

Rainfall Forecasting in Medan City Using Singular Spectrum Analysis (SSA)

Silvia Agustina, Fadhilah Fitri*, Dodi Vionanda, Admi Salma
Departemen Statistika, Universitas Negeri Padang, Padang, Indonesia
*Corresponding author: fadhilahfitri@fmipa.unp.ac.id

Submitted : 29 Maret 2023
Revised : 12 Mei 2023
Accepted : 17 Mei 2023

ABSTRACT

Singular spectrum analysis is a time series analysis that can be used for data that has seasonal effects. Rainfall is one example that has a seasonal effect. High rainfall has an impact on natural disasters such as floods. Medan city is the capital city of North Sumatra province which has quite high rainfall and is a lowland area, so it has the potential for flooding. Rainfall forecasting can be done as disaster mitigation. The forecasting method used is SSA. The MAPE forecasting accuracy value obtained is 15.5% and the tracking signal is within tolerance limits, so that it can be concluded that the forecasting is done well.

Keywords: forecasting, Singular Spectrum Analysis (SSA), Rainfall



This is an open access article under the Creative Commons 4.0 Attribution License, which permits unrestricted use, distribution, and reproduction in medium, provided the original work is properly cited. ©2022 by author and Universitas Negeri Padang.

I. PENDAHULUAN

Curah hujan merupakan bagian dari iklim. Balai Besar Meteorologi, Klimatologi dan Geofisika Wilayah III (BBMKG Wil III) mendefinisikan bahwa curah hujan merupakan ketinggian air yang jatuh pada penangkar air hujan yang diasumsikan bahwa air tersebut tidak menguap, meresap dan mengalir. Indonesia termasuk kedalam negara dengan curah hujan yang cukup tinggi karena wilayah Indonesia terletak dalam wilayah tropis (Sadita, 2017).

Secara Geografis Kota Medan berbatasan secara langsung dengan Selat Malaka. Letak tersebut mempengaruhi kelembapan udara. Rata-rata kelembapan udara tertinggi Kota Medan adalah 83.6 % yang terjadi pada bulan Desember 2022. Penelitian yang dilakukan Pradipta (2013) menyimpulkan bahwa curah hujan di Kota Medan dipengaruhi oleh kelembapan udara dan kecepatan angin. Curah hujan Kota Medan berdasarkan pemantauan dari stasiun BBMKG Wilayah 1 tahun 2022 mencatat bahwa curah hujan tertinggi adalah 513,6 mm dan rata-rata curah hujan bulanan adalah 291,2 mm.

Kota Medan dilalui oleh Sungai Bengawan, Sungai Deli dan Sungai Denai. Kondisi tersebut dapat menyebabkan potensi bencana alam seperti bencana banjir terjadi. Pada bulan November 2022 terjadi bencana banjir pada 9 kecamatan di Kota Medan yang mengakibatkan 1843 KK terdampak. Banjir tersebut disebabkan oleh intensitas curah hujan yang tinggi (Kemkes, 2022). Oleh karena itu, peramalan terhadap curah hujan Kota Medan penting dilakukan.

Peramalan dapat diartikan sebagai metode yang digunakan untuk mendapatkan gambaran nilai suatu kejadian untuk beberapa periode ke depan. Salah satu metode peramalan adalah *Singular Spectrum Analysis* (SSA). Ide utama SSA adalah membuat dekomposisi dari data time series menjadi sejumlah kelompok yang saling lepas seperti trend, musiman dan *noise* (Rocco, 2013). SSA dapat diterapkan pada data yang mempunyai efek musiman. Salah satu yang terdapat efek musiman adalah curah hujan. Oleh karena itu, SSA digunakan dalam meramalkan curah hujan Kota Medan.

Penelitian dengan menggunakan SSA pernah dilakukan Fitri (2020) dalam meramalkan curah hujan di Provinsi Sumatera Barat dan diperoleh MAPE sebesar 17%. Penelitian lainnya juga dilakukan oleh Hardi (2019) dalam meramalkan Produk Domestik Bruto (PDB) menggunakan metode SSA dan diperoleh MAPE sebesar 1,59 %. Pada penelitian ini akan dilakukan peramalan curah hujan di Kota Medan menggunakan *Singular Spectrum Analysis* (SSA).

II. METODE PENELITIAN

A. Jenis Penelitian dan Sumber Data

Penelitian yang dilakukan merupakan penelitian terapan, dengan menerapkan metode *Singular Spectrum Analysis* (SSA) dalam meramalkan curah hujan Kota Medan. Data curah hujan Kota Medan yang diperoleh berasal dari website Badan Meteorologi, Klimatologi dan Geofisika (BMKG) berdasarkan pemantauan stasiun BBMKG Wilayah 1 pada pengamatan bulan Januari 2018 sampai Desember 2022.

B. Teknik Analisis Data

Analisis data yang dilakukan adalah *Singular Spectrum Analysis* (SSA). Adapun langkah-langkah analisis menurut Fitri (2020) dengan menggunakan SSA adalah sebagai berikut.

1. Melakukan eksplorasi data dengan melihat plot data curah hujan Kota Medan pada pengamatan bulan Januari 2018 sampai Desember 2022
2. Membagi data menjadi data latih dan data uji. Perbandingan data latih dan data uji yang digunakan adalah 90% untuk data latih dan 10 % untuk data uji. Data latih digunakan dari bulan Januari 2018 sampai bulan Juni 2022, sedangkan data uji yang digunakan adalah bulan Juli 2022 sampai Desember 2022.
3. Melakukan *embedding*. *Embedding* merupakan tahapan SSA untuk mengubah data deret waktu satu dimensi ke dalam multidimensi. Hasil dari *embedding* merupakan matriks *trajectory* berukuran $L \times K$. L disebut sebagai *window length*. Nilai L ditentukan secara *trial and error* yang nilainya diantara $2 \leq L \leq N/2$ (Hassani, 2018: 3). Nilai L dengan MAPE terkecil akan digunakan untuk tahapan selanjutnya. Kemudian nilai K diperoleh dengan persamaan 1.

$$K = N - L + 1 \tag{1}$$

Matriks *trajectory* yang terbentuk adalah sebagai berikut.

$$X = [X_1, X_2, \dots, X_K] = (x_{ij})_{i,j=1}^{L,K}$$

$$X_{L \times K} = \begin{bmatrix} x_1 & x_2 & \dots & x_K \\ x_2 & x_3 & \dots & x_{K+1} \\ x_3 & x_4 & \dots & x_{K+2} \\ \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & \dots & x_N \end{bmatrix} \tag{2}$$

4. Melakukan *singular value decomposition* (SVD). SVD akan menghasilkan *eigentriple*. *Eigentriple* terdiri dari *eigenvector* (U_i), *singular value* ($\sqrt{\lambda_i}$), dan *principal component* (V_i). Nilai *singular value* ($\sqrt{\lambda_i}$), dan *eigenvector* (U_i) diperoleh dari dekomposisi matriks $S = XX^T$. Nilai *principal component* diperoleh dari persamaan (2) berikut:

$$V_i = \frac{x^T U_i}{\sqrt{\lambda_i}} \tag{3}$$

SVD dari matriks X dapat dituliskan sebagai berikut:

$$\begin{aligned} X &= X_1 + X_2 + \dots + X_d \\ X &= \sqrt{\lambda_1} U_1 V_1^T + \sqrt{\lambda_2} U_2 V_2^T + \dots + \sqrt{\lambda_d} U_d V_d^T \\ X &= \sum_{i=1}^d \sqrt{\lambda_i} U_i V_i^T \end{aligned}$$

5. Melakukan *grouping*. Hasil dari SVD dikelompokkan ke dalam kelompok-kelompok seperti trend, musiman dan *noise*. Pengelompokkan dilakukan berdasarkan *trial and error*. Ekspansi matriks hasil SVD menyebabkan dekomposisi sebagai berikut.

$$X_{ij} = X_{i_1} + \dots + X_{i_m}$$

6. Melakukan *diagonal averanging*. *Diagonal averanging* merupakan tahapan SSA untuk mengkonversi setiap matriks X_{ij} yang dikelompokkan pada tahapan *grouping* menjadi data baru dengan panjang yang sama seperti data awal (Isnawati, 2018). Misalkan diketahui matriks $Y = L \times K$, dan elemen matriks y_{ij} . *Diagonal averanging* (Golyandina, 2013) untuk mengubah matriks Y menjadi deret waktu g_0, \dots, g_{N-1} adalah sebagai berikut:

$$g_k = \frac{\sum_{(l,k) \in A_s} y_{lk}}{|A_s|}$$

Dimana $|A_s|$ merupakan jumlah elemen dalam matriks X_{ij} . y_{lk} merupakan elemen diagonal matriks X_{ij} . g_k merupakan rata-rata elemen di sepanjang diagonal matriks. Untuk $k = 1$ diperoleh $g_1 = y_{11}$, $k = 2$ diperoleh $g_2 = \frac{(y_{12} + y_{21})}{2}$ dan seterusnya.

7. Melakukan peramalan. Model pada *R-Forecasting* dibangun berdasarkan koefisien *Linear Recurrent Formula* (LRF). Perhitungan koefisien LRF menggunakan persamaan (4) berikut.

$$\mathfrak{R} = (a_{L-1}, \dots, a_1)^T = \frac{1}{1 - v^2} \sum_{i=1}^r \pi_i U_i^v \tag{4}$$

Dimana $U = (u_1, u_2, \dots, u_{L-1}, u_L)^T$, $U^V = (u_1, u_2, \dots, u_{L-1})^T$, π_i merupakan komponen terakhir dari vector U dan $v^2 = \sum_{i=1}^r \pi_i^2$ (Kaimuddin, 2021).

Model peramalan RSSA diperoleh dengan menggunakan persamaan berikut.

$$g_i = \begin{cases} \tilde{y}_i & \text{untuk } i = 0, \dots, N \\ \sum_{j=1}^{L-1} a_j g_{i-j} & \text{untuk } i = N + 1, \dots, N + h \end{cases}$$

8. Menghitung nilai akurasi peramalan yaitu nilai *Mean Absolute Percentage Error* (MAPE) dan keandalan peramalan yaitu *tracking signal* pada hasil peramalan data uji. Persamaan MAPE dapat dituliskan sebagai berikut.

$$MAPE = \frac{\sum_{i=1}^t \left| \frac{y_t - \hat{y}_t}{y_t} \right|}{N} \times 100\% \quad (5)$$

dimana y_t = data deret waktu aktual dan \hat{y}_t = data hasil peramalan.

Tracking Signal (TS) merupakan batas toleransi untuk menentukan hasil peramalan dapat digunakan. Batas *control tracking signal* adalah ± 4 (Puspitasari, 2023). Nilai TS dapat dihitung melalui persamaan berikut.

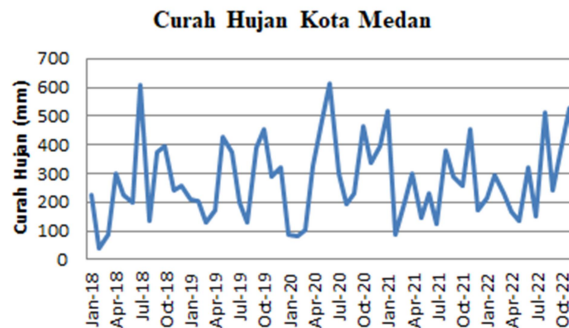
$$Tracking\ signal = \frac{\sum_1^n e_n}{\sum_1^n \frac{|e_n|}{n}} \quad (6)$$

dimana e_n = jumlah kesalahan peramalan dan n = jumlah observasi data

9. Melakukan peramalan curah hujan Kota Medan untuk 24 periode selanjutnya

III. HASIL DAN PEMBAHASAN

A. Identifikasi Pola Data



Gambar 1. Curah hujan Kota Medan 2018-2022

Curah hujan Kota Medan pengamatan bulan Januari 2018 sampai Desember 2022 ditampilkan dalam Gambar 1. Berdasarkan Gambar 1 diatas terlihat bahwa Kota Medan mengalami puncak curah hujan setiap tahunnya melebihi 400 mm. Bulan Juni 2020 merupakan curah hujan dengan intensitas tertinggi sebesar 615 mm. Curah hujan dengan intensitas terendah sebesar 39.1 mm terjadi pada bulan Februari 2018. Pada Gambar 1 dapat dilihat bahwa curah hujan Kota Medan mempunyai pola musiman.

B. Singular Spectrum Analysis (SSA)

1. Dekomposisi

a. Embedding

Embedding merupakan langkah awal yang dimulai dengan menentukan nilai *window length* (L). Nilai L diperoleh dengan MAPE terkecil berdasarkan *trial and error* adalah 22. Dengan demikian nilai K yang diperoleh berdasarkan persamaan (1) adalah 33. Sehingga ukuran matriks *trajectory* adalah 22×33 . Matriks *trajectory* yang terbentuk adalah seperti persamaan (2).

$$X = [X_1, X_2, \dots, X_K] = (x_{ij})_{i,j=1}^{35,118} = \begin{pmatrix} 224.3 & 39.1 & \dots & 229.1 \\ 39.1 & 88.6 & \dots & 465.7 \\ \vdots & \vdots & \ddots & \vdots \\ 455.6 & 291.5 & \dots & 319.2 \end{pmatrix}$$

b. *Singular Value Decomposition (SVD)*

Tahapan SVD akan menghasilkan *Singular value* ($\sqrt{\lambda_i}$), *eigenvector* (U_i), dan *principal component* (V_i) yang disebut sebagai komponen *eigen triple*.


1). *Singular value* ($\sqrt{\lambda_i}$)

Tabel 1 merupakan hasil perhitungan *singular value*.

Tabel 1. *Singular value* ($\sqrt{\lambda_i}$)

No	<i>Singular value</i> ($\sqrt{\lambda_i}$)
1	7671.103
2	1432.137
⋮	⋮
22	349.61

Nilai *singular value* yang diperoleh dapat divisualisasikan seperti gambar 2 berikut.



Gambar 2. Plot Singular Value

Berdasarkan Tabel 1 dan Gambar 2 terlihat bahwa *singular value* pertama mempunyai nilai yang lebih besar dibandingkan dengan nilai lainnya. Hal tersebut menunjukkan bahwa *eigen triple* pertama mempunyai pengaruh terbesar terhadap pembentukan komponen *signal*.

2). *Eigenvector* (U_i)

Nilai *eigenvector* digunakan untuk membantu dalam tahapan *grouping*. Tabel 2 merupakan hasil perhitungan nilai *eigenvector*.

Tabel 2. Nilai *eigenvector*

No	U_1	U_2	...	U_{22}
1	-0.200	0.206	...	0.001
2	-0.206	0.207	...	0.098
⋮	⋮	⋮	⋮	⋮
22	-0.209	-0.019	...	0.15

Nilai *eigenvector* diatas dapat divisualisasikan seperti gambar 3 untuk mempermudah dalam melihat karakteristik setiap komponen. Nilai *eigenvector* dapat membantu dalam proses identifikasi pengelompokkan.

3). *Principal component* (V_i)

Principal component (V_i) diperoleh dari *singular value* dan *eigenvector*. Nilai *principal component* dihitung berdasarkan persamaan (3). Tabel 3 merupakan hasil perhitungan *principal component*.

Tabel 3. Nilai *principal component*

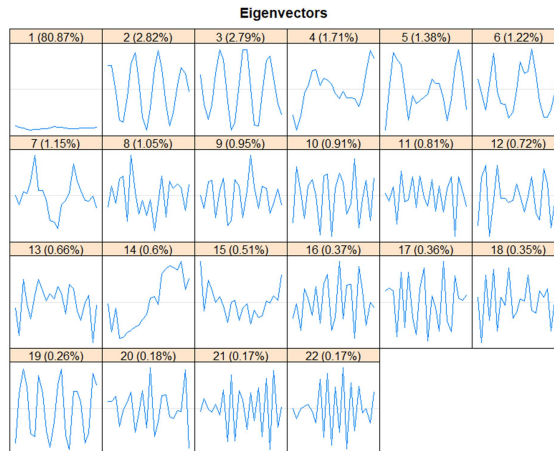
No	V_1	V_2	...	V_{22}
1	-0.161	-0.102	...	-0.049
2	-0.163	-0.078	...	-0.038
⋮	⋮	⋮	⋮	⋮
33	-0.165	-0.006	...	0.149

Hasil dari tahap SVD akan digunakan dalam membantu identifikasi tiap komponen untuk tahap selanjutnya yaitu tahapan *grouping*.

2. Rekonstruksi

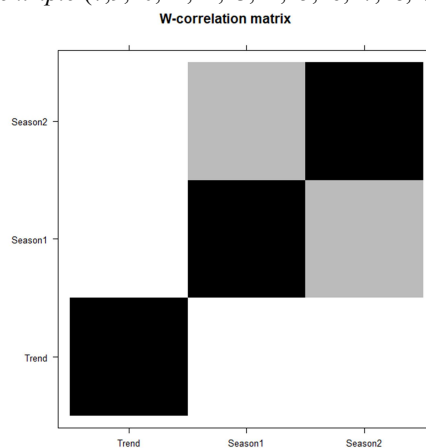
a. *Grouping*

Grouping merupakan tahapan dalam SSA untuk membedakan komponen antara *signal* dan *noise*. Komponen *signal* terdiri dari Trend dan musiman. Pada Gambar 2, terlihat bahwa *singular value* menurun secara lambat dari *singular value* 3 sampai *singular value* 22. Untuk melihat komponen trend dan komponen musiman dapat dilihat dengan bantuan plot *eigenvector* Gambar 3.



Gambar 3. Grafik *Eigenvector*

Berdasarkan Gambar 3, *eigenvector* 1 membentuk pola trend sehingga dapat dikatakan bahwa *eigentruple* 1 dikelompokkan sebagai trend. *Eigenvector* 2 sampai 22 mempunyai bentuk pola yang tidak beraturan sehingga untuk penentuan komponen musiman dilakukan secara *trial and error*. Berdasarkan hasil *trial and error*, pengelompokan yang terbentuk dengan MAPE terkecil adalah 3 kelompok yaitu trend, Musiman1 dan Musiman 2. Komponen trend yaitu *eigentruple* 1, komponen musiman 1 terdiri dari *eigentruple*(2,3,4,5,6,8) dan komponen musiman 2 terdiri dari *eigentruple* (7,9,10,11,12,13,14,15,16,17,18,19, dan 20).



Gambar 4. *W-correlation*

Gambar 4 merupakan grafik *w-correlation*. Grafik *w-correlation* digunakan untuk melihat keterpisahan antara kelompok yang terbentuk. Pengelompokan yang baik adalah jika tidak terdapat korelasi yang kuat antar kelompok. Hal tersebut dapat dilihat dari gradasi warna yang terdapat antar kelompok. Berdasarkan Gambar 4 dapat disimpulkan bahwa pengelompokan antara trend dengan musiman tidak terdapat korelasi, sedangkan kelompok musiman 1 dengan musiman 2 memiliki korelasi, namun korelasi yang terjadi lemah.

b. *Diagonal Averaging*

Diagonal averaging merupakan tahapan untuk membentuk deret waktu yang baru berdasarkan tiga kelompok yang terbentuk pada tahapan *grouping*.

Tabel 4. Hasil rekonstruksi

No	Data	Hasil rekonstruksi			<i>Diagonal Averaging</i>
		Trend	Musiman 1	Musiman 2	
1	224.3	248.1830	-22.4058	-0.8466	224.9306
2	39.1	253.6945	-151.8523	-64.6033	37.2389
⋮	⋮	⋮	⋮	⋮	⋮
54	319.2	265.8870	-5.3574	51.1696	311.6992

Hasil *diagonal averaging* diatas merupakan penjumlahan dari 3 kelompok yang direkonstruksi yaitu kelompok trend, kelompok musiman 1 dan kelompok musiman 2. Hasil *diagonal averaging* ini akan digunakan dalam peramalan.

3. *R-Forecasting*

Peramalan dalam SSA dibangun berdasarkan koefisien *linear recurrent formula* (LRF). Koefisien LRF diperoleh menggunakan persamaan (4). Hasil perhitungan koefisien LRF disajikan dalam tabel 5 berikut.

Tabel 5. Koefisien LRF

Koefisien	
a_1	0.025
a_2	0.569
⋮	⋮
a_{21}	0.944

Koefisien LRF yang diperoleh pada Tabel 5, selanjutnya digunakan untuk melakukan peramalan pada data uji. Hasil Peramalan data uji ditampilkan dalam Tabel 6 berikut.

Tabel 6. Hasil Peramalan data uji

Periode	Data Aktual (data uji)	Data Ramalan
Juli 2022	150.4	159.9124
Agustus 2022	513.6	390.8269
September 2022	242.7	267.5233
Oktober 2022	376.3	509.1028
November 2022	525.9	479.0947
Desember 2022	321.2	349.6587

C. Akurasi Peramalan

Akurasi peramalan menggunakan nilai *Mean Absolute Percentage Error* (MAPE) dan *Tracking Signal* (TS).

1. *Mean Absolute Percentage Error* (MAPE)

Menurut Chang (2007) nilai MAPE yang berada dibawah 20% dapat dikatakan peramalan yang dihasilkan baik. Nilai MAPE diperoleh berdasarkan persamaan (5). MAPE yang dihasilkan pada penelitian ini adalah 15.5%, sehingga dapat disimpulkan bahwa nilai L sebesar 22 dengan menggunakan *singular spectrum analysis* (SSA) baik dalam meramalkan curah hujan Kota Medan .

2. *Tracking signal* (TS)

Tabel 7. Nilai *Tracking signal*

Periode	Aktual	Forecast	<i>Tracking Signal</i>
1	150.4	159.9124	-1
2	513.6	390.8269	1.712368
3	242.7	267.5233	1.688716
4	376.3	509.1028	-0.61212
5	525.9	479.0947	0.036231
6	321.2	349.6587	-0.4275

Perhitungan *tracking signal* adalah melalui persamaan (6). Berdasarkan Tabel 7 nilai batas kontrol berada ± 4 sehingga dapat disimpulkan bahwa metode SSA masih bisa digunakan dalam melakukan peramalan curah hujan Kota Medan periode selanjutnya karena nilai *tracking signal* berada dalam batas kontrol.

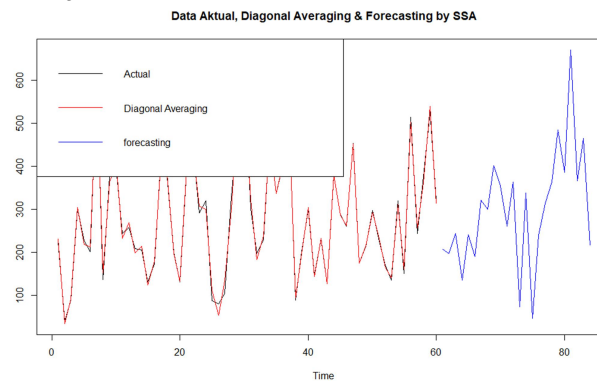
D. Peramalan

Peramalan curah hujan kota medan untuk 24 periode kedepan disajikan dalam Tabel 8 berikut.

Tabel 8. Peramalan curah hujan Kota Medan

Periode	Hasil ramalan	Periode	Hasil ramalan
Januari 2023	206.70	Januari 2024	72.05
Februari 2023	197.15	Februari 2024	337.55
Maret 2023	242.60	Maret 2024	46.01
April 2023	133.96	April 2024	238.81
Mei 2023	240.88	Mei 2024	313.57
Juni 2023	189.88	Juni 2024	363.36
Juli 2023	320.98	Juli 2024	483.82
Agustus 2023	299.82	Agustus 2024	385.69
September 2023	400.88	September 2024	669.97
Oktober 2023	354.18	Oktober 2023	366.08
November 2023	259.58	November 2024	464.20
Desember 2023	362.67	Desember 2024	215.86

Berdasarkan Tabel 8 diatas, terlihat bahwa hasil peramalan curah hujan tertinggi pada Tahun 2023 dan 2024 terjadi pada bulan September. Selanjutnya hasil peramalan curah hujan dengan intensitas rendah terjadi pada bulan April pada tahun 2023 dan bulan Maret pada tahun 2024. Grafik hasil peramalan curah hujan Kota Medan disajikan dalam gambar 5 berikut.



Gambar 5. Data Aktual, Diagonal Averaging dan Peramalan curah hujan Kota Medan tahun 2023 dan 2024

Gambar 5 merupakan grafik perbandingan antara data aktual, hasil diagonal averaging dan hasil peramalan untuk 24 periode. Berdasarkan gambar 5, hasil diagonal averaging yang diperoleh mengikuti pola data aktual. Hasil ramalan curah hujan Kota Medan pada awal periode terlihat mengalami kenaikan.

IV. KESIMPULAN

Peramalan curah hujan Kota Medan dengan menerapkan *Singular Spectrum Analysis* (SSA) diperoleh akurasi peramalan MAPE sebesar 15,5 %. Berdasarkan nilai MAPE dan *tracking signal* yang berada dalam batas kontrol dapat dikatakan bahwa peramalan yang dilakukan baik. Berdasarkan Gambar 5, peramalan curah hujan Kota Medan pada tahun 2024 lebih tinggi dari tahun 2023. Pada tahun 2023 curah hujan kota Medan berada dalam rentang 200 – 400 mm, sedangkan peramalan curah hujan Kota Medan tahun 2024 mencapai 600 mm. Peramalan curah hujan Kota Medan dapat menjadi referensi bagi pemerintah daerah Kota Medan untuk menangani bencana alam yang disebabkan oleh curah hujan.

DAFTAR PUSTAKA

- Fitri, F., Rahmat, R., & Pengestuti, A. D. (2020, May). Forecasting of rainfall in Sumatera Barat: singular spectrum analysis (SSA) application. In *Journal of Physics: Conference Series* (Vol. 1554, No. 1, p. 012047). IOP Publishing.
- Golyandina, N., Nekrutkin, V., & Zhigljavsky, S., A. (2001). *Analysis of Time Series Structure SSA and Related Techniques*, London: Chapman & Hall/CRC.
- Hardi, D., T., Safitri, D. dan Rusgiyono, A. 2019. Peramalan Produk Domestik Bruto (PDB) Sektor Pertanian, Kehutanan, dan Perikanan Menggunakan Singular Spectrum Analysis (SSA). *Jurnal Gaussian*, 8(1), 68-80.
- Hassani, H., Mahmoudvand, R. 2018. *Singular Spectrum Analysis Using R*. Palgrave Macmillan.
- Golyandina, N., & Zhigljavsky, S. A. (2013). *Singular Spectrum Analysis for Time Series*.-Springer Heidelberg New York Dordrecht London.
- Isnawati, Salafyah. 2018. "Model Hibrida Singular Spectrum Analysis dan Automatic ARIMA untuk Peramalan Air Terjual di PDAM Giri Tirta Sari Kabupaten Wonogiri Jawa Tengah", *Tugas Akhir*, 165 Hal., Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia, Januari 2018.
- Pradipta, N. S., Sembiring, p., & Bangun, P. (2013). Analisis pengaruh curah hujan di Kota Medan, *Saintia Matematika*, 1(5), 459 – 468.
- Puspitasari, E., Eltivia, N., & Riwijanti, N. I. (2023). Inventory Forecasting Analysis using The Weighted Moving Average Method in Go Public Trading Companies: English. *Journal of Applied Business, Taxation and Economics Research*, 2(3), 266-278
- Rocco S, C. M. (2013). Singular spectrum analysis and forecasting of failure time series. *Reliability Engineering and System Safety*, 114, 126-136
- Sadita, L., D. 2017. Peramalan Curah Hujan di Kabupaten Bojonegoro dengan Metode ARIMA Box-Jenkins, *Tugas Akhir*, 156 Hal, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia, Juli 2015.