



*Corresponding author: Andrea Tri Rian Dani, Department of Mathematics, Faculty of Mathematics and Natural Sciences, Mulawarman University, Samarinda, Indonesia

E-mail:
andreatriandani@fmipa.unmul.ac.id

RESEARCH ARTICLE

Modeling Maximum Water Level in Sangkuliman East Borneo using Singular Spectrum Analysis

Andrea Tri Rian Dani^{1*}, Mislan², Fachrian Bimantoro Putra¹, Gavrila Nathania Rambung¹, Narita Yuri Adrianingsih³

¹Department of Mathematics, Faculty of Mathematics and Natural Sciences, Mulawarman University, Samarinda, Indonesia

²Department of Physics, Faculty of Mathematics and Natural Sciences, Mulawarman University, Samarinda.

³Department of Mathematics, Faculty of Mathematics and Natural Sciences, Tribuana Kalabahi University, Alor.

Abstract: This study aims to model the average maximum water level in Lake Sangkuliman using time series data collected from January 2015 - December 2022. The method used is Singular Spectrum Analysis (SSA). SSA is one of the time series analysis methods that has advantages, including flexibility in detecting patterns, especially seasonal patterns. The data is divided into in-sample and out-sample data with a proportion of 90:10. The accuracy measure used is Symmetric Mean Absolute Percentage Error (SMAPE). Based on the analysis results, the optimal windown length $L = 12$ with the minimum SMAPE value is obtained. Forecasting results from SSA based on Linear Recurrent Formula (LRF) coefficients show that the predicted data pattern tends to follow the actual data pattern.

Keywords: Forecasting, Modeling Water Level, Singular Spectrum Analysis, Sangkuliman Post

1. INTRODUCTION

Rata-rata tinggi muka air maksimum merupakan salah satu parameter penting dalam bidang pengelolaan sumber daya air dan mitigasi bencana banjir. Tinggi muka air dipengaruhi oleh berbagai faktor, baik yang berasal dari dalam (internal) maupun dari luar (eksternal) sistem perairan (Penton et al., 2023). Contoh faktor internal diantaranya Morfometri Danau, Kondisi Vegetasi, Sedimentasi, Keberadaan Penampungan Air seperti Waduk dan atau Bendungan. Sedangkan faktor eksternal diantaranya diakibatkan oleh Curah Hujan, Pasang Surut Air Laut, dan Perubahan Iklim. Pemantauan tinggi muka air secara real-time dimaksudkan untuk memprediksi potensi kenaikan tinggi muka air dan memberikan peringatan dini sebagai bagian dari proses mitigasi bencana (Mislan & Dani, 2024).

Danau Sangkuliman adalah danau Air Tawar yang terletak di desa Sangkuliman, Kecamatan Kota Bangun, Kabupaten Kutai Kartanegara, Kalimantan Timur. Danau Sangkuliman dikelilingi oleh hutan hujan tropis yang masih alami dan merupakan habitat bagi berbagai Flora dan Fauna. Pada penelitian ini, obyek pengukuran tinggi muka air maksimum dilakukan pada Danau Sangkuliman, dengan alasan Morfologi Danau Sangkuliman memiliki pengaruh yang signifikan terhadap ekosistem di sekitarnya. Danau Sangkuliman juga merupakan sumber air bagi Masyarakat disekitarnya.



Peramalan tinggi muka air maksimum (TMA) menjadi suatu proses untuk memprediksi ketinggian air tertinggi yang mungkin terjadi pada suatu lokasi, dalam hal ini Danau Sangkuliman pada waktu tertentu di masa depan. Hasil peramalan dapat dipertimbangkan pada berbagai aspek diantaranya mitigasi bencana banjir, pengelolaan sumber daya air, dan perencanaan infrastruktur (Mislani & Dani, 2024). Peramalan adalah suatu metode statistika yang digunakan untuk memprediksi apa yang akan terjadi di masa yang akan datang berdasarkan data dan informasi di masa lalu (A. T. R. Dani et al., 2023; Zen et al., 2023). Beberapa manfaat peramalan diantaranya adalah membantu pengambilan keputusan, mengurangi risiko, yang dimana sangat penting dan berguna bagi pemangku kebijakan (Permata et al., 2024; Stock & Watson, 1999). Metode peramalan yang digunakan pada penelitian ini adalah *Singular Spectrum Analysis* (Sulandari, Subanar, Lee, et al., 2020).

Singular Spectrum Analysis (SSA) adalah metode analisis runtun waktu nonparametrik yang sering digunakan untuk memodelkan data runtun waktu (Hassani & Thomakos, 2010). SSA juga memiliki kelebihan dalam memodelkan data yang mengandung pola musiman (Purnama, 2022). Konsep dasar dari SSA adalah menggunakan prinsip dekomposisi dalam memecahkan komponen data runtun waktu. Terdapat dua langkah utama dalam pemodelan SSA yaitu dekomposisi dan rekonstruksi (Movahedifar et al., 2023). Dekomposisi terdiri dari dua tahapan yaitu *embedding* dan *singular value decomposition*, sedangkan tahap rekonstruksi yaitu *grouping* dan *diagonal averaging* (Hassani & Thomakos, 2010). Terdapat beberapa penelitian sebelumnya yang menggunakan SSA, diantaranya oleh Hidayat, dkk (2020) menggunakan metode SSA untuk meramalkan jumlah titik panas di Provinsi Kalimantan Timur yang menjelaskan bahwa SSA memberikan performansi yang baik dalam meramalkan dengan *window length* yang optimal sebanyak 20 (Hidayat et al., 2020). Penelitian lain dilakukan oleh Satriani & Iknas, R (2020) menggunakan metode SSA untuk meramalkan Indeks Harga Konsumen (IHK) di Provinsi Sulawesi Selatan dengan akurasi SSA dalam memodelkan data IHK yang diukur dengan MAPE sebesar 1,32% (Satriani et al., 2020). Penelitian lainnya juga dilakukan oleh Purnama, Eka (2022) yang menggunakan metode SSA untuk meramalkan data curah hujan di Provinsi Gorontalo dengan hasil penelitian menjelaskan bahwa SSA memberikan performansi yang baik dengan MAPE sebesar 2,90% dan *window length* yang optimal sebanyak 36 (Purnama, 2022).

Tujuan dari penelitian ini adalah memperoleh hasil peramalan untuk tinggi muka air maksimum menggunakan metode SSA untuk 12 periode kedepan berdasarkan *window-length* yang optimal. Ukuran kebaikan model menggunakan *Symmetric Mean Absolute Percentage Error* (SMAPE). Harapan dari luaran penelitian ini adalah menjadi sumber informasi dan referensi bagi pemangku kebijakan dan *early warning system* terkait mitigasi bencana penduduk didaerah sekitar Danau Sangkuliman.

2. Literature Review

2.1 Analisis Periodogram

Periodogram dapat diartikan sebagai fungsi spektrum kuasa atas frekuensinya. Analisis periodogram dilakukan untuk mengetahui apakah data pengamatan dipengaruhi oleh faktor musiman (Sulandari, Subanar, Suhartono, et al., 2020). Pengujian hipotesis analisis periodogram dilakukan dengan menggunakan Persamaan (1).

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

dimana $I^{(1)}(\omega_{(1)})$ merupakan nilai periodogram terbesar dan $I(\omega_i)$ merupakan nilai periodogram pada frekuensi fourier ke- I (Wei, 2006).

2.2 Singular Spectrum Analysis

Algoritma dasar SSA terdiri dari dua tahap, yaitu dekomposisi dan rekonstruksi. Dekomposisi terdiri dari dua tahap, yaitu *embedding* dan *singular value decomposition* (SVD).

1. Embedding

Pada tahap *embedding*, data runtun waktu diubah ke dalam bentuk matriks lintasan $\mathbf{X}$ berukuran $L \times K$ dengan $2 < L < n/2$ dan $K = n - L + 1$. Matriks lintasan ditunjukkan melalui Persamaan (2) (Hidayat et al., 2020).

$$\mathbf{X} = [\mathbf{Z}_1, \mathbf{Z}_2, \dots, \mathbf{Z}_K] = \begin{bmatrix} Z_1 & Z_2 & \dots & Z_K \\ Z_2 & Z_3 & \dots & Z_{K+1} \\ \vdots & \dots & \ddots & \vdots \\ Z_L & Z_{L+1} & \dots & Z_n \end{bmatrix} \quad (2)$$

2. Singular Value Decomposition

Singular value decomposition (SVD) bertujuan untuk memperoleh pemisahan komponen dalam dekomposisi dari data runtun waktu. SVD dari matriks lintasan $\mathbf{X}$ seperti pada Persamaan (3).

$$\mathbf{X} = \mathbf{u}_1 \sqrt{\eta_1} \mathbf{v}_1^T + \mathbf{u}_2 \sqrt{\eta_2} \mathbf{v}_2^T + \dots + \mathbf{u}_r \sqrt{\eta_r} \mathbf{v}_r^T \quad (3)$$

Matriks $\mathbf{X}$ terbentuk dari vektor *eigen* ($\mathbf{u}_i$), nilai *singular* ($\sqrt{\eta_i}$) dan komponen utama ($\mathbf{v}_i^T$). Ketiga elemen pembentuk SVD ini disebut *eigentruple*.

Selanjutnya tahap rekonstruksi terdiri dari dua langkah yaitu *grouping* dan *diagonal averaging*.

1. Grouping

Grouping merupakan tahapan pengelompokan matriks $\mathbf{X}_l$ yang bertujuan untuk memisahkan komponen *eigentruple* dari tahap SVD ke dalam komponen tren, musiman, dan *noise*. Vektor eigen merupakan dasar pengelompokan dalam proses *grouping* (Hidayat et al., 2020).

2. Diagonal Averaging

Diagonal averaging adalah tahapan rekonstruksi kelompok hasil *grouping* menjadi data runtun waktu baru. *Diagonal averaging* mentransformasikan matriks hasil *grouping* ke dalam bentuk runtun kembali dengan menggunakan Persamaan (4).

$$\hat{f}_t^{(h)} = \begin{cases} \frac{1}{t} \sum_{i=1}^t y_{i,t-i+1}^{*(h)}; & \text{untuk } 1 \leq t < L^* \\ \frac{1}{L^*} \sum_{i=1}^{L^*} y_{i,t-i+1}^{*(h)}; & \text{untuk } L^* \leq t < K^* \\ \frac{1}{n-t+1} \sum_{i=t-K^*+1}^{n-K^*+1} y_{i,t-i+1}^{*(h)}; & \text{untuk } K^* \leq t < n \end{cases} \quad (4)$$

Runtun awal akan didekomposisi menjadi m komponen runtun yang direkonstruksi dimana $h=1$ untuk komponen tren dan $h=2$ untuk komponen musiman (Hidayat et al., 2020).

Peramalan metode SSA menggunakan *R-forecasting* berkaitan dengan penaksiran *Linear Recurrent Formula* (LRF). Runtun waktu hasil prediksi dan peramalan dapat ditulis dengan Persamaan (5) (Wijayanti & Kartikasari, 2023)

$$\hat{f}_t^{(h)} = \begin{cases} \hat{f}_t^{(h)} & \text{untuk } t = 1, 2, \dots, n \\ \sum_{j=1}^{L-1} r_j^{(h)} \hat{f}_{t-j}^{(h)} & \text{untuk } t = n+1, \dots, n+M \end{cases} \quad (5)$$

dengan,

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

2.3 Symmetric Mean Absolute Percentage Error

Ukuran akurasi diperlukan untuk mengukur ketepatan peramalan dari model yang diperoleh. Salah satu ukuran akurasi yang dapat digunakan adalah *Symmetric Mean Absolute Percentage Error* (SMAPE). Nilai SMAPE dapat diperoleh menggunakan Persamaan (7) (A. T. Dani et al., 2023).

$$SMAPE = \frac{2}{n} \sum_{t=1}^n \frac{|\hat{Z}_t - Z_t|}{\left(\frac{|\hat{Z}_t| + |Z_t|}{2}\right)} \times 100\% \quad (7)$$

3. Research Method and Materials

Penelitian ini menggunakan jenis penelitian kuantitatif. Data yang digunakan adalah Rata-rata Tinggi Muka Air Danau Sangkuliman periode 2015-2022 yang diperoleh melalui Dinas Lingkungan Hidup Kota Samarinda. Tahapan analisis menggunakan metode SSA, sebagai berikut:

1. Membuat grafik runtun waktu
2. Membagi data menjadi *in-sample* dan *out sample*.
3. Melakukan analisis periodogram untuk mengidentifikasi keberadaan unsur musiman pada data.
4. Melakukan pemilihan parameter *window length* (L) melalui *trial and error* berdasarkan nilai SMAPE terkecil.
5. Melakukan proses *embedding*, yaitu membentuk matriks lintasan berukuran menggunakan parameter L terbaik.
6. Mendekomposisi matriks singular dari matriks lintasan yang menghasilkan *eigentriple*.
7. Melakukan *grouping* dari hasil dekomposisi dengan membentuk grafik nilai singular dan grafik vektor eigen.
8. Melakukan pendeteksian korelasi antar komponen menggunakan matrik *w-correlation*.
9. Melakukan *diagonal averaging*, yaitu transformasi hasil *grouping* menjadi runtun baru.
10. Menghitung nilai prediksi.
11. Melakukan peramalan menggunakan koefisien *Linear Recurrent Formula* (LRF).

4. Result and Discussion

Analisis data dimulai dengan mengidentifikasi pola data runtun waktu, kemudian dilanjutkan pada tahap analisis SSA, yaitu dekomposisi dan rekonstruksi.

4.1 Deskripsi Data

Data yang digunakan pada penelitian ini yaitu data bulanan Rata-Rata Tinggi Muka Air Danau Sangkuliman periode 2015-2022 sebanyak 96. Untuk melihat pola data dibuat grafik runtun waktu yang ditampilkan pada Figure1.




Figure 1: Grafik Runtun Waktu

Berdasarkan Figure 1, dapat dilihat bahwa rata-rata tinggi muka air periode 2015-2022 cenderung mengalami penurunan dan mengandung pola musiman. Sehingga SSA cocok digunakan untuk peramalan data pada penelitian ini.

Selanjutnya membagi data menjadi *in-sample* dan *out-sample* dengan data *in-sample* sebanyak 84 data yaitu periode Januari 2015 sampai dengan Desember 2021 dan data *out-sample* sebanyak 12 data yaitu periode Januari 2022 sampai dengan Desember 2022.

4.2 Analisis Periodogram

Sebelum masuk ke tahapan analisis SSA, dilakukan analisis periodogram menggunakan Persamaan (1). Berdasarkan analisis periodogram diperoleh hasil $T = 0,33 < g_{0,05} = 0,68$ sehingga dapat disimpulkan bahwa terdapat unsur musiman pada data rata-rata tinggi muka air dengan periode musiman 12 bulan.

4.3 Singular Spectrum Analysis

4.3.1 Dekomposisi

Tahapan dekomposisi adalah menentukan parameter *window length* (L) melalui proses *trial and error* terhadap seluruh parameter L yang mungkin yaitu $3 < L < \frac{n}{2} = 3 < L < 42$. Berdasarkan kriteria SMAPE diperoleh nilai SMAPE terkecil terletak pada $L=12$. Nilai SMAPE menggunakan Persamaan (7) untuk seluruh parameter L disajikan pada Table 1.

Table 1: Perbandingan Nilai SMAPE

L	SMAPE	L	SMAPE	L	SMAPE
3	29.244	16	59.822	29	42.362
4	48.804	17	47.825	30	13.269
5	53.846	18	39.931	31	17.762
6	56.448	19	53.737	32	27.787
7	63.497	20	48.555	33	23.774
8	67.351	21	25.21	34	24.44
9	26.231	22	16.93	35	21.201
10	49.579	23	21.736	36	25.728
11	18.026	24	24.013	37	37.271
12	15.447	25	29.672	38	37.629
13	41.486	26	30.584	39	28.406
14	43.404	27	25.25	40	23.023
15	44.494	28	42.362	41	23.472

1. Embedding

Tahapan *embedding* dilakukan dengan mentransformasi data aktual runtun waktu yang berbentuk vektor ke dalam bentuk matriks lintasan $\mathbf{X}$ berukuran $L \times K$ dengan nilai $L=12$

dan $K = n - L + 1 = 84 - 12 + 1 = 73$. Hasil dari proses *embedding* menggunakan Persamaan (2) sebagai berikut:

$$\mathbf{X} = (\mathbf{Z}_1, \mathbf{Z}_2, \mathbf{Z}_3, \dots, \mathbf{Z}_{73}) = \begin{pmatrix} 2,82 & 3,67 & 2,85 & \dots & 1,22 \\ 3,67 & 2,85 & 1,67 & \dots & 1,42 \\ 2,85 & 1,67 & 2,00 & \dots & 0,63 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0,60 & 2,38 & 1,75 & \dots & 1,39 \end{pmatrix}_{(12 \times 73)}$$

2. Singular Value Decomposition

Singular Value Decomposition diawali dengan membentuk matrik *singular* $\mathbf{S} = \mathbf{X}\mathbf{X}^T$.

$$\mathbf{S} = \mathbf{X}\mathbf{X}^T = \begin{pmatrix} 203,92 & 149,80 & 100,87 & \dots & 81,59 \\ 149,80 & 197,98 & 140,35 & \dots & 42,61 \\ 100,87 & 140,35 & 184,91 & \dots & -8,65 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 81,59 & 42,61 & -8,65 & \dots & 178,09 \end{pmatrix}_{(12 \times 12)}$$

Proses SVD akan mendekomposisi matriks lintasan $\mathbf{X}$ yang diperoleh dengan Persamaan (3) menjadi 12 *eigentruple* yang terdiri dari 12 nilai eigen, 12 vektor eigen, dan 12 komponen utama.

4.3.2 Rekonstruksi

Setelah mendekomposisi data, maka tahap selanjutnya adalah rekonstruksi. Proses rekonstruksi terdiri dari *grouping* dan *diagonal averaging*.

1. Grouping

Tahap *grouping* diawali dengan melakukan pengelompokan terhadap *eigentruple* yang telah diperoleh pada tahap SVD. Grafik antara nilai *singular* dan parameter *window length* yang digunakan untuk menentukan nilai *grouping effect* (R) seperti berikut:




Figure 2: Grafik Nilai Singular

Diketahui bahwa urutan grafik yang menurun secara lambat atau perlahan dari nilai singular biasanya terkait dengan komponen *noise* dari runtun. *Eigentruple* yang telah dipisahkan pada Figure 2 menghasilkan pengelompokan yang kurang subjektif sehingga nilai *grouping effect* (R) yang diambil yaitu $R=12$ dimana akan dilakukan pemeriksaan kembali pada seluruh *eigentruple*. Untuk menentukan *eigentruple* yang memuat unsur tersebut dapat dilakukan dengan menggunakan grafik vektor eigen sebagai berikut:




Figure 3: Grafik vektor eigen


Pola grafik vektor eigen yang bervariasi lambat harus dikelompokkan ke dalam komponen tren. Berdasarkan Figure 3, dapat dilihat bahwa grafik vektor eigen 1 bervariasi secara lambat atau dengan kata lain tidak terjadi kenaikan dan penurunan yang berulang sehingga eigentriple 1 dikelompokkan ke dalam komponen tren. Selanjutnya adalah pengelompokan terhadap eigentriple yang memuat unsur musiman pada eigentriple 2 sampai dengan 12 menggunakan analisis periodogram dan diperoleh pengelompokan eigentriple seperti pada Table 2.

Table 2: Pengelompokan Eigentriple


Kelompok		Eigentriple
Tren	1	
Musiman	2,3,4,5,6,7,9,10,11, dan 12	
Noise	8	

2. Diagonal Averaging


Tahapan selanjutnya adalah *diagonal averaging*, runtun yang direkonstruksi menggunakan Persamaan (4) kemudian dibentuk grafik untuk komponen tren, musiman, dan *noise* seperti Figure 4.



(a) Tren



(b) Musiman



(c) Noise

Figure 4: Komponen yang direkonstruksi

Diagonal averaging diperoleh dari penjumlahan runtun hasil tren dan musiman hasil rekonstruksi. Runtun hasil rekonstruksi dan *diagonal averaging* dapat dilihat pada Table 3.

Table 3: Hasil Rekonstruksi dan *Diagonal Averaging*

<i>t</i>	Rekonstruksi		<i>Diagonal Averaging</i>	<i>t</i>	Rekonstruksi		<i>Diagonal Averaging</i>
	Tren	Musiman			Tren	Musiman	
1	1,59	1,35	2,94	12	0,15	0,57	0,73
2	1,75	1,94	3,68	13	0,43	1,82	2,25
3	1,68	0,96	2,64	14	0,65	1,18	1,83
4	1,45	0,37	1,83	15	0,76	0,52	1,28
5	1,14	0,89	2,03	⋮	⋮	⋮	⋮
6	0,77	0,94	1,71	79	-0,17	0,58	0,41
7	0,39	0,28	0,67	80	-0,30	-0,05	-0,35
8	0,08	0,10	0,18	81	-0,37	1,21	0,83
9	-0,10	0,23	0,12	82	-0,38	1,49	1,12
10	-0,15	0,34	0,19	83	-0,32	1,29	0,97
11	-0,05	0,29	0,24	84	-0,21	1,30	1,09

4.3.3 Peramalan SSA

Peramalan SSA yang digunakan adalah metode *R-forecasting*. Model peramalan menggunakan Persamaan (5) untuk komponen tren sebagai berikut:

$$\hat{f}_t^{(1)} = 0,02 \hat{f}_{t-1}^{(1)} + 0,02 \hat{f}_{t-2}^{(1)} + 0,02 \hat{f}_{t-3}^{(1)} + \dots + (-0,03) \hat{f}_{t-12}^{(1)}$$

Sedangkan model peramalan untuk komponen musiman adalah sebagai berikut:

$$\hat{f}_t^{(2)} = 0,89 \hat{f}_{t-1}^{(2)} + (-0,47) \hat{f}_{t-2}^{(2)} + (-0,39) \hat{f}_{t-3}^{(2)} + \dots + 1,09 \hat{f}_{t-12}^{(2)}$$

Peramalan SSA dilakukan dengan menjumlahkan hasil peramalan komponen tren dan musiman seperti pada Persamaan (6). Hal ini berlaku untuk peramalan pada data *out-sample* dan peramalan 12 periode ke depan, yaitu periode Januari 2023 sampai dengan Desember 2023. Hasil peramalan SSA disajikan pada Table 4.

Table 4: Hasil Peramalan Rata-Rata Tinggi Muka Air Danau Sangkuliman dengan Model SSA

t	Peramalan			Data Aktual	t	Peramalan			Data Aktual
	Tren	Musiman	SSA			Tren	Musiman	SSA	
85*	-0,06	2,43	2,38	1,89	97	-0,01	3,49	3,48	-
86*	-0,02	2,39	2,56	2,17	98	-0,01	4,68	4,67	-
87*	0,01	2,66	2,67	2,22	99	-0,01	5,18	5,16	-
88*	0,04	1,16	1,19	1,58	100	-0,01	5,05	5,03	-
89*	0,06	1,67	1,73	1,55	101	-0,01	4,71	4,69	-
90*	0,07	2,72	2,79	1,77	102	-0,01	6,32	6,31	-
91*	0,07	2,78	2,84	0,12	103	-0,01	7,41	7,41	-
92*	0,06	2,18	2,24	-0,72	104	-0,00	8,46	8,46	-
93*	0,04	2,82	2,87	0,15	105	-0,00	8,12	8,12	-
94*	0,03	3,93	3,96	0,07	106	0,00	8,08	8,08	-
95*	0,01	4,52	4,53	1,07	107	0,00	9,98	9,98	-
96*	-0,00	4,68	4,67	2,22	108	0,00	10,57	10,57	-

*) Hasil peramalan data *out-sample*

Hasil prediksi dan peramalan yang telah diperoleh selanjutnya disajikan dalam bentuk grafik pada Figure 5.




Figure 5: Grafik perbandingan antara data aktual dan peramalan Rata-Rata Tinggi Muka Air Danau Sangkuliman tahun 2015-2023 model SSA

Berdasarkan Figure 5, dapat dilihat bahwa pola pada grafik hasil peramalan Rata-Rata Tinggi Muka Air Danau Sangkuliman menggunakan model SSA hampir mengikuti pola data aktual. Nilai SMAPE yang diperoleh adalah sebesar 15,45% untuk data *in-sample* dan 12,92% untuk data *out-sample*.

5. Conclusion

Hasil analisis menunjukkan parameter *window-length* optimal berdasarkan nilai SMAPE terkecil adalah. Peramalan tinggi muka air menggunakan metode SSA untuk 12 periode kedepan berdasarkan *window-length* yang optimal memberikan hasil bahwa rata-rata tinggi muka air danau sangkuliman akan mengalami peningkatan pada periode Januari 2023 – Desember 2023. Tinggi muka air maksimum di Danau Sangkuliman diperkirakan akan terjadi pada periode Desember 2023, yaitu setinggi 10,57 meter.

References

- Dani, A. T., Fauziyah, M., & Sandariria, H. (2023). Forecasting The Search Trends of The Keyword “Sarung Wadimor” In Indonesia on Google Trends Data Using Time Series Regression with Calender Variation and Arima Box-Jenkins. *Jurnal Matematika, Statistika Dan Komputasi*, 19(3), 447–459. <https://doi.org/10.20956/j.v19i3.24551>
- Dani, A. T. R., Wahyuningsih, S., Putra, F. B., Fauziyah, M., Wigantono, S., Sandariria, H., A'yun, Q. Q., & Zen, M. A. (2023). Aplikasi Model ARIMAX dengan Efek Variasi Kalender untuk Peramalan Trend Pencarian Kata Kunci “Zalora” pada Data Google Trends. *Inferensi*, 6(2), 107. <https://doi.org/10.12962/j27213862.v6i2.15793>
- Hassani, H., & Thomakos, D. (2010). A review on singular spectrum analysis for economic and financial time series. In *Statistics and Its Interface* (Vol. 3).
- Hidayat, K. W., Wahyuningsih, S., & Nasution, Y. N. (2020). Pemodelan Jumlah Titik Panas Di Provinsi Kalimantan Timur Dengan Metode Singular Spectrum Analysis. *Jambura Journal of Probability and Statistics*, 1(2), 78–88. <https://doi.org/10.34312/jjps.v1i2.7287>
- Mislan, M., & Dani, A. T. R. (2024). Forecasting Maximum Water Level Data for Post Sangkuliman using An Artificial Neural Network Backpropagation Algorithm. *JTAM (Jurnal Teori Dan Aplikasi Matematika)*, 8(2), 465. <https://doi.org/10.31764/jtam.v8i2.20112>
- Movahedifar, M., Hassani, H., & Kalantari, M. (2023). Recurrent Forecasting in Singular Spectrum Decomposition †. *Engineering Proceedings*, 39(1). <https://doi.org/10.3390/engproc2023039068>
- Penton, D. J., Teng, J., Ticehurst, C., Marvanek, S., Freebairn, A., Mateo, C., Vaze, J., Yang, A., Khanam, F., Sengupta, A., & Pollino, C. (2023). The floodplain inundation history of the Murray-Darling Basin through two-monthly maximum water depth maps. *Scientific Data*, 10(1). <https://doi.org/10.1038/s41597-023-02559-4>
- Permata, R. P., Ni'mah, R., & Dani, A. T. R. (2024). Daily Rainfall Forecasting with ARIMA Exogenous Variables and Support Vector Regression. *Jurnal Varian*, 7(2), 177–188. <https://doi.org/10.30812/varian.v7i2.3202>
- Purnama, E. (2022). Aplikasi Metode Singular Spectrum Analysis (SSA) Pada Peramalan Curah Hujan Di Provinsi Gorontalo. *Jambura Journal Of Probability And Statistics*, 3(2). <https://doi.org/10.34312/jjps.v3i2.16537>
- Satriani, S., Nursalam, N., & Iknas, R. (2020). Peramalan Indeks Harga Konsumen (IHK) di Sulawesi Selatan dengan Menggunakan Metode Singular Spectrum Analysis (SSA). *Jurnal Matematika Dan Statistika Serta Aplikasinya*, 8(1), 81–89.
- Stock, J. H., & Watson, M. W. (1999). Forecasting Infation. *Journal of Monetary Economics*, 44, 293–335.
- Sulandari, W., Subanar, Lee, M. H., & Rodrigues, P. C. (2020). Indonesian electricity load forecasting using singular spectrum analysis, fuzzy systems and neural networks. *Energy*, 190. <https://doi.org/10.1016/j.energy.2019.116408>
- Sulandari, W., Subanar, Suhartono, Utami, H., Lee, M. H., & Rodrigues, P. C. (2020). Ssa-based hybrid forecasting models and applications. *Bulletin of Electrical Engineering and Informatics*, 9(5), 2178–2188. <https://doi.org/10.11591/eei.v9i5.1950>
- Wei, W. W. S. (2006). *Time Series Analysis: Univariate and Multivariate Methods* (2nd ed.). Pearson Education, Inc.
- Wijayanti, L. N., & Kartikasari, M. D. (2023). APPLICATION OF SINGULAR SPECTRUM ANALYSIS METHOD IN FORECASTING INDONESIA COMPOSITE DATA. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 17(1), 0513–0526. <https://doi.org/10.30598/barekengvol17iss1pp0513-0526>
- Zen, M. A., Wahyuningsih, S., Tri, A., Dani, R., Ekonomi, S., Bisnis, D., Statistika, S., Matematika, J., Matematika, F., Ilmu, D., Alam, P., Mulawarman, U., Samarinda, K., Timur, I., & Terapan, L. S. (2023). Aplikasi Pengelompokan Data Runtun Waktu dengan Algoritma K-Medoids. *INFERENSI*, 6(2), 2721–3862. <https://doi.org/10.12962/j27213862.vxix.xxxx>