

PERAMALAN HARGA SAHAM PT INDOFOOD SUKSES MAKMUR TBK MENGUNAKAN MODEL HIBRIDA *SINGULAR SPECTRUM ANALYSIS* (SSA) – *AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (ARIMA)

Rara Taskia Dewanti¹, Etik Zukhronah^{2*}, Winita Sulandari³

^{1,2,3} Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Sebelas Maret

*e-mail : etikzukhronah@staff.uns.ac.id

DOI: 10.14710/j.gauss.13.1.270-279

Article Info:

Received: 2024-03-21

Accepted: 2024-10-29

Available Online: 2024-10-31

Keywords:

Stock Price; Forecasting; SSA; ARIMA; Hybrid

Abstract: Daily stock price data can be predicted by examining the data pattern. SSA is a flexible nonparametric forecasting technique. ARIMA is a good technique for basic forecasting. In order to increase accuracy, hybrid method combines two or more forecasting techniques. The purpose of this study is to use the SSA-ARIMA hybrid model to forecast the stock price of PT Indofood Sukses Makmur. The August through December 2023 daily closing stock price data of PT Indofood Sukses Makmur Tbk is the source of the data. Testing data begins on November 29th and ends on December 29th, 2023, while training data runs from August 1st to November 28th 2023. SSA is used to model the training data. ARIMA is used to simulate the SSA residuals. Summing the outcomes of SSA and ARIMA forecasting yields the forecast for the SSA-ARIMA hybrid model. The findings demonstrated that the MAPE values of the SSA-ARIMA(1,0,0) and SSA-ARIMA(0,0,1) models were 1.54% for testing data and 0.82% for training data. Therefore, the SSA-ARIMA hybrid model has very good forecasting ability for PT Indofood Sukses Makmur's stock price.

1. PENDAHULUAN

Investasi sangat diminati oleh masyarakat pada saat ini. Investasi merupakan aktivitas penanaman modal untuk memperoleh keuntungan di masa depan. Saham merupakan jenis investasi yang paling populer. Saham didefinisikan sebagai surat berharga berupa bukti kepemilikan dalam suatu perusahaan, seperti perusahaan publik (Hidayana dkk., 2023).

Data harga saham harian termasuk data runtun waktu yang dapat dimodelkan dengan melihat pola datanya, lalu diramalkan nilai yang akan datang. Untuk meramalkan harga saham harian, metode *Singular Spectrum Analysis* (SSA) dan *Autoregressive Integrated Moving Average* (ARIMA) dapat digunakan. Hasil peramalan dapat menjadi lebih akurat jika menggabungkan dua atau lebih metode peramalan atau disebut sebagai metode hibrida. Penggabungan tersebut dapat membantu meningkatkan hasil akurasi peramalan yang lebih akurat serta memanfaatkan kelebihan dan mengurangi kekurangan setiap metode (Arumsari dkk., 2021). Hibrida SSA-ARIMA menjadi salah satu metode hibrida yang sering digunakan.

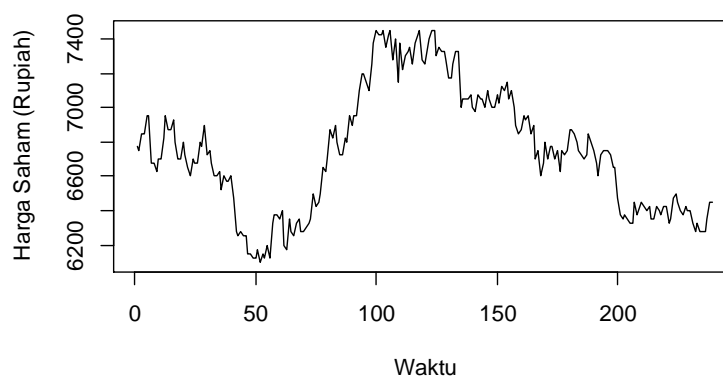
SSA merupakan metode peramalan yang penggunaannya fleksibel karena terhindar dari berbagai asumsi (Golyandina *et al.*, 2001). SSA memiliki dua tahap dasar, yaitu dekomposisi dan rekonstruksi. SSA tidak terdapat penentuan model dugaan seperti pada ARIMA. *Window length* (L) dan *grouping effect* (r) merupakan parameter dalam SSA. ARIMA sangat cocok digunakan karena penggunaannya mudah dan akurat (Ilahi dkk., 2023). Tahapan sistematis ARIMA mencakup identifikasi model, uji signifikansi parameter dan diagnostik, penentuan model terbaik, dan peramalan (Arumsari dkk., 2021). Dengan *Mean Absolute Percentage Error* (MAPE), tingkat kesalahan hasil peramalan dapat dihitung (Idrus dkk., 2022).

Beberapa penelitian sebelumnya telah dilakukan oleh Irmawati *et al.* (2018) tentang peramalan nilai tukar petani dengan model hibrida SSA-ARIMA dan ARIMA. Berdasarkan nilai MAPE, model hibrida SSA-ARIMA lebih baik dengan nilai MAPE sebesar 1,39% daripada model ARIMA yang memiliki nilai MAPE sebesar 1,53%. Darmawan *et al.* (2022) menggunakan model hibrida SSA dan ARIMA untuk meramalkan penumpang pesawat dan konsentrasi CO_2 pada atmosfer yang terdapat pada *R package datasets*. Nilai MAPE yang diperoleh sebesar 0,13% dan 3,63%. Ilahi dkk. (2023) meramalkan Indeks Harga Konsumen dengan model hibrida SSA dan ARIMA. Nilai MAPE *testing* dari pemodelan SSA-ARIMA(0,1,1) sebesar 0,77%.

Berdasarkan uraian sebelumnya, metode SSA dan ARIMA dapat meramalkan data runtun waktu dengan baik. Namun, pemodelan hibrida terbukti menghasilkan tingkat kesalahan yang lebih kecil. Oleh karena itu, digunakan model hibrida SSA-ARIMA dalam penelitian ini untuk meramalkan harga saham PT Indofood Sukses Makmur Tbk agar menghasilkan tingkat akurasi yang baik dan dapat membantu para calon investor dalam memprediksi keuntungan di masa depan.

2. TINJAUAN PUSTAKA

Saham disebut sebagai bukti kepemilikan modal yang didokumentasikan dengan nama perusahaan, nilai nominal, serta hak dan kewajiban setiap pemegangnya. Harga saham berfluktuasi karena adanya permintaan dan penawaran. Salah satu perusahaan yang harga sahamnya berfluktuasi adalah PT Indofood Sukses Makmur Tbk atau Indofood seperti yang ditunjukkan pada Gambar 1. Indofood menjadi salah satu produsen beberapa macam produk minuman dan makanan di Indonesia yang berdiri sejak 14 Agustus 1990. ICBP yang merupakan anak perusahaan Indofood termasuk dalam indeks LQ45 (Laskarjati dkk., 2022).



Gambar 1. Plot Harga Penutupan Saham Harian PT Indofood Sukses Makmur Tbk Pada Tahun 2023 yang Berfluktuasi

SSA merupakan sebuah metode nonparametrik untuk meramalkan data runtun waktu yang fleksibel karena terhindar dari berbagai asumsi (Golyandina *et al.*, 2014). SSA memiliki dua tahap utama, yaitu dekomposisi dan rekonstruksi. *Embedding* dan *Singular Value Decomposition* (SVD) merupakan dua proses yang terdapat pada tahap dekomposisi (Golyandina *et al.*, 2001). L adalah parameter yang diperlukan dalam tahap *embedding*. Dalam *embedding*, data runtun waktu asli harus dipetakan ke dalam matriks lintasan berukuran L dengan $K = N - L + 1$. Misalnya, terdapat data runtun waktu $X = \{x_1, \dots, x_N\}$ dengan panjang N . Kemudian, data tersebut diubah ke dalam matriks lintasan berukuran $L \times K$ dengan $1 < L < N$. Matriks lintasan berukuran $L \times K$:

$$\mathbf{X} = [X_1: \dots: X_K] = (x_{ij})_{i,j=1}^{L,K} = \begin{pmatrix} x_1 & x_2 & x_3 & \dots & x_K \\ x_2 & x_3 & x_4 & \dots & x_{K+1} \\ x_3 & x_4 & x_5 & \dots & x_{K+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & x_{L+2} & \dots & x_N \end{pmatrix}.$$

Setelah *embedding*, langkah berikutnya adalah SVD. Diberikan $\mathbf{S} = \mathbf{X}\mathbf{X}^T$. Misal, $\lambda_1, \dots, \lambda_L$ merupakan *eigenvalue* dari matriks \mathbf{S} dengan $\lambda_1 \geq \dots \geq \lambda_L \geq 0$ dan $\mathbf{U}_1, \dots, \mathbf{U}_L$ merupakan *eigenvector*. *Rank* matriks \mathbf{X} adalah $d = \max\{i\}$ sehingga $\lambda_i > 0$. SVD matriks lintasan \mathbf{X} dapat ditulis seperti Persamaan (1) jika $\mathbf{V}_i = \frac{\mathbf{X}^T \mathbf{U}_i}{\sqrt{\lambda_i}}$ untuk $i = 1, \dots, d$.

$$\mathbf{X} = \mathbf{X}_1 + \dots + \mathbf{X}_d \text{ dengan } \mathbf{X}_i = \sqrt{\lambda_i} \mathbf{U}_i \mathbf{V}_i^T. \quad (1)$$

Eigentruple ke- i dari SVD dengan *singular value* $\sqrt{\lambda_i}$, *eigenvector* \mathbf{U}_i , dan *principal component* \mathbf{V}_i merupakan kumpulan $(\sqrt{\lambda_i} \mathbf{U}_i \mathbf{V}_i^T)$.

Grouping dan *diagonal averaging* merupakan dua proses dalam tahap rekonstruksi (Golyandina *et al.*, 2001). Parameter yang digunakan pada *grouping* adalah r . Dalam *grouping*, matriks $\mathbf{X}_{(L \times K)}$ dibagi menjadi beberapa komponen berdasarkan pola pembentukan runtun waktu, yaitu tren, musiman, dan *noise*. Cara dalam mengelompokkan komponen-komponen tersebut dapat menggunakan grafik nilai *singular* dan grafik rekonstruksi. Setelah memperoleh Persamaan (1), prosedur pengelompokkan memartisi himpunan indeks $\{1, \dots, d\}$ menjadi m himpunan bagian yang lepas yaitu I_1, \dots, I_m . Matriks \mathbf{X}_I yang bersesuaian dengan kelompok I dapat didefinisikan sebagai $\mathbf{X}_I = \mathbf{X}_{I_1} + \dots + \mathbf{X}_{I_p}$ jika $I = i_1, \dots, i_p$. Matriks tersebut dihitung untuk $I = I_1, \dots, I_m$ dan Persamaan (1), lalu menghasilkan dekomposisi seperti Persamaan (2).

$$\mathbf{X} = \mathbf{X}_{I_1} + \dots + \mathbf{X}_{I_m}. \quad (2)$$

Setelah proses *grouping*, proses selanjutnya adalah *diagonal averaging*. Dalam proses ini, setiap matriks \mathbf{X}_{ij} dari dekomposisi yang dikelompokkan diubah menjadi runtun baru dengan panjang N . Misalnya, terdapat matriks \mathbf{Y} berukuran $L \times K$ dengan elemen y_{ij} , di mana $1 \leq i \leq L$ dan $1 \leq j \leq K$. Ditentukan bahwa $L^* = \min(L, K)$, $K^* = \max(L, K)$, dan $N = L + K - 1$. Misal, $y_{ij}^* = y_{ij}$ jika $L \leq K$ dan $y_{ij}^* = y_{ji}$ jika $L > K$. Dengan *diagonal averaging*, matriks \mathbf{Y} dapat diubah menjadi runtun y_1, \dots, y_N menggunakan Persamaan (3).

$$y_k = \begin{cases} \frac{1}{k} \sum_{m=1}^k y_{m, k-m+1}^* & 1 \leq k < L^* \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m, k-m+1}^* & L^* \leq k < K^* \\ \frac{1}{N-k+1} \sum_{m=k-K^*+1}^{N-K^*+1} y_{m, k-m+1}^* & K^* \leq k \leq N. \end{cases} \quad (3)$$

Jika Persamaan (2) diterapkan pada matriks \mathbf{X}_{Ik} , akan diperoleh runtun rekonstruksi $\tilde{\mathbf{X}}^{(k)} = (\tilde{x}_1^{(k)}, \dots, \tilde{x}_N^{(k)})$. Selanjutnya, data runtun awal x_1, \dots, x_N didekomposisikan menjadi jumlahan dari m hasil rekonstruksi seperti Persamaan (4).

$$\mathbf{x}_n = \sum_{k=1}^m \tilde{x}_n^{(k)}, \text{ dengan } n = 1, \dots, N. \quad (4)$$

Metode *R-Forecasting* merupakan suatu metode dasar yang sangat populer karena mudah digunakan (Golyandina *et al.*, 2001). Menurut Hassani *et al.* (2010), model SSA dibangun dengan bantuan *Linear Recurrent Forecasting* (LRF). *Eigenvector* yang diperoleh dari proses SVD digunakan untuk menaksir koefisien LRF. Misal, \mathbf{U}'_j merupakan vektor komponen pertama $L - 1$ dari *eigenvector* \mathbf{U}_j , π_j merupakan komponen terakhir dari \mathbf{U}_j dengan $j = 1, \dots, r$ dan $v^2 = \sum_{j=1}^r \pi_j^2$. Koefisien LRF (vektor $\mathbf{R} = (a_{L-1}, \dots, a_1)^T$) dapat dihitung dengan.

$$\mathbf{R} = \frac{1}{1 - v^2} \sum_{j=1}^r \pi_j \mathbf{U}'_j$$

Selanjutnya, M adalah jumlah data baru yang akan diramalkan.

$$\hat{y}_i = \begin{cases} \hat{y}_i; & i = 1, \dots, N \\ \sum_{j=1}^{L-1} a_j \hat{y}_{i-j}; & i = N + 1, \dots, N + M \end{cases} \quad (5)$$

Terbentuklah hasil peramalan $\hat{Y} = (\hat{y}_1, \dots, \hat{y}_{N+M})$ dengan $\hat{y}_{N+1}, \dots, \hat{y}_{N+M}$ seperti Persamaan (5) yang merupakan hasil peramalan untuk M periode ke depan.

Data runtun waktu adalah sekumpulan observasi yang diurutkan berdasarkan interval waktu yang tetap selama periode tertentu (Wei, 2006). Analisis runtun waktu merupakan perkiraan suatu peristiwa di masa yang akan datang. Runtun waktu berukuran N dapat ditulis dengan

$$X = \{x_t; t = 1, 2, \dots, N\} = \{x_1, x_2, \dots, x_N\}.$$

ARIMA menjadi sebuah metode klasik yang sangat populer dalam peramalan data runtun waktu (Hyndman *et al.*, 2009). Menurut Wei (2006), model ARIMA(p, d, q) dapat ditulis secara sistematis seperti Persamaan (6).

$$\phi_p(B)(1 - B)^d Z_t = \theta_q(B)a_t \quad (6)$$

dengan

$$\phi_p(B) = (1 - \phi_1 B^1 - \phi_2 B^2 - \dots - \phi_p B^p),$$

$$\theta_q(B) = (1 - \theta_1 B^1 - \theta_2 B^2 - \dots - \theta_q B^q),$$

ϕ merupakan parameter model AR, θ merupakan parameter model MA, Z_t merupakan pengamatan ke- t , B merupakan operator *backshift*, p merupakan orde model AR, d merupakan orde *differencing*, q merupakan orde model MA, a_t merupakan *error* pada waktu ke- t yang berdistribusi normal serta berasumsi *white noise* ($0, \sigma^2$). Untuk memodelkan ARIMA, perlu dilakukan identifikasi model, uji signifikansi parameter dan diagnostik, penentuan model terbaik, dan peramalan.

Peramalan hibrida SSA-ARIMA merupakan penggabungan model SSA dan model ARIMA. Data dimodelkan dengan SSA, lalu residu SSA dimodelkan dengan ARIMA. Menurut Zhang (2003), hasil peramalan hibrida (\hat{H}_t) dapat ditulis dengan Persamaan (7).

$$\hat{H}_t = \hat{Y}_t + \hat{Z}_t \quad (7)$$

dengan \hat{Y}_t merupakan hasil peramalan SSA dan \hat{Z}_t merupakan hasil peramalan ARIMA.

MAPE adalah alat ukur tingkat akurasi hasil peramalan (Rahmawati dkk., 2021). Semakin kecil kesalahan nilai peramalan, akan semakin baik model yang digunakan dalam meramalkan runtun waktu. MAPE dapat diperoleh dengan Persamaan (8).

$$MAPE = \left(\frac{1}{N} \sum_{t=1}^n \left| \frac{H_t - \hat{H}_t}{H_t} \right| \right) 100\% \quad (8)$$

dengan H_t merupakan data asli dan \hat{H}_t merupakan hasil peramalan serta n menunjukkan jumlah data. Tabel 1 menunjukkan kriteria tingkat akurasi hasil peramalan (Zhang *et al.*, 2015).

Tabel 1. Kriteria Akurasi Hasil Peramalan dengan MAPE


Nilai	Kriteria
< 10%	Sangat akurat
10 – 20%	Baik
20 – 50%	Cukup
> 50%	Tidak akurat

3. METODE PENELITIAN

Model hibrida SSA-ARIMA digunakan dalam penelitian ini untuk meramalkan harga saham PT Indofood Sukses Makmur Tbk. Data yang digunakan adalah data harga penutupan saham harian PT Indofood Sukses Makmur Tbk periode Agustus sampai Desember 2023 yang berjumlah 105 data dan diambil dari *website* <https://finance.yahoo.com/>. Berikut langkah-langkah yang dilakukan dalam penelitian ini.

1. Membagi data menjadi data *training* dan data *testing* dengan perbandingan 80:20 sehingga data *training* dimulai dari 1 Agustus hingga 28 November 2023 dan data *testing* dimulai dari 29 November hingga 29 Desember 2023.
2. Melakukan peramalan dengan SSA dengan langkah-langkah berikut.
 - a. Mencari nilai parameter L dari data *training* untuk membentuk matriks lintasan pada proses *embedding*.
 - b. Mengubah matriks lintasan menjadi penjumlahan matriks orthogonal.
 - c. Melakukan *grouping* untuk menggabungkan pola hasil dekomposisi ke dalam tiga pola runtun waktu, yaitu tren, musiman, dan *noise*.
 - d. Mengubah matriks hasil dekomposisi yang dikelompokkan menjadi suatu runtun baru pada proses *diagonal averaging*.
 - e. Meramalkan data *testing* pada kelompok komponen yang telah terbentuk dengan LRF.
4. Melakukan peramalan dengan ARIMA yang menggunakan residu dari model SSA melalui langkah-langkah berikut.
 - a. Mengidentifikasi pola data residu dari model SSA dengan melihat plot runtun waktu.
 - b. Memeriksa kestasioneran data dengan transformasi Box-Cox untuk stasioner terhadap variansi dan melihat plot ACF untuk stasioner terhadap rata-rata.
 - c. Mengidentifikasi model dari plot ACF dan PACF.
 - d. Melakukan uji signifikansi parameter pada setiap model ARIMA dugaan.
 - e. Melakukan uji asumsi *white noise* dan uji normalitas residu pada setiap model ARIMA dugaan.
 - f. Melakukan pemodelan ARIMA yang memenuhi semua asumsi.
5. Menjumlahkan hasil peramalan SSA dan ARIMA.
6. Menentukan model hibrida SSA-ARIMA terbaik dengan melihat tingkat akurasi dari nilai MAPE data *testing*.
7. Mengevaluasi hasil peramalan hibrida SSA-ARIMA dengan melihat tingkat akurasi dari nilai MAPE.

4. HASIL DAN PEMBAHASAN



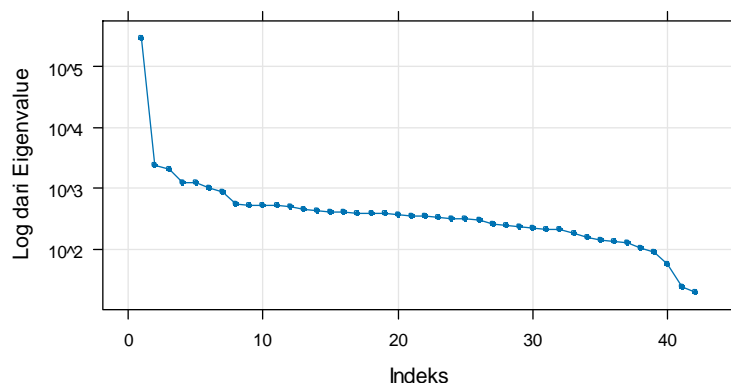
Gambar 2. Plot Harga Penutupan Saham PT Indofood Sukses Makmur Tbk Pada Agustus hingga Desember 2023

Gambar 2 menunjukkan bahwa harga penutupan saham harian PT Indofood Sukses Makmur Tbk pada bulan Agustus hingga Desember 2023 terjadi penurunan dari waktu ke waktu sehingga menunjukkan adanya pola tren.

Dalam tahap dekomposisi, langkah awal yang perlu dilakukan adalah *embedding*. L yang digunakan sebesar $L = \frac{N}{2} = \frac{84}{2} = 42$. Dari nilai L tersebut, K dapat terbentuk menjadi $K = N - L + 1 = 84 - 42 + 1 = 43$. Proses *embedding* ini menghasilkan matriks lintasan X yang berukuran 42×43 seperti berikut.


$$X = \begin{bmatrix} 7000 & 7050 & \dots & 6750 \\ 7050 & 7050 & \dots & 6725 \\ \vdots & \vdots & \ddots & \vdots \\ 6625 & 6750 & \dots & 6375 \end{bmatrix}.$$

Selanjutnya, mencari SVD dengan mendekomposisikan matriks lintasan X menjadi 42 *eigen triple* yang meliputi 42 nilai *singular*, 42 *eigenvector*, dan 42 *principal component*. r adalah jumlah *eigen triple* yang digunakan untuk membentuk kelompok komponen. Nilai r dapat dihitung dari jumlah *eigen triple* yang tidak menunjukkan *noise* (Sodiqin *et al.*, 2021).



Gambar 3. Scree Plot Nilai Singular

Gambar 3 menunjukkan *scree plot* dari 42 nilai *singular*. Selain itu, dapat dilihat bahwa nilai *singular* ke-4 hingga 42 mengalami penurunan secara lambat sehingga dapat diidentifikasi ke dalam komponen *noise* sehingga nilai dari parameter $r = 3$ dapat digunakan dalam mengelompokkan komponen menjadi tren dan musiman.




Gambar 4. Plot dari Deret yang Direkonstruksi

Gambar 4 menunjukkan bahwa deret yang direkonstruksi oleh *eigen triple* 1, 2, dan 3 memuat komponen yang bervariasi lambat dan tidak mengandung komponen musiman sehingga ketiga *eigen triple* tersebut termasuk komponen tren. Selanjutnya, pada proses *diagonal averaging*, komponen yang telah dikelompokkan menjadi tren dan *noise* direkonstruksikan oleh *eigen triple* masing-masing. Kemudian, perbandingan hasil peramalan SSA dan data *training* dapat dilihat pada Tabel 2.


Tabel 2. Perbandingan Data *Training* dan Hasil Peramalan SSA

<i>t</i>	Data <i>Training</i>	Hasil Peramalan SSA
1	7000	7047,204
2	7050	7039,882
⋮	⋮	⋮
84	6375	6468,073




Gambar 5. Plot Runtun Waktu Residu Model SSA

Gambar 5 menunjukkan residu dari model SSA. Untuk mengetahui kestasioneran data, dapat dilakukan melalui pemeriksaan data terhadap variansi melalui transformasi Box-Cox dengan melihat besarnya nilai lambda (λ). Data tersebut memiliki $\lambda = 1,061$, artinya mendekati $\lambda = 1$ sehingga data tersebut sudah stasioner terhadap variansi. Sementara itu, plot ACF dapat digunakan untuk melihat kestasioneran data terhadap rata-rata.



Gambar 6. Plot ACF Residu Model SSA



Gambar 7. Plot PACF Residu Model SSA

Berdasarkan Gambar 6 dan Gambar 7, plot ACF menunjukkan *cut off* setelah lag 1, artinya residu telah stasioner terhadap rata-rata dan diperoleh orde untuk $MA(q)$ adalah 0 dan 1. Sementara itu, plot PACF menunjukkan *cut off* setelah lag 1 sehingga diperoleh orde untuk $AR(p)$ adalah 0 dan 1. Selanjutnya, terbentuk beberapa model ARIMA dugaan yaitu ARIMA(1,0,0), ARIMA(1,0,1), dan ARIMA(0,0,1). Kemudian, dilakukan uji signifikansi parameter yang hasilnya dapat dilihat pada Tabel 3.

Tabel 3. Uji Signifikansi Parameter

Model	Parameter	Koefisien	<i>p-value</i>	Keterangan
ARIMA(1,0,0)	ϕ_1	0,60404	$4,018 \times 10^{-09}$	Signifikan
ARIMA(1,0,1)	ϕ_1	0,84071	$2,299 \times 10^{-09}$	Signifikan
	θ_1	-0,35892	0,1283	Tidak signifikan
ARIMA(0,0,1)	θ_1	0,439536	$7,306 \times 10^{-07}$	Signifikan

H_0 berarti parameter model tidak signifikan, sedangkan H_1 berarti parameter model signifikan. Jika $p - value < \alpha = 0,05$, H_0 ditolak. Karena *p-value* dari masing-masing parameter dari model ARIMA(1,0,0) dan ARIMA(0,0,1) kurang dari taraf signifikansi ($\alpha = 0,05$), seluruh parameter dari kedua model tersebut signifikan sehingga dapat dikatakan kedua model tersebut memenuhi uji signifikansi parameter. Kemudian, model ARIMA dugaan yang memenuhi uji signifikansi parameter dilakukan pemeriksaan diagnostik yang mencakup uji *white noise* dan uji normalitas residu. Tabel 4 menunjukkan hasil pemeriksaan diagnostik.

Tabel 4. Pemeriksaan Diagnostik

	Model	<i>p-value</i>	Keterangan
Uji <i>White Noise</i>	ARIMA(1,0,0)	0,9164	Independen
	ARIMA(0,0,1)	0,4261	Independen
Uji Normalitas Residu	ARIMA(1,0,0)	0,3803	Normal
	ARIMA(0,0,1)	0,2232	Normal

Pada uji *white noise*, H_0 berarti residu bersifat *white noise*, sedangkan H_1 berarti residu tidak bersifat *white noise*. Jika $p - value < \alpha = 0,05$, H_0 ditolak. Tabel 4 menunjukkan bahwa model ARIMA(1,0,0) dan ARIMA(0,0,1) memiliki residu yang bersifat *white noise* sampai lag 12 karena $p - value > \alpha$ sehingga dapat dikatakan kedua model tersebut memenuhi asumsi *white noise*.

Pada uji normalitas residu, H_0 berarti residu berdistribusi normal, sedangkan H_1 berarti residu tidak berdistribusi normal. Jika $p - value < \alpha = 0,05$, H_0 ditolak. Tabel 4 menunjukkan bahwa model ARIMA(1,0,0) dan ARIMA(0,0,1) memiliki residu yang berdistribusi normal karena $p - value > \alpha$.

Tabel 5. Perbandingan Data *Testing* dan Hasil Peramalan Hibrida SSA-ARIMA

t	Data <i>Training</i>	Hasil Peramalan	
		SSA-ARIMA(1,0,0)	SSA-ARIMA(0,0,1)
85	6425	6495,177	6495,177
86	6425	6507,218	6507,218
⋮	⋮	⋮	⋮
105	6450	6120,713	6120,713

Tabel 5 menampilkan perbandingan antara data *testing* dan hasil peramalan model SSA-ARIMA(1,0,0) dan SSA-ARIMA(0,0,1). Model hibrida SSA-ARIMA(1,0,0) dan SSA-ARIMA(0,0,1) memiliki hasil peramalan yang mirip atau tidak menunjukkan perbedaan.

Tabel 6. Hasil Akurasi Peramalan

Model	MAPE	
	<i>Training</i>	<i>Testing</i>
SSA-ARIMA(1,0,0)	0,82%	1,54%
SSA-ARIMA(0,0,1)	0,82%	1,54%

Tabel 6 menunjukkan bahwa model hibrida SSA-ARIMA(1,0,0) dan SSA-ARIMA(0,0,1) memiliki nilai MAPE yang sama, baik pada data *testing* maupun data *training* sehingga kedua model tersebut merupakan model terbaik. Kedua model tersebut dapat dikatakan sangat akurat karena berada nilai MAPE berada di bawah 10%.

5. KESIMPULAN

Peramalan menggunakan SSA dengan nilai parameter L sebesar 42 dan r sebesar 3 menghasilkan dua kelompok komponen yaitu komponen tren yang terdiri dari *eigentriple* 1 sampai 3 dan komponen *noise* yang terdiri dari *eigentriple* 4 sampai 42. Komponen tren yang dihasilkan dari rekonstruksi digunakan dalam pemodelan SSA. Sementara itu, residu dari SSA digunakan dalam pemodelan ARIMA. Peramalan hibrida SSA-ARIMA dihasilkan dari penjumlahan hasil peramalan SSA dan ARIMA. Model hibrida SSA-ARIMA(1,0,0) dan SSA-ARIMA(0,0,1) menjadi model terbaik. Kedua model tersebut menghasilkan nilai MAPE sebesar 0,82% pada data *training* dan 1,54% pada data *testing* sehingga dapat dikatakan sangat akurat karena nilai MAPE kurang dari 10%.

DAFTAR PUSTAKA

- Arumsari, M., Wahyuningsih, S., dan Siringoringo, M. 2021. Peramalan Inflasi Provinsi Kalimantan Timur Menggunakan Model Hybrid Singular Spectrum Analysis-Autoregressive Integrated Moving Average. *Jurnal Matematika, Statistika, dan Komputasi*. Vol. 18(1), 78-92.
- Darmawan, G., Rosadi, D., and Ruchjana, B.N. 2022. Hybrid Model of Singular Spectrum Analysis and ARIMA for Seasonal Time Series Data. *Jurnal Matematika Murni dan Aplikasi*. Vol. 7(2), 302-315.
- Golyandina, N. and Korobeynikov, A. 2014. Basic Singular Spectrum Analysis and Forecasting with R. *Computational Statistics dan Data Analysis*. Vol. 71, 934-954.
- Golyandina, N., Nekrutkin, V., and Zhigljavsky, A.A. 2001. *Analysis of Time Series Structure: SSA and Related Techniques*. Chapman & Hall CRC.
- Hassani, H. and Thomakos, D. 2010. A Review on Singular Spectrum Analysis for Economic and Financial Time Series. *Statistics and Its Interface*. Vol. 3, 377- 397.
- Hidayana, R.A. dan Ruchjana, B.N. 2023. Peramalan Return Saham Menggunakan Model Integrated Moving Average. *Jambura Journal of Mathematics*. Vol. 5(1), 199-209.

- Hyndman, R.J., Koehler, A.B., Ord, J.K., and Snyder, R.D. 2009. Monitoring Processes with Changing Variances. *International Journal of Forecasting*. Vol. 25(3), 518-525.
- Idrus, R.A., Ruliana dan Aswi. 2022. Penerapan Metode Singular Spectrum Analysis dalam Peramalan Jumlah Produksi Beras di Kabupaten Gowa. *Journal of Statistics and Its Application on Teaching and Research*. Vol. 4(2), 49-58.
- Ilahi, E.P.S.P., Zukhronah, E., dan Susanti, Y. 2023. Model Hibrida Singular Spectrum Analysis (SSA) dan Autoregressive Integrated Moving Average (ARIMA) untuk Peramalan Indeks Harga Konsumen. *Prosiding Seminar Nasional Pendidikan Matematika Ahmad Dahlan*. Yogyakarta. Universitas Ahmad Dahlan.
- Irmawati, D.R., Atok, R.M., and Suhartono. 2018. Singular Spectrum Analysis-ARIMA Modelling for Direct and Indirect Forecasting of Farmer's Term of Trade in East Java. *International Conference on Information and Communications Technology*, 889-894.
- Laskarjati, S.D. dan Ahmad, I.S. 2022. Perbandingan Peramalan Harga Saham Autoregressive Integrated Moving Average (ARIMA) dan Fuzzy Time Series Markov Chain (Studi Kasus: Saham PT Indofood CBP Sukses Makmur Tbk). *Jurnal Sains dan Seni ITS*. Vol. 11(6), 397-404.
- Rahmawati, Y.F., Zukhronah, E., dan Pratiwi, H. 2021. Penerapan Model ARIMA-ARCH untuk Meramalkan Harga Saham PT Indofood Sukses Makmur Tbk. *Business Innovation and Entrepreneurship Journal*. Vol. 03(03), 171-177.
- Sodiqin, M.A., Sulandari, W., and Respatiwulan. 2021. The Application of Singular Spectrum Analysis Method in Forecasting The Number of Foreign Tourists Visit to Special Capital Region of Jakarta. *Jurnal Riset dan Aplikasi Matematika*. Vol. 05(02), 92-102.
- Wei, W.W.S. 2006. *Time Series Analysis: Univariate and Multivariate Methods (2nd ed.)*. California. Addison-Wesley Publishing Company.
- Zhang, G.P. 2003. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*. Vol. 50, 159-175.
- Zhang, T., Wang, K., and Zhang, X. 2015. Modelling and Analyzing the Transmission Dynamics of HBV Epidemic in Xinjiang, China. *Plos One*. Vol. 10(9), 110-121.