

Inflation Forecasting for East Kalimantan Province Using Hybrid Singular Spectrum Analysis-Autoregressive Integrated Moving Average Model

Peramalan Inflasi Provinsi Kalimantan Timur Menggunakan Model *Hybrid Singular Spectrum Analysis-Autoregressive Integrated Moving Average*

Melisa Arumsari¹, Sri Wahyuningsih², Meiliyani Siringoringo³

Abstract

The Singular Spectrum Analysis (SSA)-Autoregressive Integrated Moving Average (ARIMA) hybrid method is a good combination of forecasting methods to improve forecasting accuracy and is suitable for economic data that tends to have trend and seasonal patterns, one of which is inflation data. The purpose of this study is to obtain the results of inflation forecasting for East Kalimantan Province in 2021 using the SSA-ARIMA hybrid model. The results of the inflation forecasting for East Kalimantan Province in 2021 using the SSA-ARIMA(1,1,1) hybrid model overall experienced an increase and the highest inflation in 2021 occurred in December of 0.92% with a forecasting accuracy level based on the Root Mean Square Error (RMSE) was 0.069399 and *Mean Absolute Percentage Error* (MAPE) was 32.61084%

Keywords: ARIMA, Forecasting, Hybrid, Inflation, SSA.

Abstrak

Metode *hybrid Singular Spectrum Analysis* (SSA)-*Autoregressive Integrated Moving Average* (ARIMA) merupakan kombinasi metode peramalan yang baik untuk meningkatkan akurasi peramalan dan cocok untuk data ekonomi yang cenderung memiliki pola tren dan musiman, salah satunya adalah data inflasi. Tujuan dari penelitian ini adalah memperoleh hasil peramalan inflasi Provinsi Kalimantan Timur tahun 2021 menggunakan model *hybrid SSA-ARIMA*. Hasil peramalan inflasi Provinsi Kalimantan Timur tahun 2021 menggunakan model *hybrid SSA-ARIMA*(1,1,1) secara keseluruhan mengalami peningkatan dan inflasi tertinggi pada tahun 2021 terjadi pada bulan Desember sebesar 0,92% dengan tingkat akurasi peramalan berdasarkan *Root Mean Square Error* (RMSE) sebesar 0,069399 dan *Mean Absolute Percentage Error* (MAPE) sebesar 32,61084%.

Kata kunci: ARIMA, *Hybrid*, Inflasi, Peramalan, SSA.

^{1,2,3}Laboratorium Statistika Ekonomi dan Bisnis, Fakultas MIPA, Universitas Mulawarman
Email Address: melisa.arumsari1998@gmail.com¹, swahyuningsih@fmipa.unmul.ac.id²,
meiliyanisiringoringo@fmipa.unmul.ac.id³



1. PENDAHULUAN

1.1 Latar Belakang

Metode *hybrid* adalah metode peramalan yang terbentuk dari kombinasi dua jenis atau lebih metode peramalan yang berbeda [18]. Kombinasi ini dilakukan untuk meningkatkan akurasi peramalan, memanfaatkan kelebihan antara kedua metode dan meminimalisasi adanya kekurangan pada masing-masing metode [1]. Salah satu metode *hybrid* yang dapat digunakan adalah *hybrid Singular Spectrum Analysis (SSA)-Autoregressive Integrated Moving Average (ARIMA)*.

Beberapa penelitian telah membahas metode *hybrid* SSA-ARIMA. Penelitian mengenai peramalan konsentrasi O₃ maksimum untuk beberapa hari ke depan di enam stasiun pemantauan Eropa dengan hasil yang diperoleh adalah SSA-ARIMA telah berkinerja lebih baik [10]. Penelitian mengenai peramalan limpasan tahunan dari dua waduk di Cina dengan hasil yang diperoleh adalah prediksi dari SSA-ARIMA memiliki performa terbaik jika dibandingkan dengan ARIMA dan SSA-LRF [19].

SSA merupakan teknik analisis nonparametrik yang dapat digunakan untuk mengidentifikasi pola tren, musiman dan *noise* pada runtun waktu [19]. Sedangkan ARIMA dapat digunakan baik pada data stasioner, non-stasioner, maupun musiman. Selain itu ARIMA memiliki tahapan sistematis yang meliputi identifikasi, estimasi, dan pengujian diagnostik sehingga ARIMA tepat digunakan sebagai metode lanjutan untuk pemodelan *hybrid* [15].

Metode dengan pemecahan komponen seperti SSA cocok untuk mencirikan runtun data ekonomi dan bisnis yang cenderung memuat faktor tren, musiman dan siklis, salah satunya adalah data inflasi [13]. Inflasi adalah kondisi meningkatnya harga-harga secara umum dan terus menerus yang mengakibatkan kenaikan harga pada barang lainnya [5].

Berdasarkan uraian tersebut, penulis akan melakukan peramalan inflasi Provinsi Kalimantan Timur tahun 2021 menggunakan model *hybrid* SSA-ARIMA dan menunjukkan bahwa tingkat akurasi peramalan model *hybrid* SSA-ARIMA lebih akurat dibandingkan model SSA. Hasil peramalan tersebut dapat digunakan untuk membantu pemerintah dalam mempersiapkan program dalam mengantisipasi kenaikan inflasi Provinsi Kalimantan Timur di masa yang akan datang.

1.2 Analisis Periodogram

Periodogram dapat diartikan sebagai fungsi spektrum kuasa atas frekuensinya [7]. Analisis periodogram dilakukan untuk mengetahui apakah data pengamatan dipengaruhi oleh faktor musiman. Pengujian dilakukan dengan menggunakan persamaan sebagai berikut:

$$T = \frac{I^{(1)}(\omega_{(1)})}{\sum_{i=1}^{n/2} I(\omega_i)} \quad (1.1)$$

di mana $I^{(1)}(\omega_{(1)})$ adalah nilai periodogram terbesar dan $I(\omega_i)$ adalah nilai periodogram pada frekuensi fourier ke- i [3].

1.3 Singular Spectrum Analysis

Algoritma dasar SSA terdiri dari dua buah tahap yaitu dekomposisi dan rekonstruksi [20].

1. Dekomposisi

a. *Embedding*

Pada proses *embedding* dibentuk matriks lintasan atau matriks \mathbf{X} . Misalkan data runtun waktu dengan panjang n tanpa data hilang dinyatakan dengan $F = (f_1, f_2, \dots, f_n)$. Data runtun waktu tersebut di transformasi ke dalam bentuk matriks berukuran $L \times K$ di

mana $2 < L < \frac{n}{2}$ dan $K = n - L + 1$ [4]. Matriks lintasan dari runtun F dapat ditunjukkan melalui persamaan berikut [9] :

$$\mathbf{X} = [\mathbf{f}_1, \mathbf{f}_2, \dots, \mathbf{f}_K] = \begin{bmatrix} f_1 & f_2 & \cdots & f_K \\ f_2 & f_3 & \cdots & f_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ f_L & f_{L+1} & \cdots & f_n \end{bmatrix} \quad (1.2)$$

b. *Singular Value Decomposition (SVD)*

SVD dari matriks lintasan adalah sebagai berikut :

$$\mathbf{X} = \mathbf{u}_1 \sqrt{\lambda_1} \mathbf{v}_1^T + \mathbf{u}_2 \sqrt{\lambda_2} \mathbf{v}_2^T + \dots + \mathbf{u}_L \sqrt{\lambda_L} \mathbf{v}_L^T = \sum_{i=1}^L \mathbf{u}_i \sqrt{\lambda_i} \mathbf{v}_i^T \quad (1.3)$$

Matriks \mathbf{X} terbentuk dari *eigenvector* \mathbf{u}_i , *singular value* $\sqrt{\lambda_i}$ dan *principal component* \mathbf{v}_i^T . Ketiga elemen pembentuk SVD ini disebut *eigen triple* [4].

2. Rekonstruksi

a. *Grouping*

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 [8].

b. *Diagonal Averaging*

Diagonal averaging mentransformasi matriks $\mathbf{Y}^{(k)}$ ke dalam bentuk runtun kembali dengan menggunakan persamaan berikut [9]:

$$\hat{f}_t^{(k)} = \begin{cases} \frac{1}{t} \sum_{i=1}^t y_{i,t-i+1}^{*(k)} & ; \text{ untuk } 1 \leq t < L^* \\ \frac{1}{L^*} \sum_{i=1}^{L^*} y_{i,t-i+1}^{*(k)} & ; \text{ untuk } L^* \leq t \leq K^* \\ \frac{1}{n-t+1} \sum_{i=t-K^*+1}^{n-K^*+1} y_{i,t-i+1}^{*(k)} & ; \text{ untuk } K^* < t \leq n \end{cases} \quad (1.4)$$

Runtun awal akan didekomposisi menjadi jumlah dari m runtun yang direkonstruksi dan ditunjukkan pada persamaan berikut [9]:

$$\hat{f}_t = \sum_{k=1}^m \hat{f}_t^{(k)}, \text{ di mana } t = 1, 2, \dots, n \quad (1.5)$$

3. R-Forecasting

Peramalan *R-forecasting* berkaitan dengan penaksiran *Linier Recurrent Formula* (LRF). Koefisien LRF dari suatu komponen dapat dihitung menggunakan persamaan berikut [6]:

$$\mathbf{r}^{(k)} = (r_{L-1}^{(k)}, \dots, r_1^{(k)}) = \frac{1}{1-v^2} \sum_{i=1}^L \pi_i \mathbf{u}_i^\nabla \quad (1.6)$$

dengan hasil peramalan diperoleh berdasarkan persamaan berikut:

$$\hat{f}_t^{(k)} = \begin{cases} \hat{f}_t^{(k)} & \text{ untuk } t = 1, 2, \dots, n \\ \sum_{j=1}^{L-1} r_j^{(k)} \hat{f}_{t-j}^{(k)} & \text{ untuk } t = n+1, \dots, n+M \end{cases} \quad (1.7)$$

1.4 Autoregressive Integrated Moving Average

Tahap awal *autoregressive integrated moving average* (ARIMA) adalah melakukan identifikasi model untuk menentukan apakah data runtun waktu yang akan digunakan sudah stasioner atau tidak, baik dalam variansi maupun dalam rata-rata. Jika kondisi stasioner dalam variansi tidak terpenuhi maka digunakan transformasi pangkat (*power transformation*) menggunakan persamaan berikut [2] :

$$Z_t^* = \begin{cases} \frac{Z_t^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln Z_t, & \lambda = 0 \end{cases} \quad (1.8)$$

Metode *differencing* (pembedaan) digunakan untuk menstasionerkan data yang tidak stasioner dalam rata-rata. Pengujian yang dapat digunakan untuk pendeteksian stasioneritas dalam rata-rata adalah uji *Augmented Dickey Fuller* (ADF).

Tahapan selanjutnya dalam identifikasi model adalah membentuk grafik *autocorrelation function* (ACF) dan grafik *partial autocorrelation function* (PACF). Melalui perhitungan ACF dan PACF maka dapat ditentukan model *autoregressive* atau model *moving average* orde ke berapa data yang sedang dianalisis [2].

Model ARIMA mengacu pada pembedaan (*differencing*). Model ARIMA (p, d, q) adalah sebagai berikut [17]:

$$(Z_t - \phi_1 Z_{t-1} - \phi_2 Z_{t-2} - \dots - \phi_p Z_{t-p})(1-B)^d = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (1.9)$$

Setelah memperoleh model ARIMA, dilakukan penaksiran parameter model ARIMA menggunakan *maximum likelihood estimation* [2].

Selanjutnya adalah melakukan pemeriksaan diagnostik yang terdiri dari pengujian signifikansi parameter, pengujian residual berdistribusi normal dan pengujian independensi residual. Pengujian signifikansi parameter dilakukan dengan menggunakan uji t [2]. Sedangkan pengujian kenormalan residual menggunakan uji *Kolmogorov-Smirnov* dan pengujian independensi residual menggunakan uji *Ljung-Box* [2].

1.5 Hybrid SSA-ARIMA

Secara umum struktur *hybrid* pada runtun waktu adalah kombinasi dari dua atau lebih metode peramalan yang berbeda. Hasil peramalan model *hybrid* (\hat{H}_t) yaitu:

$$\hat{H}_t = \hat{f}_t + \hat{Z}_t \quad (1.10)$$

di mana \hat{f}_t adalah hasil peramalan dari metode SSA. Sedangkan \hat{Z}_t adalah hasil peramalan dari metode ARIMA dengan data yang digunakan adalah data komponen *noise* [16].

1.6 Pengukuran Akurasi Peramalan

Pemilihan model terbaik dan ketepatan metode peramalan yang digunakan dapat ditentukan berdasarkan beberapa nilai ukuran, antara lain *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE) [14]. Berikut cara memperoleh RMSE [12]:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (L_t - \hat{L}_t)^2}{n}} \quad (1.11)$$

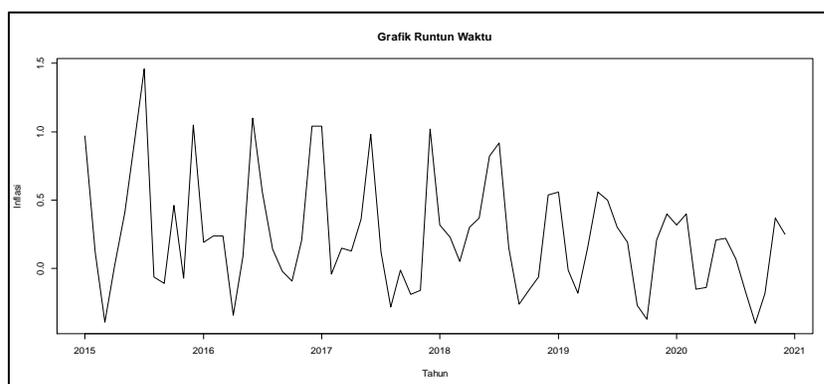
MAPE diperoleh menggunakan persamaan berikut [11]:

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{L_t - \hat{L}_t}{L_t} \right| \quad (1.12)$$

2. HASIL DAN PEMBAHASAN

2.1 Deskripsi Data

Data yang dapat digunakan untuk pemodelan *hybrid* SSA-ARIMA adalah data yang memiliki pola tren, musiman dan siklis. Pada penelitian ini digunakan data bulanan inflasi Provinsi Kalimantan Timur tahun 2015-2020 sebanyak 72 data yang diperoleh dari *website* resmi Badan Pusat Statistik (BPS) Provinsi Kalimantan Timur. Untuk melihat pola data dibuat grafik runtun waktu yang ditampilkan pada Gambar 2.1.



Gambar 2.1. Grafik runtun waktu data bulanan inflasi Provinsi Kalimantan Timur tahun 2015-2020

Berdasarkan Gambar 2.1 dapat dilihat bahwa data bulanan inflasi Provinsi Kalimantan Timur tahun 2015-2020 cenderung membentuk pola musiman. Hal ini dikarenakan pola dari data tersebut mengalami kenaikan dan penurunan yang berulang-ulang secara periodik.

2.2 Analisis Periodogram

Analisis periodogram digunakan untuk memeriksa pola musiman pada data pengamatan. Berdasarkan Persamaan (1.1) diperoleh hasil $T = 0,5319 > \alpha = 0,05$ sehingga dapat disimpulkan bahwa terdapat pola musiman pada data inflasi Provinsi Kalimantan Timur tahun 2015-2020.

2.3 Singular Spectrum Analysis

1. Dekomposisi

Tahap awal dekomposisi adalah *embedding*. Pada tahap *embedding* hal pertama yang dilakukan adalah menentukan parameter *window length* (L) di mana $2 < L < \frac{n}{2}$.

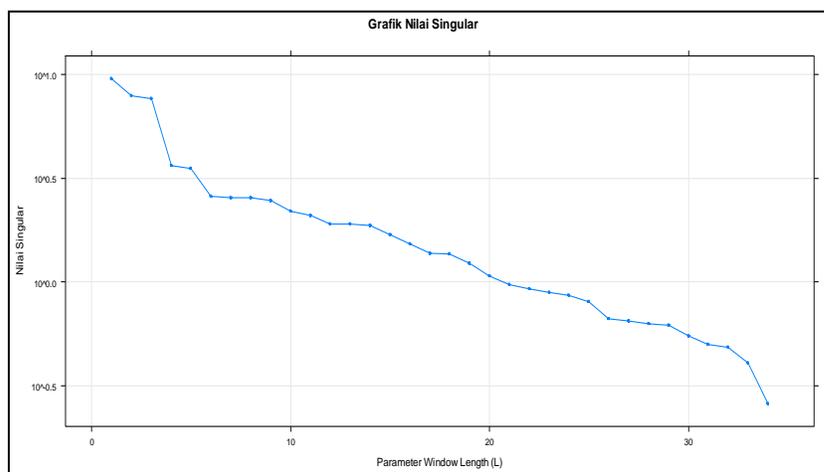
Penentuan nilai L dilakukan secara coba-coba (*trial and error*) berdasarkan kriteria RMSE terkecil. Nilai L yang memenuhi adalah $2 < L < 36$ dan diperoleh RMSE terkecil terletak pada $L = 34$. Runtun F merupakan runtun dari data aktual di mana $F = (f_1, f_2, f_3, \dots, f_{72}) = (0,97; 0,12; -0,39; \dots; 0,25)$. Berdasarkan nilai L maka $K = n - L + 1 = 72 - 34 + 1 = 39$ dan matriks lintasan yang terbentuk adalah sebagai berikut :

$$\mathbf{X} = (\mathbf{f}_1, \mathbf{f}_2, \mathbf{f}_3, \dots, \mathbf{f}_{39}) = \begin{bmatrix} f_1 & f_2 & \dots & f_{39} \\ f_2 & f_3 & \dots & f_{40} \\ \vdots & \vdots & \ddots & \vdots \\ f_{34} & f_{35} & \dots & f_{72} \end{bmatrix} = \begin{bmatrix} 0,97 & 0,12 & \dots & 0,05 \\ 0,12 & -0,39 & \dots & 0,30 \\ \vdots & \vdots & \ddots & \vdots \\ -0,19 & -0,16 & \dots & 0,25 \end{bmatrix}_{(34 \times 39)}$$

Tahap selanjutnya dalam tahap dekomposisi adalah *singular value decomposition* (SVD). Pada tahap SVD, matriks lintasan di dekomposisi menjadi 34 *eigentriple* yang terdiri dari 34 nilai eigen dan 34 vektor eigen.

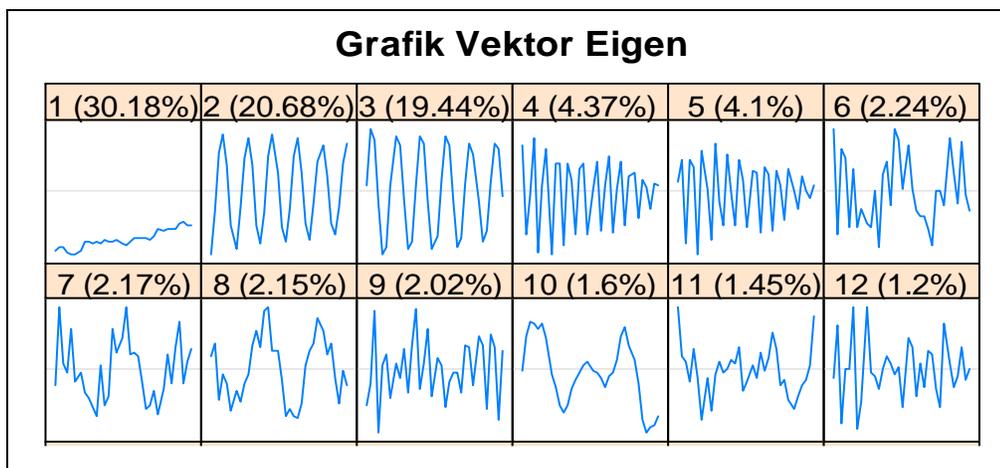
2. Rekonstruksi

Proses rekonstruksi diawali dengan melakukan *grouping* terhadap *eigentriple* yang diperoleh pada tahap dekomposisi. Berikut adalah grafik antara nilai singular yang digunakan untuk menentukan nilai *grouping effect* (R).

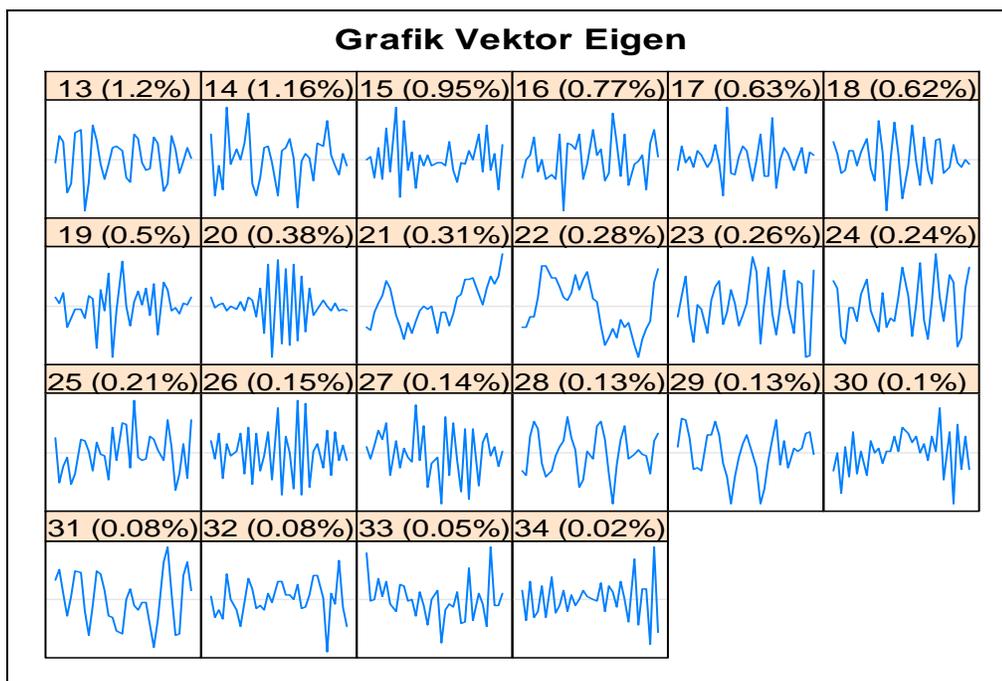


Gambar 2.2. Grafik nilai singular

Diketahui bahwa urutan grafik yang menurun secara lambat atau perlahan dari nilai singular biasanya terkait dengan komponen *noise* dari runtun. *Eigentriple* yang telah dipisahkan pada Gambar 2.2 menghasilkan pengelompokkan yang kurang subjektif sehingga nilai *grouping effect* (R) yang diambil yaitu $R = 34$ di mana akan dilakukan pemeriksaan kembali pada seluruh *eigentriple*. Untuk menentukan *eigentriple* yang memuat unsur tersebut dapat dilakukan dengan menggunakan grafik vektor eigen. Berikut adalah grafik vektor eigen dari 34 *eigentriple*.



Gambar 2.3. Grafik vektor eigen



Gambar 2.3. Grafik vektor eigen (lanjutan)

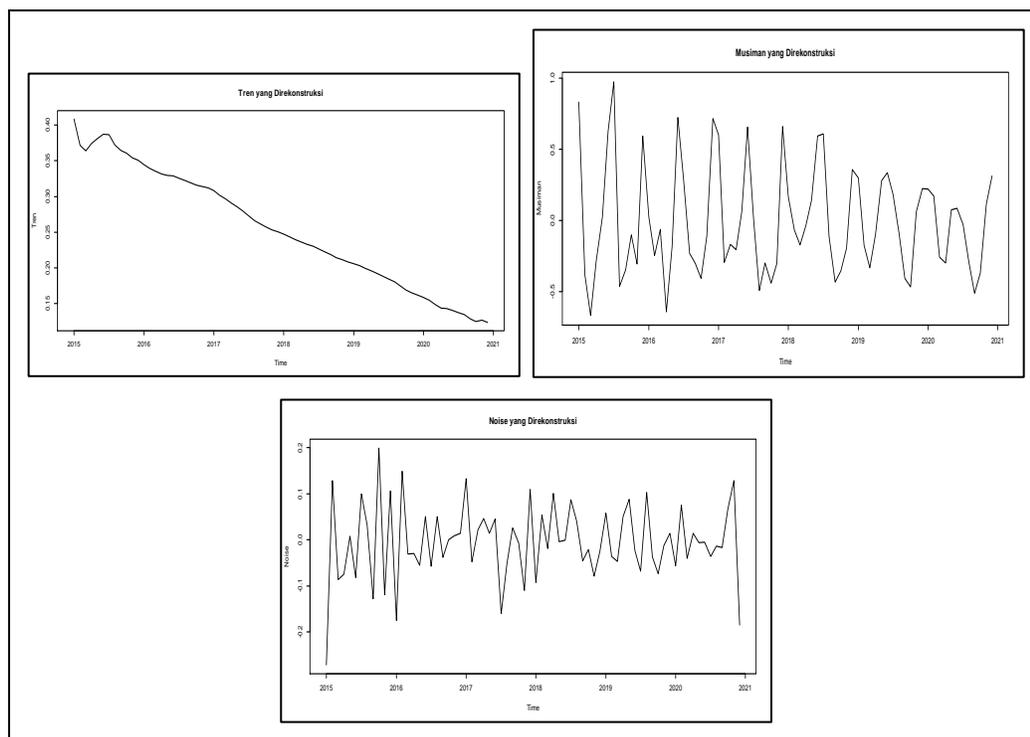
Pola grafik vektor eigen yang bervariasi lambat harus dikelompokkan ke dalam komponen tren. Berdasarkan Gambar 2.3, dapat dilihat bahwa grafik vektor eigen 1 bervariasi secara lambat atau dengan kata lain tidak terjadi kenaikan dan penurunan yang berulang sehingga *eigen triple* 1 dikelompokkan ke dalam komponen tren. Selanjutnya adalah pengelompokan terhadap *eigen triple* yang memuat unsur musiman pada *eigen triple* 2 sampai dengan 34 menggunakan analisis periodogram dan diperoleh pengelompokan *eigen triple* sebagai berikut.

Tabel 2.1. Pengelompokan *Eigen triple*

Kelompok	<i>Eigen triple</i>
Tren	1
Musiman	2, 3, 4, 5, 7, 8, 9, 10, 11, 13, 14, 17, 18, 20, 21, 22, 24, 26, 27, 28, 29, 30 dan 34
Noise	6, 12, 15, 16, 19, 23, 25, 31, 32 dan 33

Tahapan selanjutnya adalah *diagonal averaging*. Pada tahap *diagonal averaging* masing-masing komponen akan direkonstruksi oleh masing-masing *eigen triple* yang terkait kemudian dapat dibentuk grafik untuk komponen tren, musiman, dan *noise* yang direkonstruksi sebagai berikut.

Jurnal Matematika, Statistika & Komputasi
 Melisa Arumsari, Sri Wahyuningsih, Meiliyani Siringoringo



Gambar 2.4. Komponen tren, musiman dan *noise* yang direkonstruksi

Diagonal averaging diperoleh dari penjumlahan runtun tren dan musiman hasil direkonstruksi. Runtun hasil rekonstruksi dan *diagonal averaging* dapat dilihat pada Tabel 2.2.

Tabel 2.2. Hasil Rekonstruksi dan *Diagonal Averaging*

t	Rekonstruksi		<i>Diagonal Averaging</i>	t	Rekonstruksi		<i>Diagonal Averaging</i>	t	Rekonstruksi		<i>Diagonal Averaging</i>
	Tren	Musiman			Tren	Musiman			Tren	Musiman	
1	0,4087	0,8324	1,2411	25	0,3079	0,5993	0,9073	49	0,2056	0,2968	0,5024
2	0,3717	-0,3800	-0,0083	26	0,3015	-0,2939	0,0076	50	0,2030	-0,1772	0,0258
3	0,3639	-0,6680	-0,3041	27	0,2965	-0,1682	0,1283	51	0,1993	-0,3325	-0,1331
4	0,3739	-0,2792	0,0947	28	0,2908	-0,2067	0,0841	52	0,1959	-0,0967	0,0992
5	0,3816	0,0204	0,4020	29	0,2852	0,0610	0,3462	53	0,1925	0,2793	0,4718
6	0,3871	0,6252	1,0123	30	0,2797	0,6549	0,9346	54	0,1885	0,3346	0,5232
7	0,3867	0,9730	1,3597	31	0,2723	0,0076	0,2799	55	0,1847	0,1836	0,3684
8	0,3723	-0,4648	-0,0924	32	0,2661	-0,4946	-0,2285	56	0,1805	-0,0936	0,0869
9	0,3644	-0,3468	0,0176	33	0,2616	-0,2978	-0,0362	57	0,1746	-0,4074	-0,2328
10	0,3608	-0,1002	0,2606	34	0,2568	-0,4401	-0,1833	58	0,1689	-0,4658	-0,2970
11	0,3541	-0,3049	0,0492	35	0,2532	-0,3033	-0,0502	59	0,1649	0,0580	0,2229
12	0,3512	0,5926	0,9438	36	0,2507	0,6595	0,9101	60	0,1619	0,2237	0,3856
13	0,3441	0,0210	0,3651	37	0,2470	0,1661	0,4131	61	0,1584	0,2176	0,3760
14	0,3391	-0,2482	0,0909	38	0,2436	-0,0679	0,1757	62	0,1548	0,1705	0,3253
15	0,3353	-0,0648	0,2706	39	0,2398	-0,1708	0,0690	63	0,1489	-0,2583	-0,1094
16	0,3312	-0,6413	-0,3101	40	0,2362	-0,0371	0,1990	64	0,1439	-0,2977	-0,1539
17	0,3293	-0,1842	0,1451	41	0,2330	0,1413	0,3743	65	0,1430	0,0728	0,2158
18	0,3288	0,7210	1,0498	42	0,2304	0,5906	0,8210	66	0,1406	0,0844	0,2250
19	0,3257	0,2918	0,6175	43	0,2268	0,6067	0,8335	67	0,1374	-0,0313	0,1061
20	0,3222	-0,2329	0,0894	44	0,2227	-0,1142	0,1085	68	0,1345	-0,2908	-0,1563
21	0,3191	-0,3014	0,0177	45	0,2186	-0,4327	-0,2141	69	0,1291	-0,5126	-0,3835
22	0,3160	-0,4062	-0,0902	46	0,2144	-0,3536	-0,1391	70	0,1248	-0,3710	-0,2462
23	0,3138	-0,1125	0,2013	47	0,2118	-0,1931	0,0188	71	0,1271	0,1144	0,2415
24	0,3121	0,7135	1,0256	48	0,2087	0,3560	0,5648	72	0,1236	0,3106	0,4343

3. Peramalan SSA

Peramalan SSA yang digunakan adalah metode *R-forecasting*. Model peramalan untuk komponen tren adalah sebagai berikut:

$$\hat{f}_t^{(1)} = 0,0142\hat{f}_{t-1}^{(1)} + \dots + 0,0233\hat{f}_{t-31}^{(1)} + 0,0234\hat{f}_{t-32}^{(1)} + 0,0252\hat{f}_{t-33}^{(1)}$$

Sedangkan model peramalan untuk komponen musiman adalah sebagai berikut :

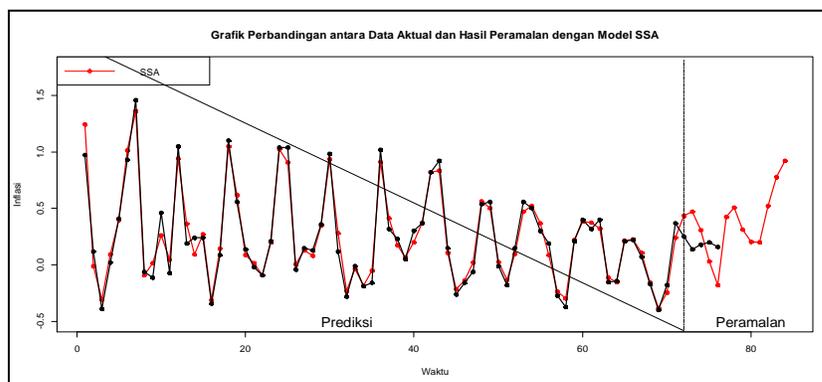
$$\hat{f}_t^{(2)} = 0,4604\hat{f}_{t-1}^{(2)} + \dots - 0,1534\hat{f}_{t-31}^{(2)} - 0,2267\hat{f}_{t-32}^{(2)} - 0,1418\hat{f}_{t-33}^{(2)}$$

Berdasarkan model peramalan yang terbentuk untuk komponen tren dan musiman, dilakukan penjumlahan kedua komponen tersebut untuk memperoleh peramalan SSA. Hasil peramalan SSA adalah sebagai berikut:

Tabel 2.3. Hasil Peramalan Inflasi Provinsi Kalimantan Timur Tahun 2021 dengan Model SSA

<i>t</i>	Peramalan			Data Aktual	<i>t</i>	Peramalan			Data Aktual
	Tren	Musiman	SSA			Tren	Musiman	SSA	
73	0,1233	0,3460	0,4693	0,14	79	0,1095	0,2040	0,3134	-
74	0,1209	0,1859	0,3068	0,18	80	0,1073	0,0984	0,2057	-
75	0,1186	-0,0867	0,0318	0,20	81	0,1051	0,0941	0,1992	-
76	0,1163	-0,2936	-0,1773	0,16	82	0,1029	0,4197	0,5226	-
77	0,1140	0,3132	0,4272	-	83	0,1008	0,6758	0,7766	-
78	0,1117	0,3959	0,5076	-	84	0,0986	0,8200	0,9186	-

Hasil prediksi dan peramalan yang telah diperoleh selanjutnya disajikan dalam bentuk grafik pada Gambar 2.5.

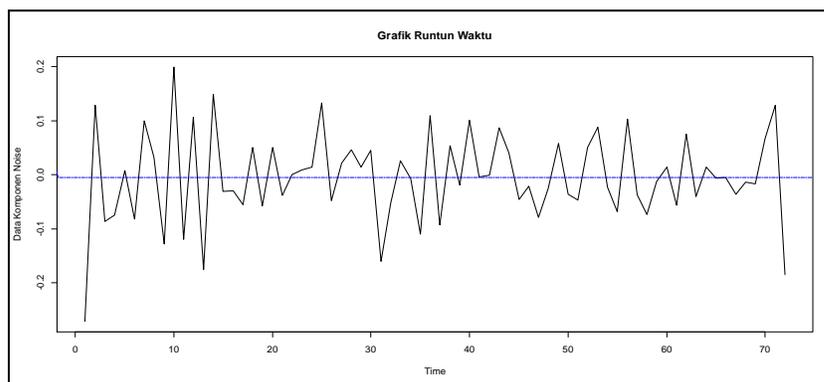


Gambar 2.5. Grafik perbandingan antara data aktual dan hasil peramalan Inflasi Provinsi Kalimantan Timur tahun 2015-2021 menggunakan model SSA

Berdasarkan Gambar 2.5 dapat dilihat bahwa pola pada grafik hasil peramalan inflasi Provinsi Kalimantan Timur menggunakan model SSA hampir mengikuti pola data aktual. RMSE yang diperoleh adalah sebesar 0,083008 dan MAPE yang diperoleh adalah sebesar 45,77432%.

2.4 Hybrid SSA-ARIMA

Untuk pemodelan *hybrid* SSA-ARIMA, digunakan data komponen *noise* dari hasil rekonstruksi metode SSA dan ditampilkan grafik runtun waktu sebagai berikut :

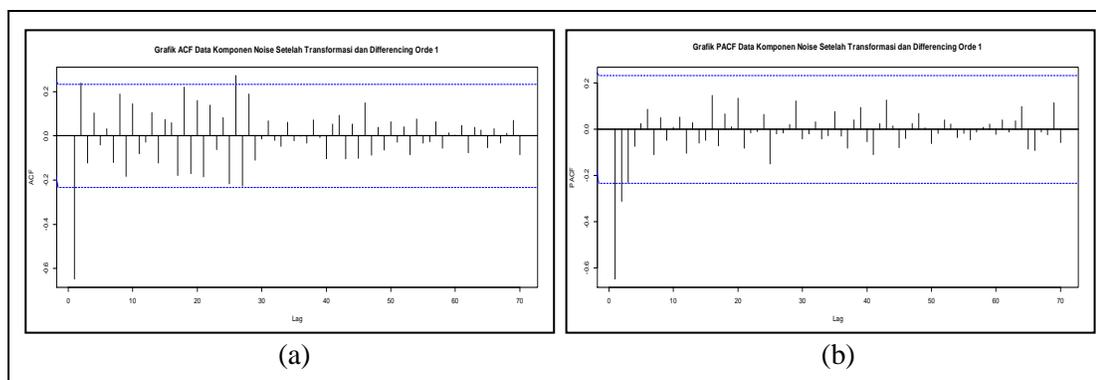


Gambar 2.6. Grafik runtun waktu dari data komponen *noise*

Berdasarkan grafik runtun waktu komponen *noise* dapat dilihat bahwa data komponen *noise* cenderung membentuk pola stasioner. Hal ini dikarenakan pola dari data tersebut berfluktuasi di sekitar garis nilai rata-rata yang konstan.

Dalam analisis menggunakan metode ARIMA, perlu dilakukan pemeriksaan kestasioneran dalam variansi dengan transformasi *Box-Cox*. Data dikatakan stasioner dalam variansi apabila nilai λ mendekati atau bernilai 1. Berdasarkan hasil analisis diperoleh nilai $\lambda = 1,992599$ sehingga dapat disimpulkan bahwa data komponen *noise* belum stasioner dalam variansi dan perlu dilakukan transformasi pangkat. Setelah dilakukan transformasi pangkat yaitu $Z_t^{(1,992599)}$, dilakukan pemeriksaan kembali nilai λ dan diperoleh nilai $\lambda = 0,999999$. Oleh karena nilai λ telah mendekati 1, maka syarat dari nilai estimasi telah terpenuhi dan dapat disimpulkan bahwa data komponen *noise* telah stasioner dalam variansi.

Selanjutnya adalah melakukan pemeriksaan stasioneritas dalam rata-rata pada data komponen *noise* setelah transformasi menggunakan uji *Augmented Dickey-Fuller* (ADF). Berdasarkan uji ADF diperoleh $p\text{-value} = 0,62 > \alpha = 0,05$ yang berarti data komponen *noise* setelah transformasi belum stasioner dalam rata-rata sehingga perlu dilakukan *differencing* orde 1 pada data komponen *noise* setelah transformasi. Setelah *differencing* orde 1 dan dilakukan pengujian ADF kembali, diperoleh $p\text{-value} = 2 \times 10^{-16} < \alpha = 0,05$ yang berarti data komponen *noise* setelah transformasi dan *differencing* orde 1 telah stasioner dalam rata-rata. Grafik ACF dan PACF untuk data komponen *noise* setelah transformasi dan *differencing* orde 1 diperlihatkan pada Gambar 2.7.



Gambar 2.7. (a) Grafik ACF data komponen *noise* setelah transformasi dan *differencing* orde 1, (b) Grafik PACF data komponen *noise* setelah transformasi dan *differencing* orde 1

Berdasarkan Gambar 2.7(a) dapat dilihat bahwa nilai ACF *cut off after lag 1* sehingga diperoleh orde untuk *moving average* (q) adalah 1. Sedangkan pada Gambar 2.7(b) nilai PACF

cut off after lag 1 dan 2 sehingga diperoleh orde untuk *autoregressive* (p) adalah 1 dan 2. Model ARIMA sementara yang terbentuk adalah ARIMA(0,1,1), ARIMA(1,1,0), ARIMA(1,1,1), ARIMA(2,1,0) dan ARIMA(2,1,1).

Untuk mengetahui model terbaik diantara lima model ARIMA sementara, perlu dilakukan pengujian hipotesis terhadap model tersebut. Hasil pengujian signifikansi parameter dapat dilihat pada Tabel 2.4.

Tabel 2.4. Penaksiran dan Pengujian Signifikansi Parameter Model

Model	Penaksiran Parameter	t_{hit}	$t_{0,025;db}$	p -value
ARIMA(0,1,1)	$\hat{\theta}_1 = -1,0000$	-26,7090	1,9939	$< 2,20 \times 10^{-16}$
ARIMA(1,1,0)	$\hat{\phi}_1 = -0,7671$	-8,6777	1,9939	$9,26 \times 10^{-13}$
ARIMA(1,1,1)	$\hat{\phi}_1 = -0,5500$	-4,9752	1,9944	$4,48 \times 10^{-6}$
	$\hat{\theta}_1 = -1,0000$	-24,7619	1,1944	$< 2,2 \times 10^{-16}$
ARIMA(2,1,0)	$\hat{\phi}_1 = -1,1276$	-10,0197	1,1944	$3,68 \times 10^{-15}$
	$\hat{\phi}_2 = -0,5104$	-4,4903	1,1944	$2,73 \times 10^{-5}$
ARIMA(2,1,1)	$\hat{\phi}_1 = -0,5903$	-4,7357	1,9950	$1,13 \times 10^{-5}$
	$\hat{\phi}_2 = -0,0894$	-0,6908	1,9950	0,4920
	$\hat{\theta}_1 = -1,0000$	-24,1528	1,9950	$< 2,2 \times 10^{-16}$

Berdasarkan pengujian signifikansi parameter pada Tabel 2.4 diperoleh kesimpulan bahwa model yang memiliki parameter yang signifikan adalah model ARIMA(0,1,1), ARIMA(1,1,0), ARIMA(1,1,1) dan ARIMA(2,1,0) karena p -value dari masing-masing parameternya lebih kecil dari taraf signifikansi ($\alpha=0,05$).

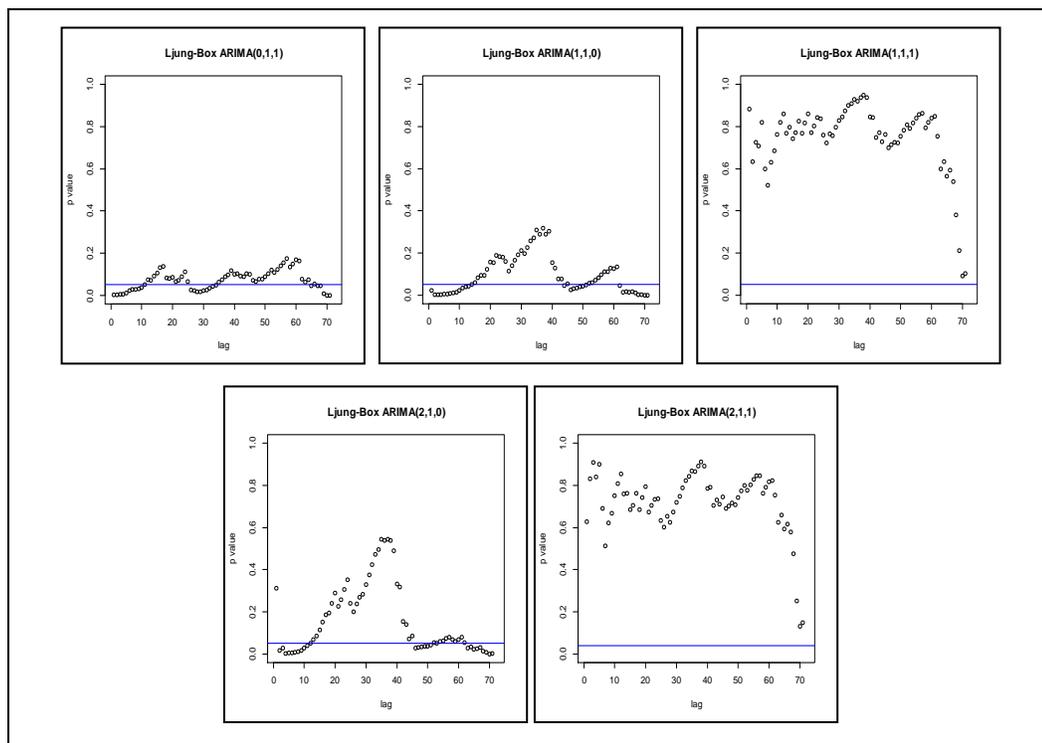
Selanjutnya hasil pengujian kenormalan residual menggunakan uji *Kolmogorov-Smirnov* dapat dilihat pada Tabel 2.5.

Tabel 2.5. Hasil Pengujian Kenormalan Residual

Model	D_{hit}	$D_{0,05;72}$	p -value
ARIMA(0,1,1)	0,1088	0,1603	0,3368
ARIMA(1,1,0)	0,0765	0,1603	0,7641
ARIMA(1,1,1)	0,0645	0,1603	0,9061
ARIMA(2,1,0)	0,0843	0,1603	0,6541
ARIMA(2,1,1)	0,0703	0,1603	0,8438

Berdasarkan pengujian kenormalan residual pada Tabel 2.5, dapat disimpulkan bahwa seluruh model ARIMA memiliki residual yang berdistribusi normal karena p -value dari masing-masing model lebih besar dari taraf signifikansi ($\alpha=0,05$).

Pengujian independensi residual dilakukan dengan membuat grafik dari setiap nilai p -value pengujian *Ljung-Box*. Hasil pengujian *Ljung-box* untuk setiap model dapat dilihat pada Gambar 2.8.



Gambar 2.8. Hasil pengujian *Ljung-Box*

Model ARIMA dikatakan memenuhi asumsi independensi residual apabila *p-value* berada diatas garis *threshold* atau taraf signifikansi ($\alpha=0,05$). Berdasarkan Gambar 2.8 dapat dilihat bahwa model ARIMA(1,1,1) dan ARIMA(2,1,1) memiliki *p-value* lebih besar dari 0,05. Sehingga model yang residualnya independen atau tidak terjadi autokorelasi adalah model ARIMA(1,1,1) dan ARIMA(2,1,1).

Model ARIMA sementara yang memenuhi seluruh pemeriksaan diagnostik adalah model ARIMA(1,1,1) dengan RMSE sebesar 0,069399. Sehingga model terbaik untuk peramalan data komponen *noise* adalah model ARIMA(1,1,1). Secara matematis model ARIMA(1,1,1) dapat ditulis sebagai berikut :

$$\begin{aligned}\hat{Z}_t &= (1 + \hat{\phi}_1)Z_{t-1} - \hat{\phi}_1 Z_{t-2} + e_t - \hat{\theta}_1 e_{t-1} \\ &= (1 - 0,5500)Z_{t-1} + 0,5500Z_{t-2} + e_t + 1,0000e_{t-1} \\ &= 0,4500Z_{t-1} + 0,5500Z_{t-2} + e_t + 1,0000e_{t-1}\end{aligned}$$

Berdasarkan model yang terbentuk, diperoleh hasil peramalan komponen *noise* berdasarkan model ARIMA(1,1,1) dan ditampilkan pada Tabel 2.6.

Tabel 2.6. Hasil Peramalan Komponen *Noise* Berdasarkan Model ARIMA(1,1,1)

Periode	Peramalan	Periode	Peramalan	Periode	Peramalan
73	0,0892	77	0,0091	81	0,0014
74	-0,0515	78	-0,0040	82	0,0002
75	0,0282	79	0,0032	83	0,0009
76	-0,0148	80	-0,0007	84	0,0005

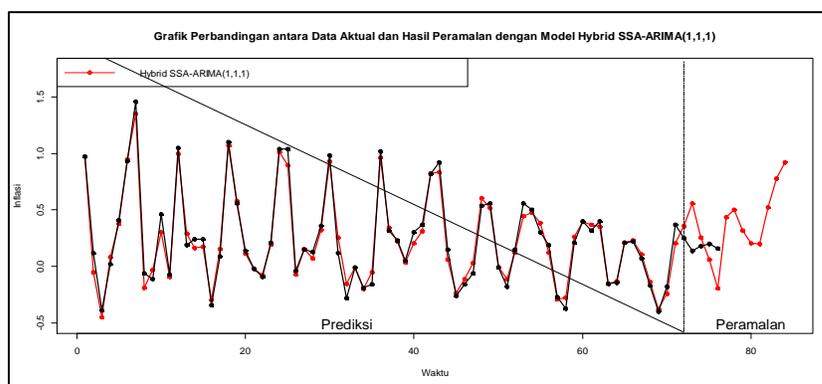
Peramalan *hybrid* SSA-ARIMA diperoleh dengan cara menjumlahkan hasil peramalan dari model SSA dan model ARIMA. Hasil peramalan inflasi Provinsi Kalimantan Timur periode

Januari 2015 sampai dengan Desember 2020 menggunakan model *hybrid* SSA-ARIMA(1,1,1) dapat dilihat pada Tabel 2.7.

Tabel 2.7. Hasil Peramalan Inflasi Provinsi Kalimantan Timur Tahun 2021 dengan Model *Hybrid* SSA-ARIMA(1,1,1)

t	Peramalan			Data Aktual	t	Peramalan			Data Aktual
	SSA	ARIMA (1,1,1)	SSA-ARIMA (1,1,1)			SSA	ARIMA (1,1,1)	SSA-ARIMA (1,1,1)	
73	0,4693	0,0892	0,56	0,14	79	0,3134	0,0032	0,32	-
74	0,3068	-0,0515	0,26	0,18	80	0,2057	-0,0007	0,20	-
75	0,0318	0,0282	0,06	0,20	81	0,1992	0,0014	0,20	-
76	-0,1773	-0,0148	-0,19	0,16	82	0,5226	0,0002	0,52	-
77	0,4272	0,0091	0,44	-	83	0,7766	0,0009	0,78	-
78	0,5076	-0,0040	0,50	-	84	0,9186	0,0005	0,92	-

Hasil prediksi dan peramalan yang telah diperoleh selanjutnya disajikan dalam bentuk grafik pada Gambar 2.9.



Gambar 2.9. Grafik perbandingan antara data aktual dan hasil peramalan inflasi Provinsi Kalimantan Timur tahun 2015-2021 menggunakan model *hybrid* SSA-ARIMA(1,1,1)

Berdasarkan Gambar 2.9 dapat dilihat bahwa pola pada grafik hasil peramalan inflasi Provinsi Kalimantan Timur menggunakan model *hybrid* SSA-ARIMA(1,1,1) hampir mengikuti pola data aktual. RMSE yang diperoleh adalah sebesar 0,069399 dan MAPE yang diperoleh adalah sebesar 32,61084%. Hasil pengukuran akurasi selengkapnya dapat dilihat pada Tabel 2.8.

Tabel 2.8. Hasil Pengukuran Akurasi Berdasarkan RMSE dan MAPE

Model	RMSE	MAPE
SSA	0,083008	0,069399
<i>Hybrid</i> SSA-ARIMA	45,77432%	32,61084%

Akurasi peramalan model *hybrid* SSA-ARIMA(1,1,1) berdasarkan RMSE dan MAPE mengalami peningkatan di mana diperoleh RMSE dan MAPE yang lebih kecil dibandingkan dengan model SSA.

3. KESIMPULAN DAN SARAN

3.1 Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dilakukan, diperoleh hasil peramalan inflasi Provinsi Kalimantan Timur tahun 2021 menggunakan model *hybrid* SSA-ARIMA(1,1,1) yang secara keseluruhan mengalami peningkatan. Hasil peramalan menunjukkan akan terjadi inflasi tertinggi sebesar 0,92% pada bulan Desember 2021.

Akurasi peramalan berdasarkan RMSE untuk model *hybrid* SSA-ARIMA(1,1,1) mengalami peningkatan, di mana RMSE untuk model SSA adalah 0,083008 dan RMSE untuk model *hybrid* SSA-ARIMA(1,1,1) adalah 0,069399 sedangkan MAPE untuk model SSA adalah 45,77432% dan MAPE untuk model *hybrid* SSA-ARIMA(1,1,1) adalah 32,61084%.

3.2 Saran

Penelitian selanjutnya dapat membangun kombinasi model *hybrid* yang lain, sebagai contoh *hybrid Singular Spectrum Analysis – Neural Network* (SSA–NN), *hybrid Seasonal Autoregressive Integrated Moving Average – Neural Network* (SARIMA–NN) atau *hybrid SSA–ARIMA–NN* agar mendapatkan kinerja peramalan yang lebih baik.

DAFTAR PUSTAKA

- [1] Arumsari, M , Dani, A.T.R., 2021. Peramalan Data Runtun Waktu menggunakan Model Hybrid Time Series Regression – Autoregressive Integrated Moving Average. *Jurnal Siger Matematika*, Vol. 2, No.1, 1-12.
- [2] Aswi, Sukarna, 2006. *Analisis Deret*. Makassar: Andira Publisher.
- [3] Darmawan, G., Handoko, B., Zulhanif, 2017. Identifikasi Perubahan Pola Curah Hujan Melalui Periodogram Standar. *JMP*, Vol. 9, No. 1, 103-112.
- [4] 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*, Vol. 5, No. 1, 9-11.
- [5] Endri, 2008. Analisis Faktor-Faktor yang Mempengaruhi Inflasi di Indonesia. *Jurnal Ekonomi Pembangunan*, Vol. 13, No. 1, 1-13.
- [6] Hassani, H., Mahmoudvand, R., 2018. *Singular Spectrum Analysis With R*. Iran: Palgrave Advance Texts in Econometrics.
- [7] 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 Eksponensial*, Vol. 6, No. 1, 21-29.
- [8] 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*, Vol. 4, No. 1, 58-60.
- [9] Jatmiko, Y.A., Rahayu, R.L., Darmawan, G., 2017. Perbandingan Keakuratan Hasil Peramalan Produksi Bawang Merah Metode Holt-Winters dengan Singular Sprectrum Analysis (SSA). *Jurnal Matematika (MANTIK)*, Vol. 3, No. 1, 13-22.
- [10] Kumar, U., 2014. An Integrated SSA-ARIMA Approach to Make Multiple Day Ahead Forecast for the Daily Maximum Ambient O₃ Concentration. *Aerosol and Air Quality Research*, 1-12.
- [11] Maricar, M.A., 2019. Analisa Perbandingan Nilai Akurasi Moving Average dan Exponential Smoothing untuk Sistem Peramalan Pendapatan pada Perusahaan XYZ. *Jurnal Sistem dan Informatika*, Vol. 13, No. 2, 36-45.
- [12] Nasution, A. H., Prasetyawan, Y., 2008. *Perencanaan & Pengendalian Produksi. Edisi Pertama*. Yogyakarta: Graha Ilmu.

- [13] 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*, Vol. 4, No. 2, 125.
- [14] Sinaga, H.D.E., Irawati, N., 2018. Perbandingan Double Moving Average dengan Double Exponential Smoothing Pada Peramalan Bahan Medis Habis Pakai. *Jurnal Teknologi dan Sistem Informasi*, Vol. 4, No. 2, 4-5.
- [15] Suhartono, 2011. Time Series Forecasting by Using Seasonal Autoregressive Integrated Moving Average: Subset, Multiplicative or Additive Model. *Journal of Mathematics and Statistics*, 20-27.
- [16] Waeto, S., Chuarkham, K., Intarasit, A., 2017. Forecasting Time Series Movement Direction with Hybrid Methodology. *Journal of Probability and Statistics*, 2-3.
- [17] Wei, W. W. S., 2006. *Time Series Analysis: Univariate and Multivariate Methods*. New York: Pearson Education.
- [18] Zhang, G., 2003. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 159-175.
- [19] 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*, 2683-2703.
- [20] Zhigljavsky, A., 2010. Singular Spectrum Analysis for time series: Introduction to this special issue. *Statistics and its Interface*, Vol. 3, 255-258.