

Peramalan Jumlah Produksi Kelapa Sawit Provinsi Kalimantan Timur Menggunakan Metode Singular Spectrum Analysis

Meiliyani Siringoringo^{a,*}, Sri Wahyuningsih^a, Ika Purnamasari^a, Melisa Arumsari^a

^aLaboratorium Statistika Ekonomi dan Bisnis, Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Mulawarman University, Samarinda City, 75123, Indonesia

*Keywords: Oil Palm
Production,
Forecasting, Singular
Spectrum Analysis*

Abstract:

Singular spectrum analysis (SSA) is a nonparametric method that does not rely on assumptions such as stationary nature or residual normality. SSA separates time series data into its components, which are trend, seasonality, and error (noise). This study aimed to obtain forecasting results for the amount of oil palm production in East Kalimantan Province for the period January 2021 to December 2021 using SSA. Based on the results of the data analysis, in the process of forming the forecasting model with in-sample data, the parameter window length (L) was 24, which produced a MAPE value of 0.464%, and while the forecasting model validation process used out-sample data, it produced a MAPE value of 41.172%.

1. Pendahuluan

Peramalan merupakan suatu kegiatan untuk memperkirakan sesuatu di masa depan berdasarkan data historis. Metode-metode peramalan yang biasanya digunakan seperti metode rata-rata bergerak, metode deterministik, metode dekomposisi, metode pemulusan eksponensial dan metode ARIMA Box-Jenkins. Metode-metode tersebut dapat digunakan jika mengikuti pola data runtun waktu tertentu dan harus memenuhi asumsi-asumsi tertentu seperti stasioneritas data atau kenormalan residual. Oleh karena itu terdapat beberapa metode yang dikembangkan untuk pola runtun waktu apapun dan atau tanpa memenuhi asumsi-asumsi tertentu salah satunya adalah metode Singular Spectrum Analysis (SSA).

SSA diperkenalkan oleh Broomhead dan King pada tahun 1986 dan masih terus dikembangkan (Golyandina, Nekrutkin, & Zhigljavsky, 2001). SSA merupakan teknik analisis nonparametrik yang tidak memerlukan asumsi statistik seperti stasioneritas atau normalitas residual (Zhang, Wang, He, Peng, & Ren, 2011). Algoritma dasar SSA terbagi menjadi dua tahap yaitu dekomposisi dan rekonstruksi. Hasil peramalan dari metode SSA adalah penggabungan komponen musiman dan tren dari tahap rekonstruksi (Zhigljavsky, 2010). Banyak penelitian dengan menggunakan SSA antara lain Siregar, Prariesa, dan

* Corresponding author.

E-mail address: meiliyanisiringoringo@fmipa.unmul.ac.id



Darmawan (2017), dan Satriani, Nursalam, dan Ibas (2020) yang dalam penelitiannya mendapatkan hasil bahwa metode SSA merupakan metode yang handal untuk digunakan dalam sebuah peramalan dengan nilai ketepatan peramalan yang baik.

Hasil peramalan dengan metode SSA akan diterapkan dalam meramalkan jumlah produksi kelapa sawit Provinsi Kalimantan Timur. Kelapa sawit menjadi salah satu komoditas utama perkebunan di Provinsi Kalimantan Timur yang mana dari tahun 2015 hingga tahun 2019 luas tanam mengalami kenaikan sebesar 12,66 persen. Peningkatan luas tanam tersebut juga meningkatkan produksi kelapa sawit pada kurun waktu tersebut. Produksi tandan buah segar mengalami kenaikan sebesar 69,65 persen (Dinas Perkebunan Provinsi Kalimantan Timur, 2020). Potensi kelapa sawit dapat terus ditingkatkan dengan melihat proyeksinya di masa depan dengan menggunakan metode statistika yaitu peramalan sehingga dapat dijadikan informasi dalam mengambil kebijakan.

2. Tinjauan Pustaka

2.1. Singular Spectrum Analysis

Singular Spectrum Analysis (SSA) adalah teknik analisis data runtun waktu yang mendekomposisi runtun waktu asli menjadi komponen tren, musiman, dan *noise*. SSA didasarkan pada *singular value decomposition* (SVD) dari matriks spesifik yang dibangun pada runtun waktu. Tahap algoritma dasar SSA terbagi menjadi dua yaitu dekomposisi dan rekonstruksi (Zhigljavsky, 2010).

Tahap dekomposisi terbagi menjadi dua yaitu *embedding* dan SVD. Parameter utama dari dekomposisi adalah *window length* (L) yang berpengaruh pada kegiatan pengelompokkan yang akan membantu untuk memperoleh dekomposisi yang baik (Khaeri, Yulian, & Darmawan, 2018). Tahap *embedding* mengubah data runtun waktu ke dalam bentuk matriks lintasan dengan mentransformasi data yang berdimensi satu (vektor) menjadi data multidimensional (matriks). Data runtun waktu dengan panjang n , $F = (f_1, f_2, \dots, f_n)$ ditransformasi ke dalam bentuk matriks berukuran $L \times K$, yaitu matriks Hankel dimana $2 < L < n/2$. Penentuan nilai L dilakukan secara coba-coba (*trial and error*) dan $K = n - L + 1$. Matriks lintasan, \mathbf{X} , dibentuk dengan (Jatmiko, Rahayu, & Darmawan, 2017)

$$\mathbf{f}_i = (f_1, f_{i+1}, \dots, f_{i+L-1})^T \text{ dimana } 1 \leq i \leq K \quad (1)$$

Pada tahap SVD, nilai singular dari matriks lintasan \mathbf{X} didekomposisi menjadi penjumlahan matriks yang diperoleh dari *eigen triple*.

$$\mathbf{S} = \mathbf{X}\mathbf{X}^T \quad (2)$$

misalkan $\lambda_1, \lambda_2, \dots, \lambda_i$ merupakan nilai eigen dari matriks dimana $\lambda_1 \geq \dots \geq \lambda_i \geq 0$ dan $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_i$ adalah vektor eigen dari nilai eigen matriks \mathbf{S} . Rank dari matriks \mathbf{X} ditunjukkan dengan $r^* = \max\{i, \text{so } \lambda_i > 0\}$. Jika dinotasikan,

$$\mathbf{v}_i = \frac{\mathbf{X}^T \mathbf{u}_i}{\sqrt{\lambda_i}} \text{ dimana } i = 1, 2, \dots, r^* \quad (3)$$

Maka SVD dari matriks lintasan adalah sebagai berikut.

$$\begin{aligned} \mathbf{X} &= \mathbf{X}_1 + \mathbf{X}_2 + \dots + \mathbf{X}_{r^*} \\ &= \mathbf{u}_1 \sqrt{\lambda_1} \mathbf{v}_1^T + \mathbf{u}_2 \sqrt{\lambda_2} \mathbf{v}_2^T + \dots + \mathbf{u}_{r^*} \sqrt{\lambda_{r^*}} \mathbf{v}_{r^*}^T \\ &= \sum_{i=1}^{r^*} \mathbf{u}_i \sqrt{\lambda_i} \mathbf{v}_i^T \end{aligned} \quad (4)$$

Matriks \mathbf{X} terbentuk dari vektor eigen, \mathbf{u}_i , nilai singular $\sqrt{\lambda_i}$ dan *principal component*, \mathbf{v}_i^T . Ketiga elemen pembentuk SVD ini disebut *eigen triple* (Khaeri, Yulian, & Darmawan, 2018)

Tahap rekonstruksi terbagi menjadi dua yaitu *grouping* dan *diagonal averaging*. Parameter yang memiliki peran penting dalam rekonstruksi adalah *grouping effect* (R). Dasar pengelompokkan pada proses *grouping* adalah vektor eigen. Tujuan dari proses pengelompokkan adalah untuk memisahkan

komponen aditif dari runtun waktu dengan cara memisahkan matriks yang telah diperoleh melalui langkah SVD ke dalam beberapa kelompok, kemudian menjumlahkannya ke dalam setiap kelompok. (Ischak, Asrof, & Darmawan, 2018). Tahapan terakhir pada SSA adalah *diagonal averaging*. Proses *diagonal averaging* dilakukan dengan mentransformasi setiap matriks yang diperoleh pada tahap *grouping* menjadi suatu runtun waktu dengan panjang n . *Diagonal averaging* mentransformasi matriks $Y^{(k)}$ ke dalam bentuk runtun kembali dengan menggunakan persamaan berikut :

$$\hat{f}_t^{(k)} = \begin{cases} \frac{1}{t} \sum_{i=1}^t y_{i,t-i+1}^{*(k)} & ; \text{ untuk } 1 \leq t < L^* \\ \frac{1}{L^*} \sum_{i=1}^{L^*} y_{i,t-i+1}^{*(k)} & ; \text{ untuk } L^* \leq t \leq K^* \\ \frac{1}{n-t+1} \sum_{i=t-K^*+1}^{n-K^*+1} y_{i,t-i+1}^{*(k)} & ; \text{ untuk } K^* < t \leq n \end{cases} \quad (5)$$

$Y^{(k)}$ 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. Misalkan $L^* = \min(L, K)$, $K^* = \max(L, K)$, dan $n = L + K - 1$. Jika $L < K$, $y_{ij}^{*(k)} = y_{ij}^{(k)}$, dan jika $L > K$, $y_{ij}^{*(k)} = y_{ji}^{(k)}$. Runtun awal akan didekomposisi menjadi jumlah dari m runtun yang direkonstruksi ditunjukkan pada persamaan berikut:

$$\hat{f}_t = \sum_{k=1}^m \hat{f}_t^{(k)}, \text{ dimana } t = 1, 2, \dots, n \quad (6)$$

di mana $k = 1$ untuk komponen tren dan $k = 2$ untuk komponen musiman. (Jatmiko, Rahayu, & Darmawan, 2017)

Dekomposisi SSA dari runtun waktu hanya dapat berhasil jika komponen yang berbeda dapat dipisahkan. 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).

2.2 Peramalan SSA

Recurrent Forecasting Method (R-Forecasting) merupakan salah satu metode yang digunakan untuk melakukan peramalan period ke depan dalam SSA dan berkaitan dengan penaksir Linier Recurrent Formula (LRF). Penaksiran koefisien LRF menggunakan vektor eigen yang telah diperoleh pada SVD. Koefisien LRF dari suatu komponen dapat dihitung menggunakan persamaan berikut (Hassani & Mahmoudvand, 2018).

$$\mathbf{r}^{(k)} = (r_{L-1}^{(k)}, \dots, r_1^{(k)}) = \frac{1}{1-v^2} \sum_{i=1}^L \pi_i \mathbf{u}_i^{\nabla}. \quad (7)$$

Hasil peramalan diperoleh berdasarkan persamaan berikut.

$$\hat{f}_t^{(k)} = \begin{cases} \hat{f}_t^{(k)} & \text{ untuk } t = 1, 2, \dots, n \\ \sum_{j=1}^{L-1} r_j^{(k)} \hat{f}_{t-j}^{(k)} & \text{ untuk } t = n + 1, \dots, n + M \end{cases} \quad (8)$$

dengan data runtun waktu yang digunakan adalah hasil rekonstruksi yang diperoleh pada tahap *diagonal averaging*.

2.3 Kelapa Sawit

Tanaman kelapa sawit (*Elaeis Guineensis Jacq*) berasal dari Nigeria, Afrika Barat. Meskipun demikian, ada yang menyatakan bahwa kelapa sawit berasal dari Amerika Selatan, yakni Brazil karena

lebih banyak ditemukan spesies kelapa sawit di hutan Brazil dibandingkan dengan Afrika. Kelapa sawit pertama kali diperkenalkan di Indonesia oleh Pemerintah Kolonial Belanda pada tahun 1848. Ketika itu hanya ada empat batang bibit kelapa sawit yang dibawa dari Réunion atau Mauritius dan Hortus Botanicus Amsterdam yang ditanam di Kebun Raya Bogor (Fauzi, Widyastuti, Satyawibawa, & Hartono, 2002).

Kelapa sawit menjadi populer setelah revolusi industri pada akhir abad ke-19 yang menyebabkan tingginya permintaan minyak nabati untuk bahan pangan dan industri sabun. Kelapa sawit adalah tumbuhan industri/ perkebunan yang berguna sebagai penghasil minyak masak, minyak industri, maupun bahan bakar (Suriani, 2019)

3. Metode Penelitian


Penelitian ini dilakukan dengan mengambil data dari publikasi Badan Pusat Statistika dan Dinas Perkebunan Provinsi Kalimantan Timur. Data yang digunakan pada penelitian ini adalah jumlah produksi kelapa sawit (ton) Provinsi Kalimantan Timur periode Januari 2013 hingga Desember 2020. Langkah-langkah analisis data adalah sebagai berikut.

- i. Membuat grafik runtun jumlah produksi kelapa sawit Provinsi Kalimantan Timur periode Januari 2013 sampai dengan Desember 2020.
- ii. Membagi data menjadi data *in-sample* dan data *out-sample*. Data *in-sample* adalah data bulanan jumlah produksi kelapa sawit Provinsi Kalimantan Timur periode Januari 2013 sampai dengan Desember 2019 dan data *out-sample* adalah data bulanan jumlah produksi kelapa sawit Provinsi Kalimantan Timur periode Januari sampai dengan Desember 2020. Data *in-sample* digunakan untuk membentuk model peramalan sedangkan data *out-sample* digunakan untuk memvalidasi hasil peramalan.
- iii. Menerapkan algoritma metode SSA pada data *in-sample* dengan tahapan sebagai berikut.
 - a. Melakukan proses dekomposisi yang terdiri atas dua tahapan yaitu tahap *embedding* dan *Singular Value Decomposition* (SVD).
 - b. Melakukan proses rekonstruksi yang terdiri atas tahap *grouping* dan dilanjutkan dengan membentuk runtun rekonstruksi yang diperoleh melalui *diagonal averaging*.
 - c. Melakukan prediksi dan peramalan dengan model SSA.
 - d. Membuat grafik perbandingan antara data bulanan jumlah produksi kelapa sawit Provinsi Kalimantan Timur dengan data hasil prediksi dan peramalan menggunakan model SSA periode Januari 2013 sampai dengan Desember 2021.
 - e. Menghitung tingkat akurasi peramalan berdasarkan MAPE dari model SSA.

4. Hasil dan Pembahasan

Langkah awal dalam pemodelan dan peramalan menggunakan SSA adalah membuat grafik runtun waktu data. Grafik runtun waktu jumlah produksi kelapa sawit Provinsi Kalimantan Timur periode Januari 2013 hingga Desember 2020 disajikan pada Gambar 1.

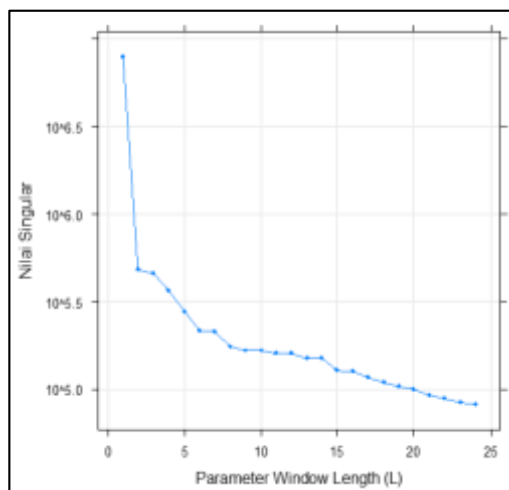
Jumlah produksi kelapa sawit Provinsi Kalimantan Timur periode Januari 2013 hingga Desember 2020 cenderung mengalami kenaikan dari tahun ke tahun. Tren naik yang cukup terlihat terjadi pada tahun 2016 hingga 2020. Jumlah produksi kelapa sawit terkecil terlihat pada nilai minimum sebesar 91.945 ton terjadi pada Januari 2014 dan jumlah produksi kelapa sawit terbesar terlihat pada nilai maksimum sebesar 36.784 ton terjadi pada Juli 2019. Rata-rata jumlah produksi kepala sawit Provinsi Kalimantan periode Januari 2013 hingga Desember 2020 adalah 217.856,50 ton dengan besarnya persebaran data terhadap rata-ratanya adalah sebesar 92.618,35 ton.



Gambar 1. Grafik runtun waktu jumlah produksi kelapa sawit Provinsi Kalimantan Timur periode Januari 2013 hingga Desember 2020

Data yang digunakan pada penelitian ini dibagi menjadi dua yaitu data *in-sample* dan data *out-sample*. Data *in-sample* yaitu jumlah produksi kelapa sawit Provinsi Kalimantan Timur periode Januari 2013 hingga Desember 2019, sedangkan data *out-sampel* yaitu jumlah produksi kelapa sawit Provinsi Kalimantan Timur periode Januari 2020 hingga Desember 2020.

Pemodelan SSA akan dilakukan pada data *in-sample*. Tahap dekomposisi terbagi atas dua yaitu *embedding* dan *singular value decomposition* (SVD). Parameter L yang terpilih dari $2 < L < 42$ adalah 24 karena memiliki MAPE yang terkecil sebesar 0,464% dan memiliki ketiga komponen yaitu tren, musiman, dan *noise*. Nilai K adalah 61 dan dihasilkan matriks lintasan \mathbf{X} yang berukuran 24×61 . Dari matriks lintasan \mathbf{X} selanjutnya akan dibentuk matriks \mathbf{S} berukuran 24×24 dan akan dihasilkan *eigentriple* yang terdiri dari nilai eigen (λ_i), vektor eigen (\mathbf{u}_i), dan komponen utama (\mathbf{v}_i). Banyaknya *eigentriple* yang terbentuk adalah 24. Tahap selanjutnya adalah rekonstruksi yang terdiri atas dua tahap yaitu *grouping* dan *diagonal averaging*.



Gambar 2. Grafik nilai singular

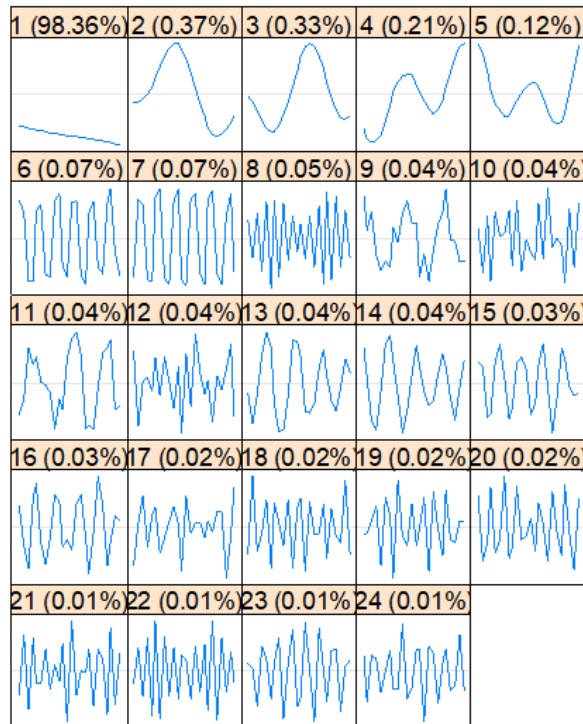
Gambar 2 menunjukkan adanya penurunan nilai singular secara lambat ketika L bernilai 6 menuju 7, 15 menuju 16 dan 23 menuju 24. Hal tersebut biasanya menunjukkan komponen *noise* dari runtun waktu.

Eigentruple yang memiliki kesamaan karakteristik akan membentuk grafik yang mirip antara vektor eigen yang satu dengan vektor eigen yang lain dan nilai persentase antara suatu vektor eigen dengan vektor eigen yang lain tidak jauh berbeda. Maka berdasarkan Gambar 3, *eigentruple* 1 dikelompokkan ke dalam komponen tren karena grafik bervariasi secara lambat. *Eigentruple* 2 hingga 16 dan *eigentruple* 18 hingga 24 dikelompokkan ke dalam komponen musiman karena ada kecenderungan membentuk pola yang berulang, sedangkan *eigentruple* 17 dikelompokkan ke dalam komponen *noise*.

Pada tahap *diagonal averaging* masing-masing komponen akan direkonstruksi oleh masing-masing *eigentruple* yang terkait dengan membentuk matriks $Y^{(k)}$ berukuran 24×61 dengan elemen $y_{ij}^{(k)}$ yang merupakan runtun hasil pengelompokkan di mana $i = 1, 2, \dots, 24$, $j = 1, 2, \dots, 61$ dan $k = 1$ untuk komponen tren, $k = 2$ untuk komponen musiman dan $k = 3$ untuk komponen *noise*.


Tabel 1 Pengelompokkan *Eigentruple*

Kelompok	<i>Eigentruple</i>
Tren	1
Musiman	2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 18, 19, 20, 21, 22, 23, dan 24
Noise	17



Gambar 3. Grafik Vektor Eigen

Runtun waktu untuk masing-masing komponen yang telah terbentuk selanjutnya akan diperiksa keterpisahan *eigentruple*-nya dengan menggunakan korelasi terboboti (*w-correlation*). Berikut hasil perhitungan korelasi terboboti (*w-correlation*) yang disajikan Gambar 3.



Gambar 4. Matrik korelasi terboboti

Komponen tren memberikan warna putih dan memiliki koefisien korelasi 0,004 sehingga dapat dikatakan bahwa antara kedua komponen tersebut dapat dipisahkan. Hal yang sama terdapat pada komponen tren dan *noise* yang memiliki koefisien korelasi 0,000 sehingga kedua komponen tersebut dapat dipisahkan. Komponen musiman dan *noise* memberikan warna abu-abu dengan koefisien korelasi sebesar 0,319 yang dapat dikatakan bahwa korelasinya masih kurang kuat sehingga kedua komponen tersebut masih dapat dipisahkan.

Langkah selanjutnya adalah menghitung nilai prediksi jumlah produksi kelapa sawit (in-sample) dengan menjumlahkan hasil rekonstruksi tiap komponen yaitu komponen tren dan komponen musiman berdasarkan Persamaan (5) dan (6) yang merupakan hasil *diagonal averaging*.

Tabel 2. Hasil Rekonstruksi dan *Diagonal Averaging*

<i>t</i>	Komponen yang Direkonstruksi		<i>Diagonal Averaging</i>
	Tren	Musiman	
1	88.958,18	20.737,69	109.695,87
2	89.575,60	19.511,20	109.086,80
3	90.519,41	13.943,89	104.463,30
4	91.564,19	10.360,45	101.924,63
5	92.833,69	5.255,48	98.089,17
6	94.226,24	37.713,80	131.940,03
7	95.588,43	21.229,96	116.818,39
8	96.907,39	24.720,53	121.627,92
9	98.301,94	9.747,15	108.049,10
10	99.792,88	19.657,21	119.450,09
.	.	.	.
.	.	.	.
.	.	.	.
83	386.042,12	-35.668,46	350.373,66
84	391.316,82	-47.504,15	343.812,66

Pemodelan SSA dilakukan untuk memperoleh peramalan 24 periode berikutnya yaitu periode Januari 2020 hingga Desember 2021 dari jumlah produksi kelapa sawit Provinsi Kalimantan Timur. Metode yang digunakan adalah *R-forecasting* dimana memerlukan penaksiran koefisien LRF, $r_j^{(k)}$, $j = 1, 2, \dots, 23$ dan $k = 1, 2, 3$ merupakan komponen hasil rekonstruksi. Komponen LRF dihitung untuk masing-masing komponen yang terbentuk. Berdasarkan persamaan (7), berikut koefisien LRF untuk komponen tren dan musiman adalah sebagai berikut.

$$r^{(1)} = \begin{pmatrix} 0,041 \\ 0,042 \\ 0,043 \\ \vdots \\ 0,063 \end{pmatrix}_{(23 \times 1)} \quad \text{dan} \quad r^{(2)} = \begin{pmatrix} 0,457 \\ -0,287 \\ -0,742 \\ \vdots \\ -0,176 \end{pmatrix}_{(23 \times 1)}$$

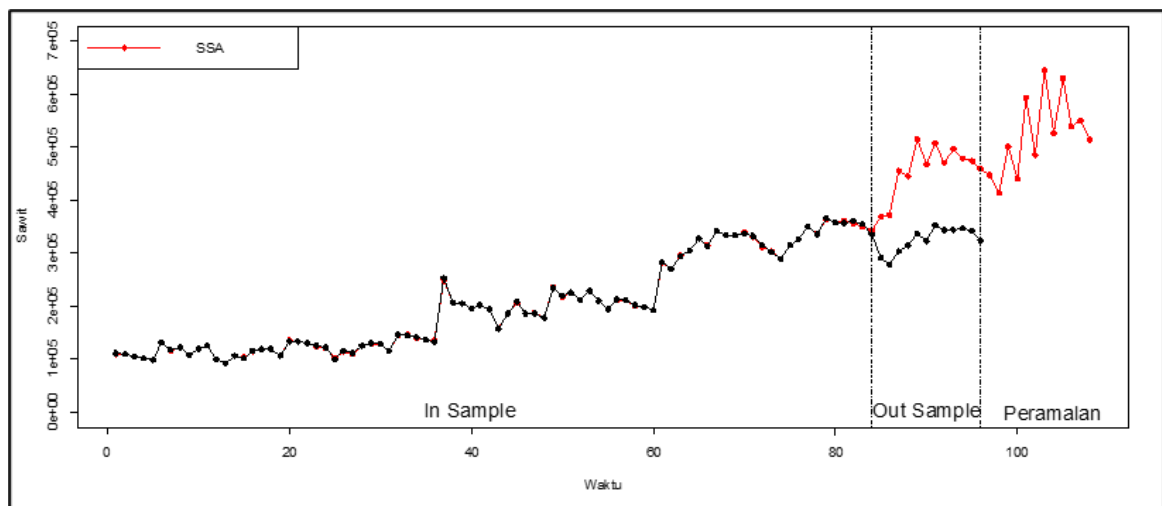
Koefisien LRF digunakan untuk membentuk model peramalan. Model peramalan runtun waktu komponen tren dan musiman data bulanan jumlah produksi kelapa sawit Provinsi Kalimantan Timur untuk 24 periode berikutnya, yaitu periode Januari 2020 hingga Desember 2021 berdasarkan Persamaan (8).

Peramalan runtun waktu komponen tren dan komponen musiman dihitung berdasarkan model yang telah diperoleh yang kemudian dijumlahkan untuk memperoleh nilai peramalan jumlah produksi kelapa sawit bulanan Provinsi Kalimantan Timur dari Januari 2020 hingga Desember 2021 dan berikut hasil peramalannya.

Tabel 3. Hasil Peramalan Jumlah Produksi Kelapa Sawit Bulanan Provinsi Kelapa Sawit Periode Januari 2020 Hingga Desember 2021

t	Waktu	Peramalan Berdasarkan Komponen		Hasil Peramalan SSA (ton)
		Tren	Musiman	
85	Januari 2020	398.549,62	-28.829,21	369.720,40
86	Februari 2020	405.628,80	-34.168,36	371.460,44
87	Maret 2020	412.791,62	41.971,08	454.762,70
88	April 2020	420.037,96	25.814,91	445.852,87
89	Mei 2020	427.369,78	88.135,51	515.505,29
90	Juni 2020	434.792,60	32.670,29	467.462,89
91	Juli 2020	442.309,58	65.604,02	507.913,60
92	Agustus 2020	449.932,83	20.840,91	470.773,74
93	September 2020	457.671,34	38.355,05	496.026,39
94	Oktober 2020	465.532,58	13.417,05	478.949,63
95	November 2020	473.528,60	145,92	473.674,52
96	Desember 2020	481.671,04	-21.912,09	459.758,94
97	Januari 2021	489.967,90	-43.050,62	446.917,28
98	Februari 2021	498.416,34	-85.230,58	413.185,76

99	Maret 2021	507.007,24	-6.631,323	500.375,92
100	April 2021	515.735,24	-74.779,26	440.955,98
101	Mei 2021	524.598,70	68.784,914	593.383,62
102	Juni 2021	533.600,76	-48.545,63	485.055,13
103	Juli 2021	542.736,99	100.741,63	643.478,62
104	Agustus 2021	552.025,44	-25.024,35	527.001,09
105	September 2021	561.476,89	68.542,256	630.019,15
106	Oktober 2021	571.099,22	-32.352,40	538.746,81
107	November 2021	580.912,43	-30.175,50	550.736,93
108	Desember 2021	590.949,12	-76.578,48	514.370,64



Gambar 5 Grafik runtun waktu hasil peramalan dan data aktual jumlah produksi kelapa sawit Provinsi Kalimantan Timur

Gambar 5 menunjukkan bahwa titik-titik data hasil prediksi jumlah produksi kelapa sawit periode Januari 2013 hingga Desember 2019 dengan data data aktual (*in-sample*) hampir berhimpit dan menghasilkan MAPE sebesar 0,464%. Sedangkan titik-titik data hasil peramalan jumlah produksi kelapa sawit periode Januari 2020 hingga Desember 2020 dengan data aktualnya (*out-sample*) memiliki jarak yang cukup jauh dan menghasilkan MAPE sebesar 41,172%. Nilai ramalan jumlah produksi kelapa sawit Provinsi Kalimantan Timur untuk tahun 2021 adalah sebesar 6.284.226,92 ton dan cenderung mengalami kenaikan dari tahun-tahun sebelumnya. Nilai MAPE untuk data aktual (*out-sample*) dengan nilai peramalan belum cukup baik. Pola data *out-sample* mengalami kecenderungan menurun sedangkan pola pada data *in-sample* cenderung mengalami kenaikan sehingga model yang dibentuk berdasarkan data *in-sample* tidak cukup baik digunakan untuk meramalkan jumlah produksi kelapa sawit 24 periode ke depan

5. Kesimpulan

Berdasarkan hasil dan pembahasan pada penelitian ini diperoleh kesimpulan bahwa peramalan jumlah produksi kelapa sawit Provinsi Kalimantan Timur periode Januari 2013 hingga Desember 2019 (*in-sample*) menggunakan metode SSA dengan $L = 24$ menghasilkan nilai MAPE hanya sebesar 0,464% namun, hasil peramalan jumlah produksi kelapa sawit Provinsi Kalimantan Timur untuk 12 periode ke depan yaitu periode Januari 2020 hingga Desember 2020 (*out-sample*) menggunakan metode *R-forecasting* SSA menghasilkan nilai MAPE yang cukup besar yaitu 41,172%. Hal tersebut menunjukkan bahwa metode peramalan SSA yang terbentuk dan metode *R-forecasting* belum cukup baik digunakan untuk meramalkan jumlah produksi kelapa sawit Provinsi Kalimantan Timur untuk periode ke depan yaitu Januari 2021 hingga Desember 2021.

6. Ucapan Terima Kasih

Ucapan terima kasih diberikan kepada Fakultas Matematika dan Ilmu Pengetahuan Alam yang telah memberikan bantuan dana penelitian

References

- Dinas Perkebunan Provinsi Kalimantan Timur. (2020). Statistik Perkebunan Kalimantan Timur 2019. Samarinda: Dinas Perkebunan Provinsi Kalimantan Timur.
- Fauzi, Y., Widyastuti, Y., Satyawibawa, I., & Hartono, R. (2002). Kelapa Sawit, Budidaya, Pemanfaatan Hasil dan Limbah Analisa, Usaha dan Pemasaran (Edisi Revisi). Jakarta: Penebar Swadaya.
- Golyandina, N., & Zhigljavsky, A. (2013). Singular Spectrum Analysis for Time Series. New York: Springer.
- Golyandina, N., Nekrutkin, V., & Zhigljavsky, A. A. (2001). Analysis of Time Series Structure: SSA and Related Techniques. Boca Raton: Chapman&Hall/CRC.
- Hassani, H., & Mahmoudvand, R. (2018). Singular Spectrum Analysis With R. London: Palgrave Macmillan UK.
- 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 (pp. 58-60). Purworejo: Pendidikan Matematika Universitas Muhammadiyah Purworejo.
- 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), 13-22.
- Khaeri, H., Yulian, E., & Darmawan, G. (2018). Penerapan Metode Singular Spectrum Analysis (SSA) Pada Peramalan Jumlah Penumpang Kereta Api di Indonesia Tahun 2017. Jurnal Euclid, 5(1), 9-11.
- Satriani, Nursalam, & Iknas, R. (2020). Peramalan Indeks Harga Konsumen (IHK) di Sulawesi Selatan dengan Menggunakan Metode Singula Spectrum Analysis (SSA). Jurnal Matematika dan Statistika serta Aplikasinya, 8(1), 81-89.
- Siregar, R. S., Prariesa, D., & Darmawan, G. (2017). Aplikasi Metode Singular Spectral Analysis (SSA) dalam Peramalan Pertumbuhan Ekonomi Indonesia Tahun 2017. Jurnal Matematika, 3(1), 1-14.
- Suriani, N. (2019). Budi Daya Tanaman Kelapa Sawit. Jakarta: Bhuana Ilmu Komputer (Kelompok Gramedia).
- Zhang, Q., Wang, B.-D., He, B., Peng, Y., & Ren, M.-L. (2011). Singular Spectrum Analysis and ARIMA Hybrid Model for Annual Runoff Forecasting. Water Resource Manage, 25(11), 2683-2703.

Zhigljavsky, A. (2010). Singular Spectrum Analysis for Time Series: Introduction to This Special Issue. *Statistics and Its Interface*, 3, 255-258..