

PERAMALAN PRODUK DOMESTIK BRUTO (PDB) SEKTOR PERTANIAN, KEHUTANAN, DAN PERIKANAN MENGGUNAKAN *SINGULAR SPECTRUM ANALYSIS* (SSA)

Desy Tresnowati Hardi¹, Diah Safitri², Agus Rusgiyono³

^{1,2,3} Departemen Statistika FSM Universitas Diponegoro

e-mail : desyhrd69@gmail.com

ABSTRACT

Forecasting is the process of estimating conditions in the future by testing conditions from the past. One of the forecasting methods is Singular Spectrum Analysis (SSA) which aim of SSA is to make a decomposition of the original series into the sum of a small number of independent and interpretable components such as a slowly varying trend, oscillatory components and a structureless noise. Gross Domestic Product data in the agriculture, forestry, and fisheries sector are time series data with trend and seasonal pattern so that it can be processed using the SSA method. The forecasting process of SSA method uses the main parameter (L) of 21 obtained by the Blind Source Separation (BSS) method. From forecasting, acquired group of 3 groups. Forecasting resulted the value of Mean Absolute Percentage Error (MAPE) is 1.59% and the value of tracking signal is 2.50, which indicates that the results of forecasting is accurate.

Keywords: Forecasting, Gross Domestic Product in the agriculture, forestry, and fisheries sector, Singular Spectrum Analysis (SSA)

1 PENDAHULUAN

Perekonomian suatu negara dapat dilihat dari semakin kuatnya atau semakin tingginya pertumbuhan ekonomi negara yang bersangkutan. Dengan pertumbuhan ekonomi yang semakin membaik akan membawa dampak positif bagi perkembangan perekonomian khususnya bagi sektor-sektor perekonomian yang berhubungan dengan pendapatan nasional. Pertumbuhan ekonomi suatu negara biasanya diukur dengan mempergunakan data tentang Produk Domestik Bruto (GDP) yang mengukur pendapatan total setiap orang dalam perekonomian di negara tersebut (Firdaus, 2012).

Menurut catatan Badan Pusat Statistik (BPS), yang dikutip dalam berita *online* Kompas.com, seluruh lapangan usaha tumbuh positif sepanjang kuartal II 2018. Pertumbuhan tertinggi ditempati oleh sektor pertanian, kehutanan, dan perikanan dengan angka pertumbuhan 9,93% dibandingkan kuartal I 2018. Hal tersebut disebabkan oleh meningkatnya produksi seiring berlangsungnya masa panen raya untuk beberapa komoditas di beberapa subsektor seperti hortikultura dan perkebunan dengan pertumbuhan masing-masing sebesar 22,86% dan 26,73% (Budi, 2018).

Dalam kutipan berita *online* Republika.co.id, Wakil Ketua Komisi IV DPR RI, Viva Yoga Mulyadi, meyakini pengembangan sektor pertanian saat ini didukung program Kementerian Pertanian (Kementan) menjadi sektor terkuat dalam mendukung tercapainya agenda prioritas Nawa Cita pemerintahan Jokowi – JK. Kebijakan strategis Kementerian Pertanian yang tertuju pada terjemahan program Nawa Cita adalah meningkatkan produksi komoditas strategis yang menguasai hajat hidup masyarakat, antara lain membenahi infrastruktur irigasi, hingga mulai mengarah ke pemanfaatan teknologi pertanian sehingga menciptakan adanya peningkatan produksi pangan (Ismail, 2018).

Berdasarkan penjelasan yang sudah dijelaskan, peneliti tertarik untuk meramalkan Produk Domestik Bruto (PDB) sektor pertanian, kehutanan, dan perikanan. Peramalan PDB sektor pertanian, kehutanan, dan perikanan sudah pernah dilakukan oleh Romzi *et al.* (2010)

dengan *seasonal adjustment* yang dilakukan dengan menggunakan metode X-12-ARIMA. Pada penelitian ini, peneliti ingin melakukan peramalan dengan menggunakan metode *Singular Spectrum Analysis* (SSA) karena setelah dilakukan identifikasi awal, data PDB sektor pertanian, kehutanan, dan perikanan memiliki struktur (pola) trend dan musiman, sehingga peramalan dapat dilakukan dengan menggunakan metode *Singular Spectrum Analysis* (SSA).

Menurut Golyandina *et al.* (2001), metode SSA dapat digunakan untuk data yang memiliki struktur. SSA merupakan teknik analisis runtun waktu yang menggabungkan unsur-unsur deret waktu klasik, statistik multivariat, *multivariate geometry*, sistem dinamis, dan pemrosesan sinyal. Metode SSA bertujuan mendekomposisi data runtun waktu menjadi jumlah sejumlah komponen kecil yang dapat diinterpretasi seperti trend yang berubah-ubah secara perlahan, *oscillatory components*, dan tanpa struktur. Keunggulan dari SSA adalah terlihat lebih fleksibel dan mampu memodelkan musiman dengan waktu multi periode dan musiman yang kompleks.

Oleh karena itu, peneliti memberi judul penelitian “Peramalan Produk Domestik Bruto (PDB) Sektor Pertanian, Kehutanan, dan Perikanan menggunakan *Singular Spectrum Analysis* (SSA)”.

2 TINJAUAN PUSTAKA

2.1 Produk Domestik Bruto

Menurut Tambunan (2001), Produk Domestik Bruto adalah nilai total atas segenap output akhir yang dihasilkan suatu perekonomian (baik yang dilakukan penduduk lokal maupun orang-orang dari negara lain yang bermukim di negara bersangkutan). Tujuan PDB adalah meringkas aktivitas ekonomi dalam suatu nilai uang tertentu selama periode waktu tertentu. PDB merupakan cerminan dari kinerja ekonomi (Mankiw, 2006). Salah satu sektor PDB ialah pertanian, kehutanan, dan perikanan. Sub-sektor dari pertanian, kehutanan, dan perikanan antara lain:

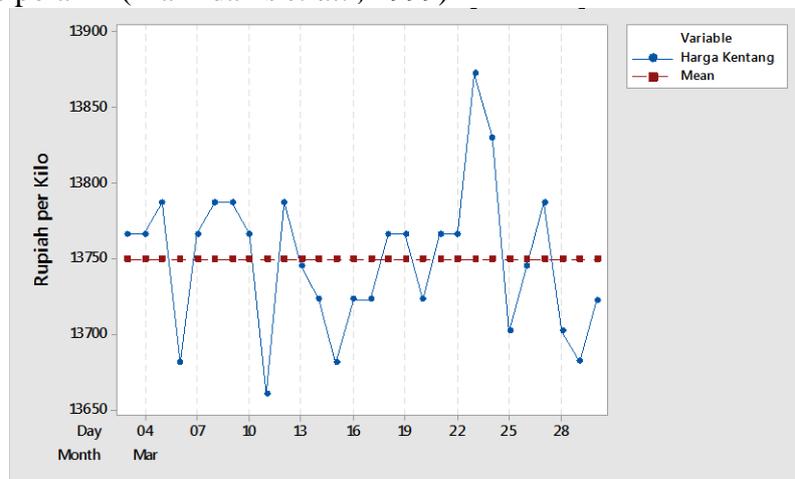
1. Pertanian, Peternakan, Perburuan dan Jasa Pertanian
2. Kehutanan dan Penebangan Kayu
3. Perikanan

2.2 Plot Data Runtun Waktu

Plot data dapat dibedakan menjadi:

1. Plot Horizontal

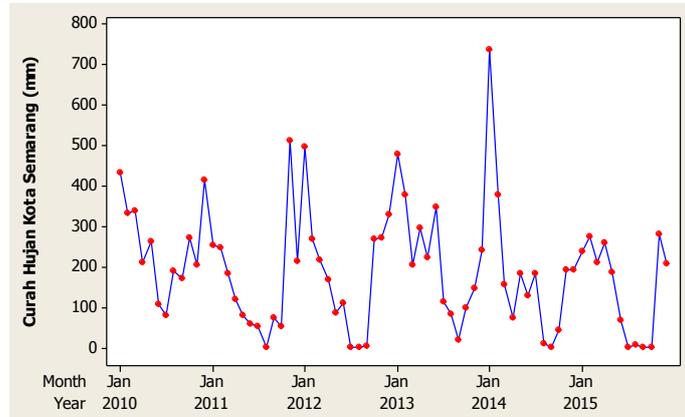
Pola ini terjadi bilamana data berfluktuasi di sekitar rata-rata yang konstan. Suatu produk yang suatu produk yang penjualannya tidak meningkat atau menurun selama waktu tertentu termasuk jenis pola ini (Makridakis *et al.* , 1999)



Gambar 1. Pola Data Horizontal

2. Plot Musiman

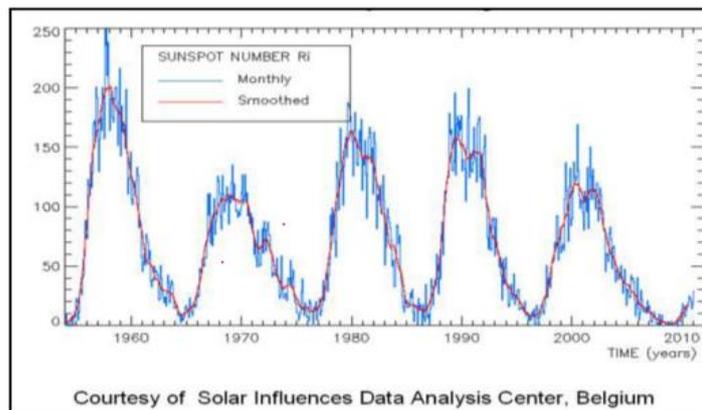
Pola data ini terjadi jika terdapat suatu deret data yang dipengaruhi oleh faktor musiman (misalnya kuartal tahun tertentu, bulanan, atau hari-hari pada minggu tertentu) (Makridakis *et al.*, 1999).



Gambar 2. Pola Data Musiman

3. Plot Siklis

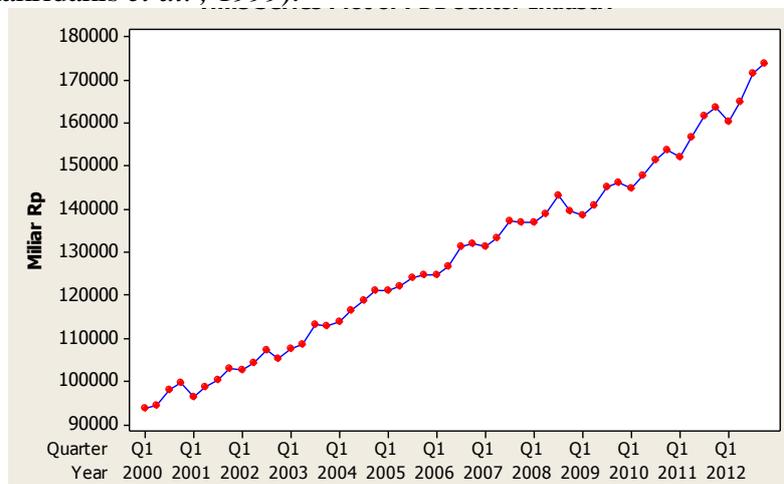
Pola data ini terjadi jika terdapat data yang dipengaruhi oleh fluktuasi ekonomi jangka panjang seperti yang berhubungan dengan siklus bisnis (Makridakis *et al.*, 1999).



Gambar 3. Pola Data Siklis

4. Plot Trend

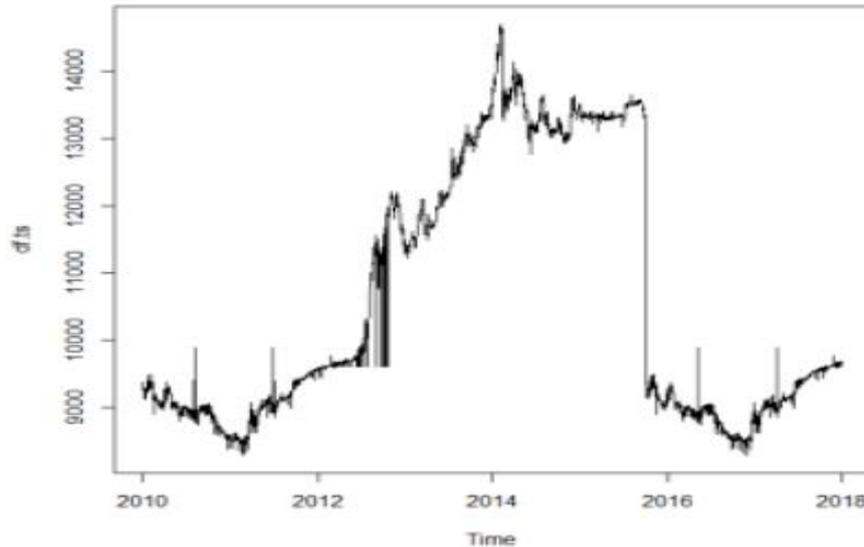
Pola data trend terjadi jika terdapat kenaikan atau penurunan sekuler jangka panjang dalam data (Makridakis *et al.*, 1999).



Gambar 4. Pola Data Trend

5. Plot Random

Menurut Arsyad (2001), pola random ialah pola acak yang tidak teratur, sehingga tidak dapat digambarkan. Pola acak ini disebabkan oleh peristiwa yang tak terduga seperti perang, bencana alam, kerusuhan, dan lain-lain.



Gambar 5. Pola Data Random

2.3 Penyamaan Tahun Dasar (*Backasting*)

Prinsip dari penyamaan tahun dasar ini adalah menyamakan nilai dasar pada seluruh data *time series*. Tujuannya agar diperoleh hasil estimasi yang baik sehingga hasil analisisnya lebih representatif (Romzi, *et al.*, 2010).

Backcast PDB triwulanan

$$x_{i-1,j,n} = \frac{x_{i-1,j,m}}{x_{i,j,m}} \cdot x_{i,j,n} \quad (1)$$

dengan n adalah tahun dasar baru, m adalah tahun dasar sebelum tahun dasar n, j adalah triwulan atau bulan, sedangkan i-1 adalah tahun yang disesuaikan tahun dasarnya.

2.4 Metode *Singular Spectrum Analysis* (SSA)

2.4.1 *Window Length* (L)

Window length (L) adalah parameter utama dalam SSA (Golyandina *et al.*, 2001). Menurut Wang *et al.* (2015), teori untuk menentukan nilai L, salah satunya adalah teori *Blind Source Separation* (BSS). Langkah-langkah menghitung nilai L dengan menggunakan BSS adalah sebagai berikut:

1. Menghitung nilai *autocorrelation function* (ACF) dimana lag berada pada interval

$$\left[20, \frac{N}{2} \right].$$

$$R_{xx}(\tau) = \frac{\sum_{i=1}^{N-L+1} (f_{i+\tau} - \bar{f})(f_i - \bar{f})}{\sum_{i=1}^{N-L} (f_i - \bar{f})^2} \quad \tau: 20, \dots, L-1 \quad (2)$$

Analisis lag dilakukan dengan memilih lag yang memiliki nilai ACF yang paling besar dan lag yang memiliki nilai ACF yang paling kecil. Hal yang perlu dipertimbangkan sebelum menentukan nilai-nilai minimum dan maksimum R_{xx} adalah mengambil nilai ACF yang positif pada setiap lag τ .

2. Menghitung nilai L

$$L = \left\lfloor \frac{\tau(R_{xx(max)}) + \tau(R_{xx(min)})}{2} \right\rfloor = \lfloor Z \rfloor \quad (3)$$

$\tau(R_{xx(max)})$: lag dengan nilai R_{xx} positif terbesar

$\tau(R_{xx(min)})$: lag dengan nilai R_{xx} positif terkecil

$\lfloor \cdot \rfloor$: bilangan bulat terbesar yang $\leq Z$

Jika τ_{min} mendekati τ_{max} , maka $L = \tau(R_{xx(min)})$

2.4.2 Dekomposisi

a. Embedding

Menurut Golyandina *et al.* (2001), *embedding* dapat dikatakan sebagai tahap mengubah data runtun waktu yang berdimensi satu $F = (f_0, \dots, f_{N-1})$ menjadi data runtun waktu multidimensi yang disebut dengan matriks lintasan (\mathbf{X}). Matriks lintasan ini berukuran $L \times K$, dimana L didapat dari tahap sebelumnya (metode BSS) dan $K = N - L + 1$

$$\mathbf{X} = (x_{ij})_{i,j=1}^{L,K} = \begin{bmatrix} f_0 & f_1 & f_2 & \cdots & f_{K-1} \\ f_1 & f_2 & f_3 & \cdots & f_K \\ f_2 & f_3 & f_4 & \cdots & f_{K+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ f_{L-1} & f_L & f_{L+1} & \cdots & f_{N-1} \end{bmatrix} \quad (4)$$

b. Singular Value Decomposition (SVD)

Dalam Golyandina *et al.* (2001), dekomposisi nilai singular matriks \mathbf{X} adalah faktorisasi

$$\mathbf{X}_i^*_{(L \times K)} = \sqrt{\lambda_i}_{(1 \times 1)} \cdot \mathbf{u}_i_{(L \times 1)} \cdot \mathbf{v}_i^T_{(1 \times K)} \quad (5)$$

$$i = 1, 2, \dots, L$$

Matriks \mathbf{X} akan diubah menjadi \mathbf{X}_i^*

Tahap SVD menghasilkan *eigen triple*, yaitu $(\sqrt{\lambda_i}, \mathbf{u}_i, \mathbf{v}_i)$. Nilai eigen $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L > 0$ didapat dari perkalian matriks $\mathbf{S} = \mathbf{X} \cdot \mathbf{X}^T$. Nilai singular dinotasikan dengan $\sqrt{\lambda_i}$ dan vektor eigen dinotasikan sebagai dengan $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_L$. Nilai komponen utama didapat dari Persamaan 6.

$$\mathbf{v}_{i(K \times 1)} = \frac{\mathbf{X}^T_{(K \times L)} \cdot \mathbf{u}_{i(L \times 1)}}{\sqrt{\lambda_i}_{(1 \times 1)}} \quad (6)$$

2.4.3 Rekonstruksi

a. Pengelompokan

Misal matriks \mathbf{X}^* akan dipartisi ke m disjoint subset I_1, \dots, I_m . Asumsikan $m = 2$, $I_1 = I = \{i_1, \dots, i_r\}$ dan $I_2 = \{1, \dots, d\} \setminus I$, dimana $1 \leq i_1 < \dots < i_r \leq d$. Tujuan dari langkah pengelompokan ini adalah untuk memisahkan komponen aditif dari runtun waktu. Diketahui F merupakan jumlahan dari $F^{(1)}$ dan $F^{(2)}$. $F^{(1)}$ dan $F^{(2)}$ dikatakan terpisah secara lemah oleh dekomposisi, jika ada kelompok yang mengindikasikan $I \subset \{1, \dots, d\}$ dimana $\mathbf{X}^{(1)} = \sum_{i \in I} \mathbf{X}_i$ maka $\mathbf{X}^{(2)} = \sum_{i \notin I} \mathbf{X}_i$ (Golyandina *et al.*, 2001).

Menurut Khaeri *et al.* (2017), pengelompokan dapat dilakukan dengan menganalisis plot tapi sifatnya sangat subjektif. Untuk mengatasi hal tersebut, dilakukan perhitungan nilai periode dari setiap vektor eigen, kemudian periodesitas yang berdekatan terindikasi berada pada kelompok yang sama.

b. *Diagonal Averaging*

Dalam Golyandina *et al.* (2001), langkah ini akan mengubah matriks hasil dekomposisi, yang telah dikelompokkan menjadi deret yang baru dengan panjang N-1. Jika $\mathbf{X}_{L_m}^*$ adalah matriks $L \times K$ dengan elemen y_{ij} dengan $1 \leq i \leq L$, $1 \leq j \leq K$, $L^* = \min(L, K)$, $K^* = \max(L, K)$, $N = L + K - 1$, $y_{ij}^* = y_{ij}$; untuk $L < K$, dan $y_{ij}^* = y_{ji}$; untuk lainnya.

$$g_k = \begin{cases} \frac{1}{k+1} \sum_{m=1}^{k+1} y_{m,k-m+2}^* & \text{untuk } 0 \leq k < L^* - 1 \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m,k-m+2}^* & \text{untuk } L^* - 1 \leq k < K^* \\ \frac{1}{N-k} \sum_{m=k-K^*+2}^{N-K^*+1} y_{m,k-m+2}^* & \text{untuk } K^* \leq k < N \end{cases} \quad (7)$$

2.4.4 Matriks Weighted Correlation

Menurut Golyandina *et al.* (2001), dekomposisi SSA dikatakan berhasil ketika komponen aditif dari hasil pemisahan tidak memiliki korelasi.

$$\rho_{12}^{(w)} = \frac{(F_T^{(1)}, F_T^{(2)})_w}{\|F_T^{(1)}\|_w \|F_T^{(2)}\|_w} \quad (8)$$

$$\begin{aligned} \|F_T^{(a)}\|_w &= \sqrt{(F_T^{(a)}, F_T^{(a)})_w} \\ (F_T^{(a)}, F_T^{(b)})_w &= \sum_{i=0}^{N-1} w_i f_i^{(a)} f_i^{(b)} \\ w_k &= \begin{cases} i+1 & 0 \leq i \leq L^* - 1 \\ L^* & L^* \leq i < K^* \\ N-i & K^* \leq i \leq N-1 \end{cases} \end{aligned}$$

2.4.5 Peramalan Metode Rekuren SSA (R-forecasting)

Menurut Golyandina *et al.* (2001), penaksiran koefisien *Linear Recurrent Formula* (r_1, r_2, \dots, r_d) digunakan vektor eigen yang diperoleh dari langkah SVD. Dengan $\mathbf{U} = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_L)^T$, $\mathbf{U}^{\bar{v}} = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_{L-1})^T$, serta komponen terakhir dari vektor eigen \mathbf{U} ($\pi_i = \mathbf{u}_L$) dan $v^2 = \sum_{i=1}^{L-1} \pi_i^2$ maka koefisien LRF (vektor R) dapat dihitung dengan menggunakan Persamaan 9.

$$\mathbf{r} = (r_{L-1}, \dots, r_1)^T = \frac{1}{1-v^2} \sum_{i=1}^{L-1} \pi_i \mathbf{u}_i^{\bar{v}} \quad (9)$$

Peramalan M buah titik baru dapat digunakan dengan menggunakan Persamaan 10.

$$g_i = \begin{cases} g_i & \text{untuk } i = 0, \dots, N - 1 \\ \sum_{j=1}^{L-1} r_j g_{i-j} & \text{untuk } i = N, \dots, N + M - 1 \end{cases} \quad (10)$$

2.5 Keandalan Peramalan (*Tracking Signal*)

Menurut Makridakis *et al.* (1999), *tracking signal* mempunyai nilai yang besar sebagai alat untuk memantau (memonitor) kesalahan peramalan dan menentukan kapan kesalahan tidak bersifat random lagi.

$$\text{Tracking Signal} = \frac{RSFE}{MAD} = \frac{\sum_{i=1}^n (g_i - \hat{g}_i)}{\sum_{i=1}^n |g_i - \hat{g}_i|} \quad (11)$$

n

g_i : nilai observasi; \hat{g}_i : nilai peramalan; n : jumlah data *out sample*

Dalam Jatmiko *et al.* (2017), model peramalan dikatakan baik selama nilai-nilai *tracking signal* berada dalam batas yang dapat diterima, yaitu antara -5 sampai 5

2.6 Mean Absolute Percentage Error

Menurut Hutasuhut *et al.* (2014), *Mean Absolute Percentage Error* (MAPE) merupakan ukuran akurasi dalam peramalan.

$$MAPE = \left(\frac{1}{n} \sum_{i=1}^n \left| \frac{g_i - \hat{g}_i}{g_i} \right| \right) \times 100\% \quad (12)$$

Dalam Anggrainingsih *et al.* (2015), kategori MAPE dibagi menjadi 4 kelompok seperti yang ditunjukkan pada Tabel 1.

Tabel 1. Kategori Nilai MAPE

Nilai MAPE	Akurasi Peramalan
$MAPE \leq 10\%$	Tinggi
$10\% < MAPE \leq 20\%$	Baik
$20\% < MAPE \leq 50\%$	<i>Reasonable</i> / masuk akal
$< MAPE 50\%$	Rendah

3 METODE PENELITIAN

3.1 Sumber Data

Data tersebut merupakan data publikasi yang dikeluarkan oleh Bank Indonesia yang dapat diakses pada situs: <https://www.bi.go.id/id/statistik>. Data yang dipakai merupakan data deret waktu yang dalam penelitian ini dibagi menjadi dua bagian, antara lain:

a. Data *in sample* : Triwulanan I 2000 - Triwulanan IV 2016

b. Data *out sample* : Triwulanan I 2017 - Triwulanan IV 2018

Data memiliki dua tahun dasar, antara lain tahun dasar 2000 dan tahun dasar 2010, dimana triwulanan I tahun 2000 sampai triwulanan III tahun 2014 memiliki tahun dasar 2000 dan triwulanan I tahun 2012 sampai triwulanan IV tahun 2018 memiliki tahun dasar 2010

3.2 Metode Analisis Data

Software yang digunakan untuk menganalisis metode SSA ialah *software* Microsoft Excel 2016, R i386 3.5.2, dan Minitab 18. Langkah-langkah analisis ialah sebagai berikut:

1. Mengganti data yang memiliki tahun dasar 2000 menjadi tahun dasar 2010 (*Backcasting*)
2. Menganalisis plot data untuk mendeteksi struktur data

3. Melakukan tahap dekomposisi, dimana tahap dekomposisi terdiri dari tahap *embedding* dan tahap *Singular Value Decomposition (SVD)*. Pada tahap *embedding* data akan diubah ke dalam bentuk matriks lintasan yang berukuran $L \times K$ dimana L ditentukan dengan metode *Blind Source Separation (BSS)* serta nilai $K = N - L + 1$.
4. Tahap *Singular Value Decomposition (SVD)*, output yang dihasilkan adalah *eigentruple* sebanyak L , *eigentruple* terdiri dari matriks nilai singular ($\sqrt{\lambda_i}$), vektor eigen (\mathbf{u}_i), dan komponen utama (\mathbf{v}_i). Setelah ditemukan *eigentruple*, maka dibentuk matriks \mathbf{X}_i^* baru dengan rumus $\mathbf{X}_i^* = \sqrt{\lambda_i} \mathbf{u}_i \mathbf{v}_i^T$
5. Melakukan tahap rekonstruksi. Pada tahap ini, terdapat dua tahap, yaitu tahap pengelompokan dan tahap *diagonal averaging*.
6. Pada tahap pengelompokan dilakukan pemisahan komponen aditif berdasarkan plot vektor eigen
7. Setelah dilakukan pengelompokan berdasarkan vektor eigen, maka matriks \mathbf{X}_i^* yang sudah didapatkan dalam tahap SVD, dikelompokkan sesuai dengan kategori kelompok yang sudah ditentukan pada tahap pengelompokan sehingga menjadi matriks \mathbf{X}_i^*
8. Tahap *diagonal averaging* mentransformasi matriks \mathbf{X}_i^* menjadi deret baru
9. Menghitung koefisien LRF dan melakukan peramalan data *out sample*
10. Menghitung *Mean Absolute Percentage Error (MAPE)* dan *Tracking Signal*
11. Menghitung peramalan data keseluruhan

4 HASIL DAN PEMBAHASAN

4.1 Penyamaan Tahun Dasar (*Backcasting*)

Tabel 2 merupakan hasil perhitungan *backcasting* tahun dasar 2010

Tabel 2. Hasil Perhitungan *Backcasting*

	2011	2010	2009	2008	2007	2006
Q1	237221,10	228470,40	220939,75	208944,46	196306,20	200567,99
Q2	255378,52	245362,78	237860,74	231382,60	220760,15	209026,05
Q3	280502,28	272064,18	267621,35	258961,11	250818,66	232666,13
Q4	224517,05	219416,17	210802,14	202456,02	192590,63	188593,66
	2005	2004	2003	2002	2001	2000
Q1	188111,59	188840,86	179482,24	175374,15	172790,82	175983,57
Q2	205680,50	201000,98	194995,91	189178,20	181597,16	169947,06
Q3	226709,80	218523,57	214890,58	205015,43	199704,95	189254,51
Q4	183758,72	174026,30	171993,58	163710,33	154473,59	150538,16

4.2 Menentukan Nilai *Window Length (L)*

Hasil dari perhitungan ACF ditampilkan pada Tabel 3.

Tabel 3. Nilai ACF

20	21	22	23	24	25	26
0.365475	0.046091	-0.038486	0.005846	0.211164	-0.123551	-0.210811
27	28	29	30	31	32	33
-0.158460	0.042015	-0.330854	-0.406293	-0.328374	-0.134072	-0.521943

Nilai ACF positif terbesar yaitu sebesar 0,365475 ada pada lag ke-20 dan lag yang memiliki nilai ACF positif terkecil yaitu sebesar 0,005846, ada pada lag ke-23, Dari hasil pengamatan tersebut, maka menghitung nilai L adalah

$$L = \left\lfloor \frac{\tau(R_{xx(max)}) + \tau(R_{xx(min)})}{2} \right\rfloor$$

$$L = \left\lfloor \frac{20 + 23}{2} \right\rfloor = \lfloor 21,5 \rfloor = 21$$

4.2 Dekomposisi

a. Embedding

Matriks lintasan berukuran $L \times K$, dimana $L = 21$ maka nilai $K = 68 - 21 + 1 = 48$

$$\mathbf{X}_{21 \times 48} = \begin{bmatrix} 175983,57 & 169947,06 & \cdots & 224517,04 \\ 169947,06 & 189254,51 & \cdots & 248019,40 \\ \vdots & \vdots & \ddots & \vdots \\ 188111,59 & 205680,50 & \cdots & 265656,10 \end{bmatrix}$$

b. Singular Value Decomposition (SVD)

1) Nilai eigen dan nilai singular

Tabel 4. Nilai Eigen dan Nilai Singular

Nilai Eigen				
53127380000000	174655900000	155914500000	...	121157500
Nilai Singular				
7288853,19	417918,51	394860,09	...	11007,16

2) Vektor eigen

$$\mathbf{U}_{21 \times 21} = \begin{bmatrix} -0,198842 & 0,266097 & \cdots & 0,111207 \\ -0,200175 & 0,011617 & \cdots & -0,180555 \\ \vdots & \vdots & \ddots & \vdots \\ -0,238312 & 0,345229 & \cdots & -0,099269 \end{bmatrix}$$

Vektor eigen digunakan untuk menentukan kelompok pada tahap pengelompokan sesuai dari plot vektor eigen yang terbentuk.

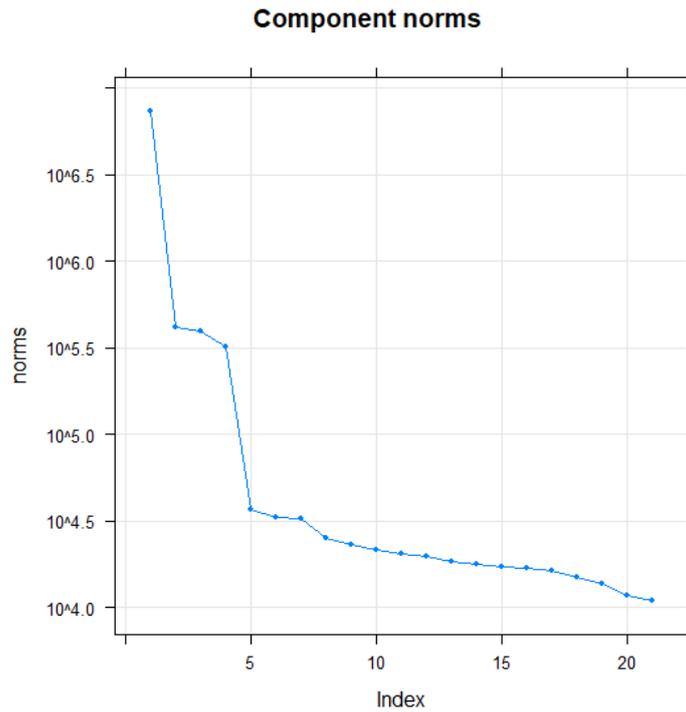
3) Komponen utama

$$\mathbf{V}_{48 \times 21} = \begin{bmatrix} -0,115622 & -0,067365 & \cdots & 0,083516 \\ -0,116550 & 0,105783 & \cdots & -0,085732 \\ \vdots & \vdots & \ddots & \vdots \\ -0,175734 & -0,248660 & \cdots & -0,032228 \end{bmatrix}$$

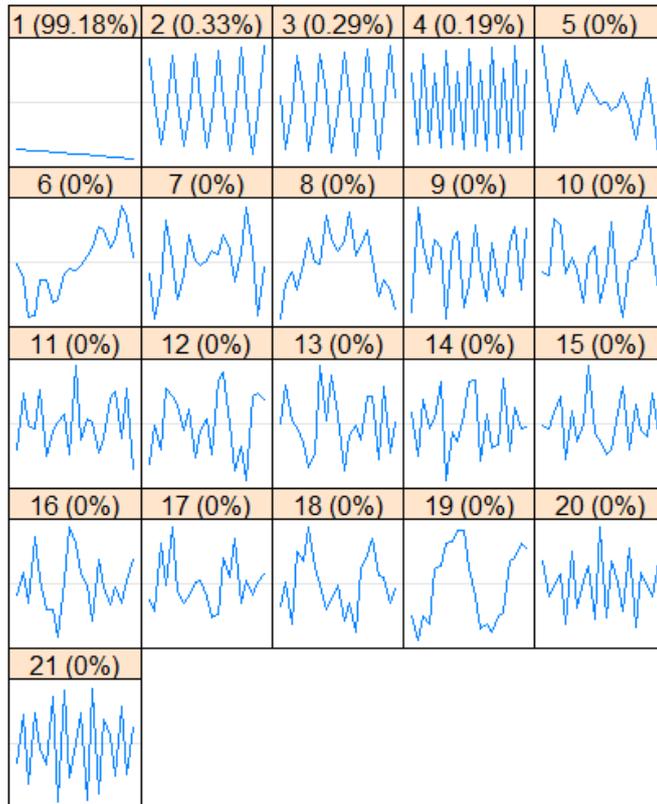
4.4 Rekonstruksi

a. Pengelompokan

Dari nilai singular yang telah didapat, maka dibuat plot. Secara subjektif, dapat dilihat pada Gambar 6 bahwa terdapat 3 patahan kasar, maka dapat disimpulkan bahwa terdapat sekitar 3 kelompok yang dapat terbentuk.

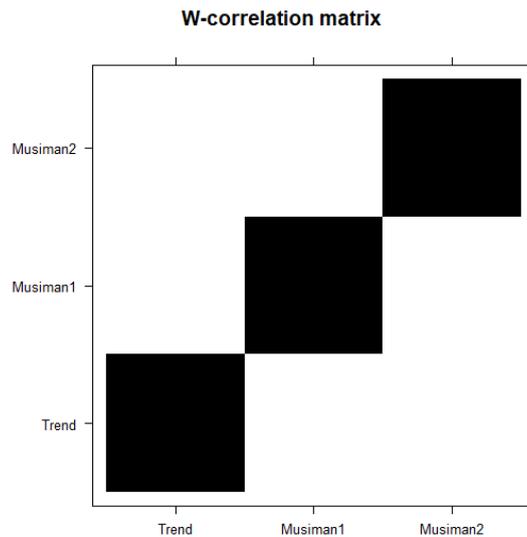


Gambar 6. Plot Nilai Singular
Eigenvectors



Gambar 7. Plot Vektor Eigen

Pengelompokan dapat dilakukan dengan melihat bentuk dari plot vektor eigen pada Gambar 7. Dari Gambar 7 maka dapat dibentuk kelompok Trend (1), Musiman1 (2,3), Musiman2 (4,20,21).



Gambar 8. Matriks w-korelasi

Berdasarkan Gambar 8, terlihat bahwa tidak ada yang memiliki korelasi antar kelompok satu dengan yang lainnya, dibuktikan dengan warna putih pada Gambar 8 di setiap kombinasi kelompok yang dihitung korelasinya.

b. *Diagonal Averaging*

Tahap ini menghasilkan deret baru yaitu pada Tabel 5.

Tabel 5. Hasil *Diagonal Averaging*

Data ke	Trend	Musiman1	Musiman2
0	167574,9	-9581,1	6230,1
1	168808,4	12170,0	-7779,3
2	170627,5	11837,9	8222,6
3	171987,5	-12159,7	-7801,5
4	173458,7	-12304,8	7506,4
5	174930,8	12163,7	-8001,4
⋮	⋮	⋮	⋮
67	305254,2	-34284,3	-6879,6

4.5 Peramalan Data Out Sample

Sebelum dilakukan peramalan, dilakukan perhitungan untuk mendapatkan koefisien LRF. Nilai koefisien LRF yang dihasilkan dapat dilihat pada Tabel 6.

Tabel 6. Nilai koefisien LRF

LRF	Trend	Musiman 1	Musiman 2
r ₂₀	0,050240	0,105837	0,049288
r ₁₉	0,050576	-0,005343	-0,037971
r ₁₈	0,051067	-0,101469	0,011366
r ₁₇	0,051674	-0,026061	0,000670
r ₁₆	0,052034	0,112656	-0,042195
r ₁₅	0,052430	-0,005753	-0,000105
⋮	⋮	⋮	⋮
r ₁	0,059794	-0,020444	-0,080901

Hasil peramalan data *out sample* tertera pada Tabel 7.

Tabel 7. Hasil Peramalan dan Data Aktual

Data Ke-	Trend	Musiman 1	Musiman 2	Data Aktual	Data Ramalan
68	309.185,1	-22.902,35	7.600,956	306.413,60	293.883,67
69	312.038,8	30.428,20	-7.543,539	332.611,70	334.923,48
70	314.915,1	23.555,82	7.686,758	346.839,00	346.157,66
71	317.816,6	-32.075,42	-7.897,931	272.011,20	277.843,26
72	320.750,7	-23.275,31	7.999,034	316.639,30	305.474,45
73	323.706,9	32.986,25	-8.044,009	348.324,80	348.649,09
74	326.684,8	23.900,41	7.938,753	359.525,30	358.523,99
75	329.687,9	-34.734,44	-7.586,101	282.536,30	287.367,35

Berdasarkan data ramalan yang sudah dihasilkan, maka diperoleh MAPE sebesar 1,59%. Dari kategori Tabel 1, nilai MAPE yang dihasilkan termasuk dalam kategori yang memiliki akurasi tinggi. Nilai *tracking signal* yaitu sebesar 2,50. Nilai *tracking signal* sebesar 2,50 sudah dapat dikatakan baik karena berada pada interval -5 sampai 5.

4.6 Peramalan Data Keseluruhan

Dari kelompok yang sudah terbentuk, dilakukan peramalan dengan data keseluruhan sebanyak 8 periode

Tabel 8. Hasil Ramalan

Tahun	Kuartal	Data Hasil Ramalan	Tahun	Kuartal	Data Hasil Ramalan
2019	Q1	320.929,8	2020	Q1	334.130,9
	Q2	366.049,3		Q2	380.922,2
	Q3	368.193,1		Q3	380.760,0
	Q4	296.708,6		Q4	307.036,6

Produk Domestik Bruto sektor pertanian, kehutanan, dan pertanian tahun 2019 mengalami kenaikan dan penurunan, dimana nilai Produk Domestik Bruto terbesar ialah pada triwulanan III yaitu sebesar 368.193,1 miliar rupiah. Pada tahun 2020, yaitu nilai terbesar pada triwulanan II sebesar 38.0922,2 miliar rupiah..

5 KESIMPULAN

5.1 Kesimpulan

Dari proses peramalan yang menggunakan *window length* sebesar 21 serta terbentuk sebanyak 3 kelompok, diperoleh nilai MAPE sebesar 1,59% dan nilai *tracking signal* sebesar 2,50. Berdasarkan dari ketentuan kategori MAPE dan *tracking signal*, keduanya sudah dalam kategori baik sehingga model yang diperoleh dapat menghasilkan peramalan dengan keakuratan tingkat tinggi. Oleh karena itu, metode SSA cocok untuk peramalan data PDB sektor pertanian, kehutanan, dan perikanan.

5.2 Saran

Untuk peneilitan selanjutnya, dapat digunakan metode pengolompokan secara otomatis sehingga dapat menghasilkan model yang optimal untuk peramalannya terutama untuk peramalan menggunakan data dalam skala besar.

DAFTAR PUSTAKA

- Anggrainingsih, R., Aprianto, G. R., Sihwi, S. W. 2015. *Time Series Forecasting Using Exponential Smoothing To Predict The Number of Website Visitor of Sebelas Maret University*. ICITACEE, 14–19.
- Arsyad, L. 2001. *Peramalan Bisnis*. Yogyakarta: BFF-Yogyakarta.

- [BI]. Departemen Statistik Bank Indonesia. *Statistik Ekonomi dan Keuangan Indonesia (SEKI)*:<https://www.bi.go.id/id/statistik/seki/terkini/moneter/Contents/Default.aspx>. Diakses: 16 Januari 2019.
- Budi, K. 2018. *Kinerja Sektor Pertanian Wujud Implementasi Nawacita*. <https://ekonomi.kompas.com/read/2018/08/18/233308026/kinerja-sektor-pertanian-wujud-implementasi-nawacita>. Diakses Januari 19 2019.
- Firdaus. 2012. *Analisis Pendapatan, Pertumbuhan dan Struktur Ekonomi Nasional*. Plano Madani Vol. I, No. 1: Hal 63-73.
- Golyandina, N., Nekrutkin, V., & Zhigljavsky, A. A. 2001. *Analysis of Time Series Structure: SSA and Related Techniques*. New York: CHAPMAN & HALL/CRC.
- Hutasuhut, A. H., Anggraeni, W., & Tyasnurita, R. 2014. *Pembuatan Aplikasi Pendukung Keputusan untuk Peramalan Persediaan Bahan Baku Produksi Plastik Blowing dan Inject Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average) di CV. Asia*. JURNAL TEKNIK POMITS , 1-6.
- Ismail, E. 2018. *DPR: Program Kementan Terkuat Dukung Nawacita Jokowi-JK*. <https://republika.co.id/berita/ekonomi/pertanian/18/08/18/pdnnt4453-dpr-program-kementan-terkuat-dukung-nawacita-jokowijk>. Diakses: 16 Januari 2019.
- Jatmiko, Y. A., Rahayu, R. L., & Darmawan, G. 2017. *Perbandingan Keakuratan Hasil Peramalan Produksi Bawang Merah Metode Holt-Winters dengan Singular Spectrum Analysis*. *Jurnal Matematika "MANTIK"*.
- Khaeri, H., Yulian, E., & Darmawan, G. 2017. *Penerapan Metode Singular Spectrum Analysis (SSA) pada Peramalan Jumlah Penumpang Kereta Api di Indonesia tahun 2017*. *Euclid*, 8.
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. 1999. *Metode dan Aplikasi Peramalan Edisi Kedua Jilid 1*. Jakarta: Erlangga.
- Mankiw, N. G. 2006. *Makroekonomi*. Jakarta: Erlangga.
- Romzi, M. *et al.* 2010. *Seasonal Adjustment dan Peramalan PDB Triwulanan*. Jakarta: Badan Pusat Statistik.
- Tambunan, T. T. 2001. *Transformasi Ekonomi di Indonesia*. Jakarta: Salemba Empat.
- Wang, R., Ma, H.-G., Liu, G.-Q., & Zuo, D. 2015. *Selection of Window Length for Singular Spectrum Analysis*. *Journal of Franklin Institute*.