilitas inflasi di Kota Balikpapan.

2. Tinjauan Pustaka

2.1 Periodogram

Periodogram dapat diartikan sebagai fungsi dari spektrum kuasa atas frekuensinya (Husnita dkk., 2015). Frekuensi dipasangkan dengan titik puncak garis spektral untuk memperoleh periodisitas data. Nilai periodogram dapat ditulis sebagai berikut (Darmawan dkk., 2017). Analisis periodogram dapat dilakukan pengujian hipotesis dengan tujuan untuk melihat apakah data pengamatan dipengaruhi oleh faktor musiman. Pengujian dapat dilakukan dengan menggunakan hipotesis H_0 (tidak terdapat pola musiman) dan H_1 (terdapat pola musiman) dengan statistik uji berdasarkan Persamaan (1) sebagai berikut:

$$T = \frac{I^{(1)}(\omega_{(1)})}{\sum_{i=1}^{\frac{n}{2}} I(\omega_i)} \quad (1)$$

di mana,

$$I^{(1)}(\omega_{(1)}) : \max \{I(\omega_i)\}$$

$$I(\omega_i) : \text{nilai periodogram}$$

H_0 ditolak jika $T > g_\alpha$, dengan nilai kritis g_α by first term only di mana $N = (n-1)/2$ jika n ganjil dan $N = (n/2) - 1$ jika n genap.

Selanjutnya, untuk memperoleh periode musiman dapat digunakan Persamaan (2) sebagai berikut:

$$T^* = \frac{2\pi}{\omega_i} \quad (2)$$

2.2. Singular Spectrum Analysis

SSA merupakan metode analisis runtun waktu nonparametrik yang digunakan dalam peramalan dengan tujuan untuk mendekomposisi runtun asli menjadi sejumlah kecil komponen yang dapat ditafsirkan seperti tren, musiman dan *noise* yang tidak terstruktur. SSA terdiri dari dua tahap yang saling melengkapi, yaitu tahap dekomposisi dan tahap rekonstruksi. Dasar dari algoritma SSA terdiri dari tahap dekomposisi dan rekonstruksi (Sakinah, 2018).

1. Dekomposisi

Pada dekomposisi, terdapat dua tahap yaitu *embedding* dan SVD (Darmawan dkk., 2018). Parameter utama dari dekomposisi adalah *window length*, dalam artian pemilihan *window length* yang tidak tepat akan berpengaruh terhadap proses untuk mendapatkan dekomposisi SSA yang baik.

a. Embedding

Embedding dapat diartikan sebagai tahap dalam mengubah data runtun waktu awal menjadi matriks lintasan \mathbf{X} di mana data yang awalnya hanya berbentuk satu dimensi (vektor) menjadi data berbentuk multidimensional (matriks) (Asrof dkk., 2017). Matriks lintasan \mathbf{X} berdimensi $L \times K$, di mana L merupakan *window length* berupa bilangan bulat dan K merupakan *L-lagged vector* $K = n - L + 1$.

Belum terdapat kriteria pemilihan L yang tepat, sehingga untuk menentukan nilai L dilakukan dengan proses coba-coba (*trial and error*), namun rentang pemilihan nilai L adalah $2 < L < n/2$ (Darmawan, dkk., 2018). Berikut Persamaan (3) untuk membentuk matriks lintasan \mathbf{X} (Jatmiko dkk., 2017):

$$\mathbf{X} = [\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_K] = \begin{bmatrix} Z_1 & Z_2 & \dots & Z_K \\ Z_2 & Z_3 & \dots & Z_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ Z_L & Z_{L+1} & \dots & Z_n \end{bmatrix} \quad (3)$$

b. *Singular Value Decomposition*

SVD atau disebut juga dengan dekomposisi nilai *singular* bertujuan untuk memperoleh pemisahan komponen dalam dekomposisi dari data runtun waktu. Tahapan SVD dimulai dengan menentukan nilai *eigen* $(\lambda_1, \lambda_2, \dots, \lambda_i)$ dari matriks simetris yaitu,

$$\mathbf{S} = \mathbf{X}\mathbf{X}^T \quad (4)$$

di mana $\lambda_1 \geq \dots \geq \lambda_i \geq 0$ dan $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_i$ adalah vektor *eigen* dari masing-masing nilai *eigen* matriks \mathbf{S} . *Rank* dari matriks lintasan \mathbf{X} dapat ditunjukkan dengan $r^* = L^* = \min(L, K)$. Jika dinotasikan,

$$\mathbf{v}_i = \frac{\mathbf{X}^T \mathbf{u}_i}{\sqrt{\lambda_i}} \text{ dimana } i = 1, 2, \dots, r^* \quad (5)$$

Matriks \mathbf{X} terbentuk dari vektor *eigen* (\mathbf{u}_i) , nilai *singular* $(\sqrt{\lambda_i})$ dan komponen utama (\mathbf{v}_i^T) . Ketiga elemen pembentuk SVD ini disebut *eigentriple* (Darmawan dkk., 2018). Sebuah matriks persegi dengan dimensi $L \times L$ misalkan matriks \mathbf{S} dan sebuah vektor kolom \mathbf{u} . Vektor \mathbf{u} merupakan vektor dalam ruang *Euclidian* R^n yang dihubungkan pada sebuah persamaan (6):

$$\mathbf{S}\mathbf{u} = \lambda \mathbf{u} \quad (6)$$

di mana λ merupakan suatu skalar dan \mathbf{u} adalah vektor yang tidak nol. Skalar λ disebut sebagai nilai *eigen* (*eigen value*) dari matriks \mathbf{S} (Adhiguna & Pujiyanta, 2014).

2. Rekonstruksi

Tahap rekonstruksi merupakan tahapan di mana data direkonstruksi menjadi data runtun waktu yang baru. Pada tahap ini terdiri dari dua langkah yaitu *grouping* dan *diagonal averaging*. Parameter yang memiliki peran penting dalam rekonstruksi adalah *grouping effect* (R).

a. *Grouping*

Pada tahap ini dilakukan pengelompokan matriks \mathbf{X}_i dengan tujuan untuk memisahkan komponen *eigentriple* yang diperoleh pada langkah SVD ke dalam beberapa sub kelompok, yaitu tren, musiman, dan *noise* (Jatmiko dkk., 2017). Menurut Ischak dkk. (2018), vektor *eigen* merupakan dasar pengelompokan dalam proses *grouping*.

b. *Diagonal Averaging*

Tahapan terakhir pada SSA adalah *diagonal averaging*. Proses *diagonal averaging* dilakukan dengan mentransformasi setiap matriks \mathbf{X}_{i_m} pada tahap pengelompokan menjadi suatu runtun waktu baru dengan jumlah n . Diberikan $\mathbf{Y}^{(k)}$ sebuah matriks berukuran $L \times K$ dengan elemen $y_{ij}^{(k)}$, di mana $1 \leq i \leq L$ dan $1 \leq j \leq K$ dan k merupakan komponen ke- k hasil rekonstruksi (Jatmiko dkk., 2017).

Diagonal averaging mentransformasi matriks $\mathbf{Y}^{(k)}$ ke dalam bentuk runtun kembali dengan menggunakan persamaan (7) sebagai berikut:

$$\hat{f}_t^{(k)} = \begin{cases} \frac{1}{t} \sum_{i=1}^t y_{i,t-i+1}^{(k)} ; \text{ untuk } 1 \leq t < L^* \\ \frac{1}{L^*} \sum_{i=1}^{L^*} y_{i,t-i+1}^{(k)} ; \text{ untuk } L^* \leq t \leq K^* \\ \frac{1}{n-t+1} \sum_{i=t-K^*+1}^{n-K^*+1} y_{i,t-i+1}^{(k)} ; \text{ untuk } K^* < t \leq n \end{cases} \quad (7)$$

Persamaan (7) tersebut akan diaplikasikan pada matriks resultan \mathbf{X}_{i_m} di mana membentuk runtun $\hat{F}^{(k)} = (\hat{f}_1^{(k)}, \hat{f}_2^{(k)}, \dots, \hat{f}_n^{(k)})$, oleh karena itu runtun awal akan didekomposisi menjadi jumlah dari m runtun yang direkonstruksi ditunjukkan pada persamaan (8) sebagai berikut (Jatmiko dkk., 2017):

$$\hat{f}_t = \sum_{k=1}^m \hat{f}_t^{(k)}, \text{ dimana } t = 1, 2, \dots, n \quad (8)$$

c. *W-Correlation*

Konsep utama dalam mempelajari SSA adalah pemisahan yang menjadi ciri khas seberapa baik komponen yang berbeda dapat dipisahkan antara yang satu dengan yang lainnya. Terdapat dua jenis keterpisahan, yaitu keterpisahan kuat dan lemah (Hassani & Mahmoudvand, 2018). Untuk mengukur tingkat keterpisahan dari dua runtun, misal $F^{(1)}$ dan $F^{(2)}$ digunakan suatu indikator yang disebut sebagai korelasi terboboti atau *W-correlation* (Golyandina & Zhigljavsky, 2013)

$$\rho^{(w)}(\hat{F}^{(1)}, \hat{F}^{(2)}) = \frac{(\hat{F}^{(1)}, \hat{F}^{(2)})_w}{\sqrt{(\hat{F}^{(1)}, \hat{F}^{(1)})_w (\hat{F}^{(2)}, \hat{F}^{(2)})_w}} \tag{9}$$

Besarnya korelasi ditunjukkan oleh gradasi warna dari warna terang hingga gelap dari plot *W-correlation* (Wicaksono dkk., 2019). Semakin gelap warnanya semakin tinggi nilai korelasinya.

3. Peramalan SSA

Salah satu metode peramalan yang digunakan dalam SSA adalah *Recurrent Forecasting Method (R-forecasting)* yang berkaitan dengan penaksiran *Linear Recurrent Formula (LRF)*. Koefisien LRF dari suatu komponen dapat dihitung menggunakan persamaan (10) sebagai berikut (Hassani & Mahmoudvand, 2018):

$$\mathbf{r}^{(k)} = (r_{L-1}^{(k)}, \dots, r_1^{(k)}) = \frac{1}{1 - \nu^2} \sum_{i=1}^L \sigma_i \mathbf{u}_i^\nabla \tag{10}$$

Runtun waktu hasil peramalan dapat ditulis dengan persamaan (11) sebagai berikut:

$$\hat{F}^{(k)} = (\hat{f}_1^{(k)}, \hat{f}_2^{(k)}, \dots, \hat{f}_{n+M}^{(k)}), \tag{11}$$

dengan hasil peramalan diperoleh berdasarkan persamaan (12) sebagai berikut:

$$\hat{f}_t^{(k)} = \begin{cases} \hat{f}_t^{(k)} & \text{untuk } t = 1, 2, \dots, n \\ \sum_{j=1}^{L-1} r_j^{(k)} \hat{f}_{t-j}^{(k)} & \text{untuk } t = n + 1, \dots, n + M \end{cases} \tag{12}$$

di mana $\hat{f}_{n+1}^{(k)}, \hat{f}_{n+2}^{(k)}, \dots, \hat{f}_{n+M}^{(k)}$ adalah hasil peramalan menggunakan SSA dengan $k = 1$ untuk komponen tren dan $k = 2$ untuk komponen musiman (Jatmiko dkk., 2017).

2.3 *Mean Arc tangent Absolute Percentage Error*

Mean Arc tangent Absolute Percentage Error (MAAPE) merupakan salah satu pengukuran nilai yang digunakan untuk mengukur kesesuaian antara data aktual dan hasil peramalan. Semakin kecil nilai MAAPE, maka hasil peramalan yang diperoleh akan semakin akurat. Nilai MAAPE dihitung menggunakan persamaan (13) sebagai berikut (Kim & Kim, 2016):

$$\text{MAAPE} = \frac{1}{n} \sum_{t=1}^n \left(\arctan \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \right) \times 100\% \tag{13}$$

2.4 *Inflasi*

Inflasi merupakan kecenderungan harga-harga yang mengalami kenaikan secara terus menerus dan mengakibatkan kenaikan sebagian besar dari barang-barang lain (Boediono, 2016). Menurut Putong (2013), rumus untuk menghitung inflasi adalah:

$$I_n = \frac{IHK_n - IHK_0}{IHK_0} \times 100\% \tag{14}$$

3. **Bahan dan Metode**

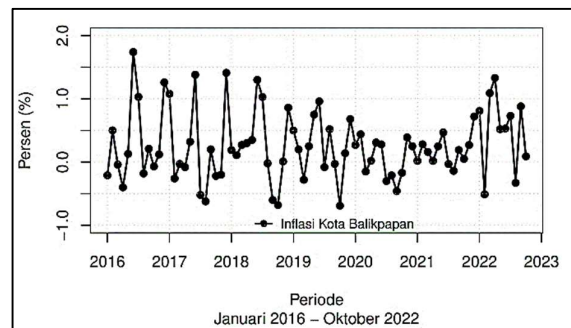
Variabel penelitian yang digunakan dalam penelitian adalah inflasi Kota Balikpapan. Teknik pengumpulan data dilakukan dengan cara mengambil data sekunder melalui laman resmi Badan Pusat Statistik (BPS) Kota Balikpapan, <https://balikpapankota.bps.go.id/>. Teknik *sampling* penelitian ini adalah teknik *purposive sampling* atau yang dikenal dengan *sampling* pertimbangan karena data diambil berdasarkan pertimbangan ketersediaan, keterbaruan dan keruntunan waktu pada data inflasi Kota Balikpapan, yaitu periode Januari 2016 sampai dengan Oktober 2022. Metode yang digunakan dalam penelitian ini adalah *Singular Spectrum Analysis*. Tahapan analisis data yang digunakan dalam penelitian adalah sebagai berikut:

- a. Melakukan analisis statistika deskriptif dengan menyajikan grafik runtun waktu.
- b. Melakukan analisis periodogram untuk mengidentifikasi keberadaan unsur musiman pada data inflasi.
- c. Melakukan proses *embedding* pada tahap dekomposisi. Pada tahap *embedding*, dilakukan pemilihan terhadap parameter tunggal dekomposisi yaitu *window length (L)*. Pemilihan parameter *window length*

- dapat dilakukan melalui *trial and error* dengan kriteria MAAPE, di mana L dengan MAAPE terkecil yang akan digunakan untuk membentuk matriks X .
- d. Melakukan proses SVD dengan cara mendekomposisikan matriks *singular* dari matriks lintasan X menjadi suatu penjumlahan.
 - e. Melakukan proses *grouping* pada tahap rekonstruksi. Proses *grouping* dapat dilakukan melalui dua cara yaitu, menggunakan grafik nilai *singular* dan vektor eigen.
 - f. Melakukan proses *diagonal averaging*. Matriks yang diperoleh pada tahap *grouping* ditransformasi ulang menjadi data runtun baru. Sebelum melakukan proses *diagonal averaging*, perlu mendeteksi apakah runtun dari kelompok yang terbentuk tidak saling berkorelasi dengan kelompok lainnya menggunakan matriks W .
 - g. Melakukan prediksi inflasi Kota Balikpapan periode Januari 2016 sampai dengan Oktober 2022.
 - h. Menghitung tingkat akurasi berdasarkan nilai MAAPE.
 - i. Melakukan peramalan inflasi Kota Balikpapan periode November 2022 sampai dengan Oktober 2023.
 - j. Membuat grafik data inflasi Kota Balikpapan dengan data hasil prediksi dan peramalan periode Januari 2016 sampai dengan Oktober 2023.

4. Hasil dan Diskusi

Data yang digunakan dalam penelitian ini adalah data inflasi Kota Balikpapan periode Januari 2016 sampai dengan Oktober 2022 sebanyak 82 data. Adapun pola data ditampilkan dalam bentuk grafik runtun waktu pada Gambar 1.



Gambar 1. Grafik Runtun Waktu Inflasi Kota Balikpapan

Berdasarkan Gambar 1, inflasi Kota Balikpapan periode Januari 2016 sampai dengan Oktober 2022 tidak membentuk pola yang tren, tetapi cenderung membentuk pola musiman yang stasioner. Hal ini dikarenakan pola dari data tersebut mengalami kenaikan dan penurunan yang berulang-ulang secara periodik namun dalam keadaan stasioner.

Analisis secara grafis mengindikasikan bahwa terdapat pola musiman pada data inflasi Kota Balikpapan, oleh karena itu untuk mendukung hasil analisis secara grafis dilakukan pengujian hipotesis menggunakan analisis periodogram. Periodogram digunakan untuk mengetahui pola atau unsur musiman pada suatu data pengamatan. Berdasarkan Persamaan (1), diperoleh keputusan bahwa H_0 ditolak karena $T = 0,2597 > g_{0,05;40} = 0,1575$ dan dapat disimpulkan bahwa terdapat pola musiman pada data inflasi Kota Balikpapan. Setelah disimpulkan bahwa terdapat pola musiman pada data inflasi Kota Balikpapan, diperoleh periode inflasi Kota Balikpapan periode Januari 2016 sampai dengan Oktober 2022 adalah 6 bulan berdasarkan Persamaan (2). Hal ini menunjukkan bahwa perubahan inflasi akan mengalami kenaikan atau penurunan setiap 6 bulan sekali. Berdasarkan hasil analisis periodogram, diketahui bahwa data inflasi Kota Balikpapan berpola musiman. Sehingga, peramalan dapat dilanjutkan dengan menggunakan metode SSA.

4.1 Dekomposisi


Langkah pertama dalam proses dekomposisi adalah melakukan *embedding*. Pada penelitian ini nilai parameter *window length* (L) yang diperoleh melalui hasil *trial and error* berdasarkan kriteria MAAPE terkecil pada Persamaan (13) dengan rentang pemilihan nilai L adalah $2 < L < 41$. Diperoleh nilai MAAPE terkecil pada $L = 13$ sebesar 23,53%.

Berdasarkan nilai $L = 13$ maka dapat ditentukan jumlah *L-Lagged vector* atau nilai K , yaitu $K = n - L + 1 = 82 - 13 + 1 = 70$. Dengan demikian, matriks lintasan X dapat disusun berdasarkan Persamaan (3). Sebelum mencari nilai SVD, tahap yang perlu dilakukan adalah membentuk matriks S dari matriks lintasan X di mana $S = XX^T$ dapat disusun berdasarkan Persamaan (4). Proses SVD akan mendekomposisi matriks lintasan X menjadi 13 *eigen triple*. Tahap SVD diawali dengan menentukan nilai eigen dan nilai *singular* dari

matriks S menggunakan Persamaan (4). Selanjutnya adalah menentukan vektor eigen dari masing-masing nilai eigen yang telah diperoleh menggunakan Persamaan (6). Terakhir, adalah menghitung nilai komponen utama. Komponen utama diperoleh dengan menggunakan nilai *singular* dan vektor eigen yang telah diperoleh sebelumnya dari matriks S menggunakan Persamaan (5).

4.2 Rekonstruksi

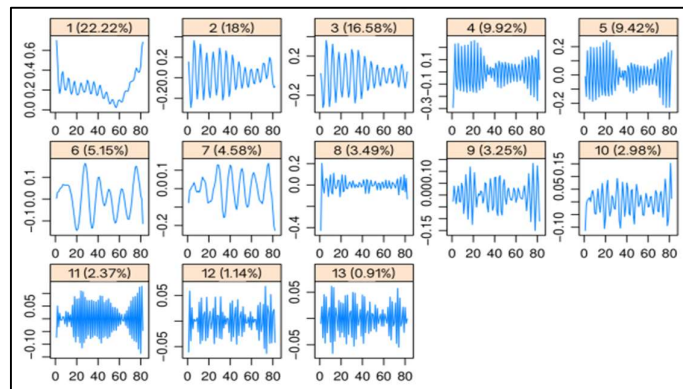
Grouping didasarkan pada *eigen triple* yang mencerminkan komponen tren, musiman dan *noise*. *Grouping effect* merupakan ukuran yang digunakan pada proses *grouping*. Nilai *grouping effect* diperoleh dari jumlah nilai *singular* yang tidak menggambarkan unsur *noise* pada grafik nilai *singular*. Nilai *singular* yang turun secara lambat biasanya dikelompokkan ke dalam unsur *noise*. Berikut disajikan grafik antara nilai *singular* dan parameter *window length* (L) untuk menentukan nilai *grouping effect*.



Gambar 2. Grafik Nilai Singular

Berdasarkan Gambar 2, dapat dilihat bahwa nilai *singular* mengalami penurunan secara lambat mulai dari nilai *singular* 1 sampai 3, 4 sampai 5 dan 6 sampai 11. Penurunan secara lambat pada nilai *singular* tersebut diidentifikasi sebagai unsur *noise* sebanyak 11 nilai *singular* yang cenderung tersebar di antara 13 nilai *singular*. *Eigen triple* yang telah dipisahkan pada Gambar 2 menghasilkan pengelompokan yang subjektif dikarenakan masih ada kemungkinan jumlah *eigen triple* yang memuat unsur tren, musiman dan *noise* dapat berubah dari 13 *eigen triple* yang telah diidentifikasi sehingga nilai *grouping effect* yang diambil yaitu $R = 13$ di mana akan dilakukan pemeriksaan kembali pada seluruh *eigen triple*.

Untuk menentukan *eigen triple* yang memuat unsur tersebut dapat dilakukan dengan menggunakan grafik vektor eigen sebagai berikut.



Gambar 3. Grafik Vektor Eigen

Berdasarkan Gambar 3, dapat dilihat bahwa kurva vektor eigen 1 memuat unsur tren karena bervariasi secara lambat. Selain itu, nilai persentase pada vektor eigen 1 sebesar 22,22% yang terlihat berbeda jauh dengan nilai persentase vektor eigen lainnya secara berurutan, sehingga *eigen triple* 1 dapat dikelompokkan dalam komponen tren dan sisa *eigen triple* lainnya akan dikelompokkan sebagai komponen musiman dan *noise*.

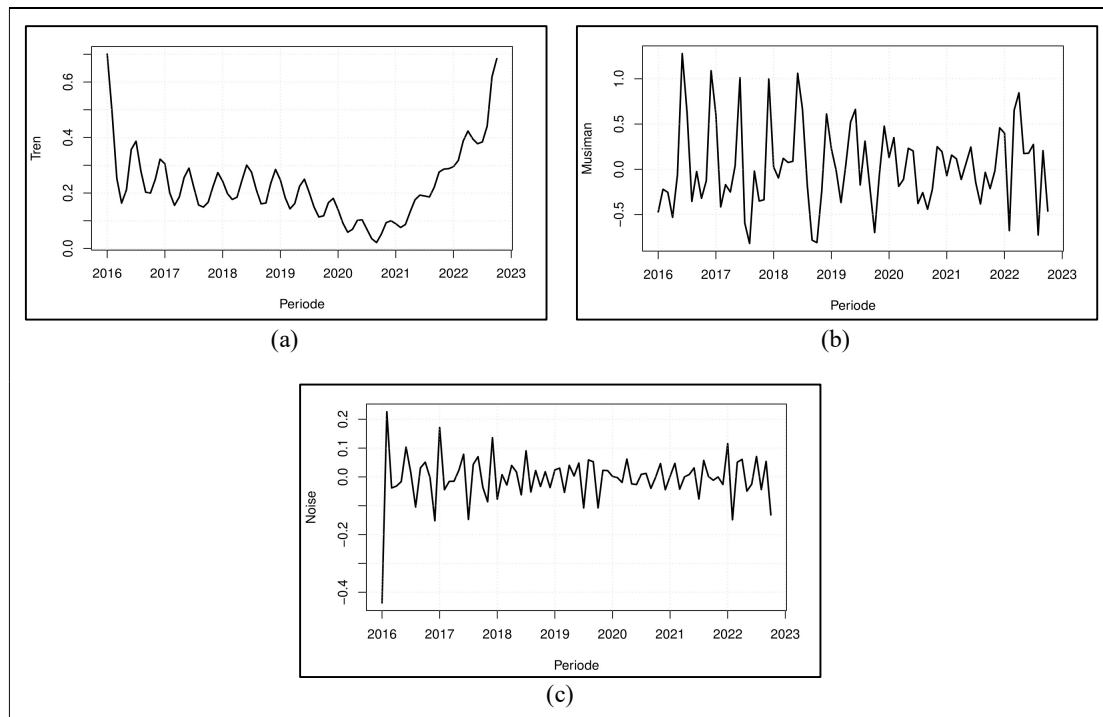
Selanjutnya pengelompokan terhadap *eigen triple* yang memuat unsur musiman dengan memperhatikan kemiripan kurva vektor eigen dan nilai persentase vektor eigen. Berdasarkan Gambar 3, dapat dilihat bahwa kurva vektor eigen 2 dan vektor eigen 3 memiliki kesamaan pola cenderung membentuk pola musiman, selain itu keduanya memiliki nilai persentase yang tidak jauh berbeda yaitu 18% dan 16,58%. Oleh karena itu *eigen triple* 2 dan *eigen triple* 3 dikelompokkan dalam komponen musiman. Pada vektor eigen 6 dan vektor eigen 7 juga memiliki kesamaan pola yang cenderung membentuk pola musiman dengan nilai persentase keduanya yang tidak jauh berbeda. Sisa *eigen triple* yang tidak dikelompokkan dalam kelompok tren dan musiman dari 13 *eigen triple* sebelumnya akan dikelompokkan sebagai *noise*.

Pengelompokan yang telah dilakukan berdasarkan Gambar 2 dan Gambar 3, mengindikasikan bahwa adanya unsur musiman pada sebagian besar *eigen triple* 2 sampai dengan *eigen triple* 13. Oleh karena itu, akan dilakukan pemeriksaan unsur musiman pada *eigen triple* 2 sampai dengan *eigen triple* 13 menggunakan analisis periodogram berdasarkan Persamaan (2). Analisis periodogram dilakukan untuk memisahkan *eigen triple* terkait komponen musiman dan *noise*. Hasil pengelompokan *eigen triple* dapat dilihat pada Tabel 1.

Tabel 1. Pengelompokan *Eigen triple*

Kelompok	<i>Eigen triple</i>
Tren	1
Musiman	2, 3, 4, 5, 6, 7, 9, 10, 11 dan 12
Noise	8 dan 13

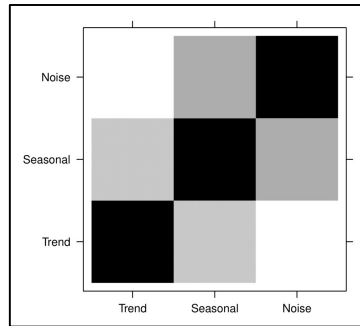
Setelah memperoleh kelompok dan anggota dari masing-masing kelompok pada tahap *grouping*, tahapan selanjutnya adalah *diagonal averaging*. Kelompok *eigen triple* yang diperoleh sebelumnya dipilih untuk direkonstruksi kembali menjadi runtun baru, di mana masing-masing komponen akan direkonstruksi oleh masing-masing *eigen triple* yang terkait.



Gambar 4. Komponen yang Direkonstruksi

Berdasarkan Persamaan (7) diperoleh runtun tren yang direkonstruksi melalui proses *diagonal averaging*, yaitu $\hat{F}^{(1)} = (0,7008 ; 0,4940 ; \dots ; 0,6845)$. Hasil dari komponen tren yang direkonstruksi disajikan dalam bentuk grafik antara waktu dengan komponen tren yang direkonstruksi dan ditampilkan pada Gambar 4(a). Selain itu, diperoleh runtun musiman yang direkonstruksi melalui proses *diagonal averaging*, yaitu $\hat{F}^{(2)} = (-0,4737 ; -0,2204 ; \dots ; -0,4625)$. Hasil dari komponen musiman yang direkonstruksi disajikan dalam bentuk grafik antara waktu dengan komponen musiman yang direkonstruksi dan ditampilkan pada Gambar 4(b). Terakhir, diperoleh runtun *noise* yang direkonstruksi melalui proses *diagonal averaging*, yaitu $\hat{F}^{(3)} = (-0,4372 ; 0,2263 ; \dots ; -0,1320)$. Hasil dari komponen *noise* yang direkonstruksi disajikan dalam bentuk grafik antara waktu dengan komponen *noise* yang direkonstruksi dan ditampilkan pada Gambar 4(c).

Setelah runtun dari komponen tren, musiman, dan *noise* telah terbentuk selanjutnya dapat dilihat keterpisahan *eigen triple* yang telah dikelompokkan dalam masing-masing komponen. Cara untuk melihat keterpisahan tersebut digunakan korelasi terboboti (*W-correlation*). Nilai *W-correlation* untuk setiap kelompok yang terbentuk dapat dihitung berdasarkan Persamaan (9). Berikut merupakan Gambar 5 yang menunjukkan plot *W-correlation* dari matriks *W* yang digunakan untuk melihat besarnya korelasi antar komponen.



Gambar 5. Plot *W*-Correlation

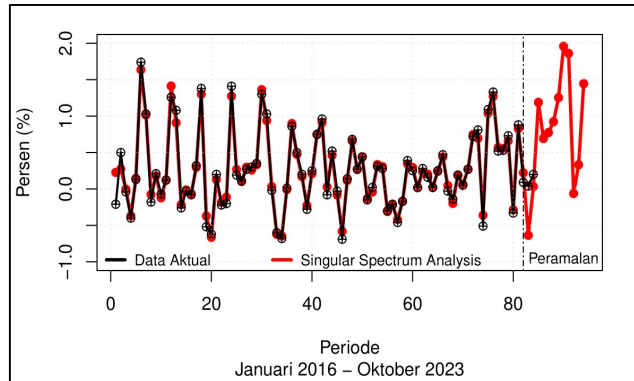
Berdasarkan Gambar 5, dapat dilihat bahwa antara komponen tren dan komponen musiman dapat dipisahkan karena memiliki gradasi yang lebih terang. Kemudian, dapat dilihat juga bahwa antara komponen tren dan komponen *noise* juga berwarna putih sehingga dapat dikatakan bahwa komponen tren dan *noise* dapat dipisahkan. Lalu, dapat dilihat bahwa komponen musiman dan komponen *noise* memiliki gradasi yang lebih terang sehingga dapat dikatakan bahwa komponen musiman dan *noise* dapat dipisahkan.

Setelah melakukan pemeriksaan terhadap keterpisahan dari *eigentriple* yang telah dikelompokkan dalam masing-masing komponen, langkah selanjutnya adalah melakukan peramalan 12 periode selanjutnya dari data inflasi Kota Balikpapan, yaitu menghitung peramalan periode November 2022 sampai dengan Oktober 2023 menggunakan *R-Forecasting* dengan koefisien LRF. Koefisien LRF digunakan untuk membentuk runtun hasil peramalan ($\hat{f}_{n+M}^{(k)}$) komponen tren dan musiman menggunakan Persamaan (10). Peramalan inflasi Kota Balikpapan periode November 2022 sampai dengan Oktober 2023 diperoleh menggunakan *R-Forecasting* menggunakan Persamaan (12) yang disajikan dalam Tabel 2.

Tabel 2. Hasil Peramalan Inflasi Kota Balikpapan Periode November 2022 sampai Oktober 2023 dengan Metode SSA

Waktu	Komponen Tren	Komponen Musiman	Hasil Peramalan
November 2022	0,57016	-1,2059	-0,6357
Desember 2022	0,57467	-0,5420	0,0327
Januari 2023	0,59651	0,5917	1,1882
Februari 2023	0,64439	0,0479	0,6923
Maret 2023	0,71258	0,0609	0,7735
April 2023	0,76271	0,1602	0,9229
Mei 2023	0,77955	0,4740	1,2535
Juni 2023	0,79464	1,1631	1,9578
Juli 2023	0,83130	1,0293	1,8606
Agustus 2023	0,89634	-0,9589	-0,0625
September 2023	0,97428	-0,6426	0,3317
Oktober 2023	1,02145	0,4238	1,4453

Hasil prediksi dan peramalan yang telah diperoleh pada Tabel 2, selanjutnya disajikan dalam bentuk Gambar 6. Gambar 6 merupakan grafik dari hasil prediksi dan peramalan data inflasi Kota Balikpapan periode Januari 2016 sampai Desember 2023 menggunakan metode SSA. Berdasarkan Gambar 6, dapat dilihat bahwa pola data hasil prediksi inflasi Kota Balikpapan periode Januari 2016 sampai Oktober 2022 mengalami fluktuatif yang menyerupai data aktual dengan nilai MAAPE sebesar 23,53%. Berdasarkan Gambar 6, dapat dilihat juga bahwa hasil peramalan inflasi Kota Balikpapan periode November 2022 sampai Oktober 2023, terjadi penurunan inflasi pada bulan November 2022 sebesar -0,64% atau dapat dikatakan akan terjadi deflasi sebesar 0,64%.



Gambar 6. Grafik Data Aktual dan Hasil Peramalan Inflasi Kota Balikpapan

Pada periode selanjutnya, inflasi cenderung akan mengalami peningkatan di mana inflasi tertinggi akan terjadi pada bulan Juni 2023 sebesar 1,96%. Gambar 6 juga menampilkan hasil peramalan inflasi Kota Balikpapan tahun 2022 dengan tambahan data aktual terbaru yaitu periode November 2022 sampai dengan Desember 2022 dengan nilai berturut-turut sebesar 0,04% dan 0,20% yang diperoleh dari Badan Pusat Statistik Kota Balikpapan.

5. Kesimpulan

Berdasarkan hasil penelitian mengenai peramalan inflasi Kota Balikpapan menggunakan metode SSA, maka dapat diperoleh kesimpulan bahwa pada tahun 2022 akan terjadi penurunan inflasi pada bulan November sebesar -0,64% atau dapat dikatakan akan terjadi deflasi sebesar 0,64%. Pada periode selanjutnya, inflasi cenderung akan mengalami peningkatan di mana inflasi tertinggi akan terjadi pada bulan Juni 2023 sebesar 1,96% dengan nilai MAAPE sebesar 23,53% yang menyatakan bahwa metode cukup akurat.

Ucapan Terima Kasih

Terima kasih kepada Badan Pusat Statistik Kota Balikpapan karena telah menyediakan data sebagai penunjang penelitian dan terima kasih kepada Program Studi Statistika Universitas Mulawarman karena membantu berjalannya proses pelaksanaan penelitian dengan lancar hingga akhir.

Daftar Pustaka

- Abdillah, R. F. (2021). *Indeks Harga Konsumen dan Inflasi Provinsi Kalimantan Timur 2021*. Samarinda: BPS Kaltim.
- Adhiguna, K., & Pujiyanta, A. (2014). Aplikasi Bantu untuk Menentukan Nilai Eigen dan Vektor Eigen Berbasis Multimedia. *Jurnal Sarjana Teknik Informatika*, 2(1).
- Asrof, A., Ischak, R., & Darmawan, G. (2017). Peramalan Produksi Cabai Merah di Jawa Barat Menggunakan Metode Singular Spectrum Analysis. *Jurnal Statistika*, 17(2).
- Boediono. (2016). *Ekonomi Internasional*. Yogyakarta: BPFE.
- Darmawan, G., Handoko, B., & Zulhanif. (2017). Identifikasi Perubahan Pola Curah Hujan Melalui Periodogram Standar. *JMP*, 9(1).
- Darmawan, G., Khaeri, H., & Yulian, E. (2018). Penerapan Metode Singular Spectrum Analysis (SSA) Pada Peramalan Jumlah Penumpang Kereta Api di Indonesia Tahun 2017. *Jurnal Euclid*, 5(1).
- Dewi, P. N., & Listiowarni, I. (2020). Implementasi Holt-Winters Exponential Smoothing untuk Peramalan Harga Bahan Pangan di Kabupaten Pamekasan. *Digital Zone: Jurnal Teknologi Informasi dan Komunikasi*, 11(2).
- Golyandina, N., & Zhigljavsky, A. (2013). *Singular Spectrum Analysis for Time Series*. New York: Springer.
- Hasibuan, R. R., & Aisa, S. (2020). Dampak dan Resiko Pemandangan Ibu Kota Terhadap Ekonomi di Indonesia. *AT-TAWASSUTH: Jurnal Ekonomi Islam*, 5(1).
- Hassani, H., & Mahmoudvand, R. (2018). *Singular Spectrum Analysis With R*. Iran: Palgrave Advanced Texts in Econometrics.
- Hidayat, K. W., Wahyuningsih, S., & Nasution, Y. N. (2020). Pemodelan Jumlah Titik Panas di Provinsi Kalimantan Timur dengan Metode Singular Spectrum Analysis. *JAMBURA*, 1(2).
- Husnita, F., Wahyuningsih, S., & Nohe, D. A. (2015). Analisis Spektral dan Model ARIMA untuk Peramalan Jumlah Wisatawan di Dunia Fantasi Taman Impian Jaya Ancol. *Jurnal Ekspensial*, 6(1).
- Irwan, Sauddin, A., & Kaimuddin, A. (2022). Peramalan Produksi Padi Kabupaten Pinrang dengan Metode Singular Spectrum Analysis. *Jurnal Matematika dan Statistika serta Aplikasinya*, 10(1).

- Ischak, R., Asrof, A., & Darmawan, G. (2018). Peramalan Rata-Rata Harga Beras di Tingkat Penggilingan Menggunakan Model Singular Spectrum Analysis (SSA). *Prosiding Seminar Nasional Matematika dan Pendidikan Matematika, Yogyakarta*, 4(1).
- Jatmiko, Y.A., Rahayu, R.L., & Darmawan, G. (2017). Perbandingan Keakuratan Hasil Peramalan Produksi Bawang Merah Metode Holt-Winters dengan Singular Spectrum Analysis (SSA). *Jurnal Matematika (MANTIK)*, 3(1).
- Juliana, A., Hamidatun, & Muslima, R. (2019). *Modern Forecasting, Teori dan Aplikasi*. Tarakan: DEEPUBLISH.
- Kim, S., & Kim, H. (2016). A New Metric of Absolute Percentage Error for Intermittent Demand Forecasts. *International Journal of Forecasting*, 32(3).
- Putong, I. (2013). *Economics Pengantar Mikro dan Makro*. Jakarta: Mitra Wacana Media.
- Ruhiat, D., Andiani, D., & Kamilah, W. N. (2020). Forecasting Data Runtun Waktu Musiman Menggunakan Metode Singular Spectrum Analysis (SSA). *Teorema*, 5(1).
- Sakinah, A. M. (2018). Akurasi Peramalan Long Horizon dengan Singular Spectrum Analysis. *Journal of Sunan Gunung Jati State Islamic University (UIN)*, 3(2).
- Seftiansyah, E. S., Yuniarti, D., & Syaripuddin. (2013). Peramalan Kas Bank Central Asia, Tbk Samarinda Tahun 2012 Dengan Menggunakan Metode Dekomposisi dan Double Moving Averages. *Jurnal Eksponensial*, 4(2).
- Sukiyono, K., & Rosdiana. (2018). Pendugaan Model Peramalan Harga Beras Pada Tingkat Grosir. *AGRISEP*, 17(1).
- Wicaksono, A., Yundari, & Helmi. (2019). Prediksi Outflow Uang Kartal di Kalimantan Barat dengan Metode Singular Spectrum Analysis (SSA). *Bimaster*, 8(3).