

# Prediksi Parameter Klimatologi Meliputi Curah hujan, Temperatur, Kecepatan Angin, Kelembaban Udara, dan Durasi Penyinaran Matahari Menggunakan Multivariate Singular Spectrum Analysis (MSSA)

Wika Dianita Utami<sup>1</sup>, Putroue Keumala Intan<sup>2</sup>

<sup>1,2</sup>Program Studi Matematika, Fakultas Sains dan Teknologi, UIN Sunan Ampel Surabaya  
Jalan Dr. Ir. H. Soekarno No. 682, Surabaya 60294, Indonesia

Korespondensi: Putroue Keumala Intan, Email: ptroue@uinsa.ac.id

## Abstrak

Curah hujan, temperatur, kecepatan angin, kelembaban udara, dan penyinaran matahari adalah parameter klimatologi. Perubahan parameter klimatologi yang signifikan mengakibatkan terjadinya bencana alam seperti banjir, angin kencang, puting beliung, tanah longsor, cuaca ekstrem hingga kekeringan. Informasi parameter klimatologi sangat dibutuhkan pada berbagai sektor kehidupan, misal pertanian, pariwisata, dan transportasi. Oleh karena itu, informasi tentang parameter klimatologi dibutuhkan di masa depan sebagai upaya mitigasi bencana. Penelitian ini bertujuan untuk memprediksi perubahan parameter klimatologi menggunakan *Multivariate Singular Spectrum Analysis* (MSSA). Data yang digunakan adalah data harian parameter klimatologi di Malang periode Januari 2023 hingga Mei 2024. Hasil pengolahan data penelitian menggunakan software R menunjukkan nilai model MSSA dengan  $M = 50$ , *Grouping Effect (r)* = 12 dan nilai MAD terkecil menghasilkan prediksi parameter klimatologi di Malang bulan Juni 2024 meliputi temperatur suhu  $25.45^{\circ}\text{C}$ , kelembapan 77.23%, curah hujan 10.56 mm, penyinaran matahari 5.94 jam, dan kecepatan angin 1.84 m/s.

**Kata Kunci:** klimatologi, prediksi, mitigasi bencana, MSSA

## Abstract

Rainfall, temperature, wind speed, air humidity, wind direction and solar radiation are climatological parameters. Significant changes in climatological parameters result in natural disasters such as floods, strong winds, tornadoes, landslides, extreme weather and drought. Information on climatological parameters is needed in various sectors of life, such as agriculture, tourism, and transportation. Therefore, information on climatological parameters is needed in the future as a disaster mitigation effort. This research aims to forecast changes in climatological parameters using Multivariate Singular Spectrum Analysis (MSSA). The data used is daily data of climatological parameters in Malang from January 2023 to May 2024. The results showed the value of the MSSA model with  $M = 50$ , *Grouping Effect (r)* = 12 and the smallest MAD value resulted in the forecasting of climatological parameters in Malang in June 2024 including temperature  $25.45^{\circ}\text{C}$ , air humidity 77.23%, rainfall 10.56 mm, sunshine duration 5.94 hours, and wind speed 1.84 m/s.

**Keywords:** climatology, forecasting, disaster mitigation, MSSA

---

## Pendahuluan

Klimatologi adalah ilmu yang mempelajari iklim dan bagaimana iklim berubah seiring waktu [1]. Perubahan iklim di bumi diakibatkan oleh pemanasan global yang berdampak signifikan terhadap perubahan curah hujan, temperatur, kecepatan angin, kelembaban udara, arah angin dan penyinaran matahari [2]. Curah hujan, temperatur, kecepatan angin, kelembaban udara, arah angin dan penyinaran matahari dikatakan sebagai parameter klimatologi. Parameter klimatologi yang berubah signifikan akan

mengakibatkan terjadinya bencana alam seperti banjir, angin kencang, puting beliung, tanah longsor, cuaca ekstrem hingga kekeringan.

Indonesia merupakan negara yang rawan terhadap bencana alam. Berdasarkan infografis data bencana Indonesia 2023, pada tahun 2023 terdapat 5.400 kejadian bencana yang tersebar di seluruh wilayah di Indonesia, jumlah tersebut naik dibandingkan dengan tahun sebelumnya yaitu 3.544. Sekitar 99,35% adalah bencana hidrometeorologi, yaitu bencana yang dipengaruhi oleh cuaca dan aliran permukaan. Rincian kejadian bencana tersebut terdiri dari kebakaran hutan dan lahan (2.051), cuaca ekstrem (1.261), banjir (1.255), tanah longsor (591), kekeringan (174), gelombang pasang dan abrasi (33), gempabumi (31) dan letusan gunungapi (4) [3].

Lebih lanjut, hingga bulan April 2024 tercatat telah terjadi 122 kali kejadian bencana yang melanda wilayah Indonesia. Dari total kejadian bencana yang terjadi, sebesar 98,36% merupakan bencana hidrometeorologi baik hidrometeorologi kering maupun basah (meliputi banjir, tanah longsor, puting beliung, gelombang pasang, dan kekeringan), selebihnya merupakan kejadian bencana geologi (meliputi gempa bumi, gunung meletus, tanah longsor, tsunami). Jawa Timur adalah salah satu provinsi di Indonesia yang wilayahnya berpotensi terjadi bencana alam dampak cuaca ekstrem. Pada bulan April 2024, Provinsi Jawa Timur menempati urutan ketiga dengan jumlah kejadian bencana terbanyak [4]. Kota Malang adalah salah satu kota di Jawa Timur yang berdampak bencana alam. Berdasarkan data BPS tahun 2023, sebanyak 353 kejadian bencana yang meliputi banjir, tanah longsor, cuaca ekstrem dan gempa bumi [5]. Kejadian bencana tersebut mengakibatkan dampak korban jiwa, kerusakan dan kerugian ekonomi. Akibatnya, perlu dilakukan mitigasi bencana sebagai upaya mengurangi risiko bencana.

Prediksi perubahan parameter klimatologi di masa depan diperlukan, dimana hasil prediksi yang diperoleh diharapkan mampu menjadi salah satu upaya untuk memitigasi bencana yang akan terjadi di masa depan. Penelitian terdahulu telah melakukan prediksi terhadap curah hujan [6], [7], prediksi kekeringan [8], dan prediksi banjir [9]. Lebih lanjut, parameter klimatologi merupakan data multivariat deret waktu. Data deret waktu sangat memperhatikan data kejadian sebelumnya untuk memprediksi data yang akan datang. Data parameter klimatologi merupakan data deret waktu multivariat yang bekerja bersamaan karena terdiri dari data deret waktu majemuk. Secara keseluruhan, interaksi kompleks antara curah hujan, temperatur, kecepatan angin, kelembaban udara dan penyinaran matahari membentuk kondisi iklim dan cuaca di suatu wilayah. Sehingga pada penelitian ini akan dilakukan dilakukan prediksi data parameter klimatologi menggunakan model *Multivariate Singular Spectrum Analysis* (MSSA). Metode MSSA adalah perluasan konsep analisis suatu deret waktu *Singular Spectrum Analysis* (SSA). SSA bertujuan untuk menguraikan deret waktu menjadi pola-pola yang kompleks dan kecenderungan yang tidak stasioner. Kemudian merekonstruksi deret waktu tersebut dengan memilih tren dan elemen-elemen utama. Pendekatan ini bersifat non-parametrik dan bebas dari beberapa batasan, seperti asumsi stasioneritas dan kenormalan deret waktu [10]. Sehingga, MSSA dapat dikatakan sebagai metode yang lebih fleksibel daripada metode pemodelan standar yang melibatkan setidaknya satu dari asumsi linearitas, normalitas, dan stasioneritas [11].

Salah satu penelitian terdahulu yang menggunakan SSA dalam memprediksi tinggi gelombang air laut diperoleh MAPE 10,01% [12] dan curah hujan diperoleh MSE 4.79 [13]. Penelitian terdahulu, Penelitian Xuegeng Mau dkk (2019) menggunakan MSSA untuk menganalisa rangkaian waktu lalu lintas [10]. Penelitian Minhuy dkk (2020) memprediksi ekstraksi efisien sinyal detak jantung dalam campuran dengan sinyal pernapasan dan *noise* diperoleh MAPE 3,44% [14]. Serta, penelitian Aris Marjuni (2022) menggunakan metode MSSA dalam memprediksi harga saham dengan diperoleh akurasi MAPE harga pembukaan saham sebesar 3,18% dan harga penutupan saham sebesar 3,21% [15].

Penelitian ini menerapkan metode MSSA untuk memprediksi parameter klimatologi multivariat, meliputi curah hujan, temperatur, kecepatan angin, kelembaban udara, dan penyinaran matahari di stasiun BMKG Kabupaten Malang secara terintegrasi. Penelitian ini berbeda dari penelitian terdahulu yang umumnya menggunakan SSA untuk memprediksi satu parameter klimatologi, seperti curah hujan,

penelitian ini menekankan analisis data deret waktu multivariat dari parameter klimatologi yang saling berinteraksi secara kompleks dan memiliki dampak langsung terhadap risiko bencana. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi yang signifikan dalam mendukung pengambilan keputusan mitigasi bencana berbasis data klimatologi multivariat.

## Landasan Teori

### 1. Multivariate Singular Spectrum Analysis (MSSA)

*Multivariate Singular Spectrum Analysis* (MSSA) adalah perkembangan dari metode *Singular Spectrum Analysis* (SSA). Metode SSA bekerja pada satu deret waktu, sementara MSSA beroperasi pada sistem atau beberapa deret waktu (dua atau lebih) secara bersamaan dan pada waktu yang sama. MSSA melibatkan dua tahap utama, yaitu dekomposisi deret waktu menjadi komponen-komponen utama deret waktu dan rekonstruksi kembali deret waktu tersebut menjadi model peramalan dengan menggunakan komponen-komponen utama tersebut [10].

#### Tahap 1: Dekomposisi

Tujuan dari dekomposisi deret waktu adalah untuk mengidentifikasi dan memisahkan deret waktu ke dalam komponen-komponen utama yang dapat diinterpretasikan, seperti tren, siklus dan *noise*. Proses dekomposisi sistem deret waktu ini melibatkan dua tahap utama. Tahap pertama pembentukan matriks trayektori Hankel dan menentukan *Singular Value Decomposition* (SVD) dari sistem matriks trayektori yang telah dibentuk. Misalkan diketahui  $P$  deret waktu berukuran  $N$ , yaitu:

$$X = \{x_i^{(p)} | p = 1, 2, \dots, P; i = 1, 2, \dots, N\} \quad (1)$$

Proses penyematan deret waktu dilakukan dengan cara mentransformasikan vektor deret waktu

$$X^{(p)} = (x_1^{(p)}, x_2^{(p)}, \dots, x_N^{(p)}) \quad (2)$$

menjadi matriks multidimensi

$$[Y_1^{(p)}, Y_2^{(p)}, \dots, Y_K^{(p)}] \quad (3)$$

dengan  $Y_i^{(p)} = (x_i^{(p)}, x_{i+1}^{(p)}, \dots, x_{i+M-1}^{(p)}) \in R^M$ ,  $M$  adalah *window length* ( $2 \leq M \leq N$ ) untuk setiap deret waktu dan  $K = N - M + 1$  (Mao dan Shang, 2019). Hasil matriks multidimensi disebut matriks trayektori Hankel

$$Y^{(p)} = [Y_1^{(p)}, Y_2^{(p)}, \dots, Y_M^{(p)}] \quad (4)$$

Selanjutnya, untuk semua deret waktu dibentuk ke dalam blok matriks trayektori Hankel  $Y^{(p)}$  dengan ukuran matriks  $M \times PK$ , sebagai berikut:

$$Y = [Y^{(1)^T}, Y^{(2)^T}, \dots, Y^{(P)^T}] \quad (5)$$

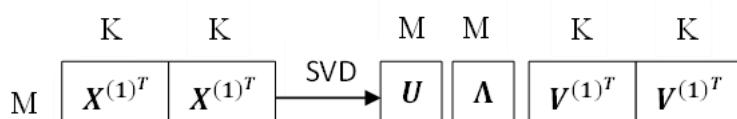
Selanjutnya dekomposisi matriks trayektori Hankel menggunakan metode *Singular Value Decomposition* (SVD). Dekomposisi *Singular Value Decomposition* (SVD) akan mendekomposisi atau memfaktorkan matriks trayektori Hankel menjadi tiga komponen matriks, yaitu matriks  $U$ ,  $V$  dan  $\Lambda$ , dengan formula sebagai berikut:

$$Y = \sqrt{\alpha} U \Lambda V^T \quad (6)$$

Dimana  $\alpha$  adalah faktor normalisasi berukuran  $PK$ ,  $U$  adalah matriks singular kiri berukuran  $M \times M$ ,  $\Lambda = diag(\lambda_1, \lambda_2, \dots, \lambda_M)$  adalah matriks diagonal eigenvalue ( $\lambda_i$ ) dari  $Y$ , sedangkan matriks  $V$  adalah matriks singular kanan berukuran  $PK \times M$ ,  $V$  berukuran  $K \times M$  dan bersesuaian dengan tiap deret  $X^{(p)}$ . Matriks  $V^T$  selanjutnya dapat diformulasikan dengan:

$$V^T = [V^{(1)^T}, V^{(2)^T}, \dots, V^{((P)^T}]] \quad (7)$$

Gambar 1 menunjukkan skema dekomposisi matriks trayektori untuk situasi dua deret waktu.



**Gambar 1.** Skema Dekomposisi Matriks Trayektori Hankel

## Tahap 2: Rekonstruksi

Tahapan rekonstruksi bertujuan untuk memisahkan data deret waktu yang diperoleh dari tahap SVD menjadi komponen-komponen utama deret waktu (yaitu tren, musiman dan *noise*) melalui pengelompokan deret waktu (*grouping*) dan perataan diagonal (*diagonal averaging*). Proses grouping dilakukan berdasarkan nilai *principal components* dan bertujuan untuk memisahkan matriks menjadi kelompok-kelompok yang saling terpisah dan selanjutnya dijumlahkan matriks-matriks tersebut [10]. Misalkan  $D = \{d_1, d_2, \dots, d_m\}$  adalah sekumpulan elemen  $d_1, d_2, \dots, d_m$ , maka matriks  $Y_D$  yang bersesuaian dengan  $D$  didefinisikan sebagai:

$$Y = Y_{d1} + Y_{d2} + \dots + Y_{dm} \quad (8)$$

Kontribusi elemen  $Y_D$  dihitung sesuai proporsi *eigenvalue* sebesar  $\sum_{d \in D} \lambda_d = \sum_{d=1}^M \lambda_d$ . Selanjutnya, matriks rekonstruksi deret waktu untuk grup  $D$ , yaitu matriks  $R_D$  yang berukuran  $M \times PK$ , diformulasikan sebagai berikut:

$$R_D = \sqrt{\alpha} U \Lambda_D V^T \quad (9)$$

Proses selanjutnya *diagonal averaging* yang bertujuan untuk mengkonversi deretan waktu yang sudah dipisah-pisahkan ( $R_{(P)}$ ) ke deret waktu awal yang berukuran  $P \times N$  (Mao dan Shang, 2019). Dalam hal ini terdapat  $P$  submatriks berukuran  $M \times K$  yang dikelompokkan kembali. Misalkan  $R_p$  adalah submatriks dengan komponen  $r_{ij}^{(p)}$ ,  $1 \leq i \leq M; 1 \leq j \leq K$ . Misal  $m^* = \min(M, K)$  dan  $k^* = \max(M, K)$ . Sebelum rekonstruksi deret waktu, terlebih dahulu dilakukan Hankelization, yaitu jika  $M < K$  maka  $r_{ij}^* = r_{ij}^{(p)}$  dan  $r_{ij}^* = r_{ji}^{(p)}$ . Selanjutnya, deret waktu direkonstruksi melalui diagonal averaging matriks  $\hat{x}_j^{(p)}$  berdasarkan formulasi berikut:

$$\hat{x}_j^{(p)} = \begin{cases} \frac{i}{j} \sum_{t=1}^j r_{t,j-t+1}^*; 1 \leq j < m^* \\ \frac{i}{m^*} \sum_{t=1}^{m^*} r_{t,j-t+1}^*; m^* \leq j < k^* \\ \frac{i}{N-j+1} \sum_{t=j-k^*+1}^{N-k^*+1} r_{t,j-t+1}^*; k^* \leq j < N \end{cases} \quad (10)$$

Diagonal averaging dihitung pada semua matriks  $R_p$  dan selanjutnya akan digunakan untuk merekonstruksi matriks ke deret waktu multivariat  $\hat{x}$  dengan formula sebagai berikut:

$$X = \hat{x}_j^{(p)} = (\hat{x}_1^{(p)}, \hat{x}_2^{(p)}, \dots, \hat{x}_N^{(p)}) \quad (11)$$

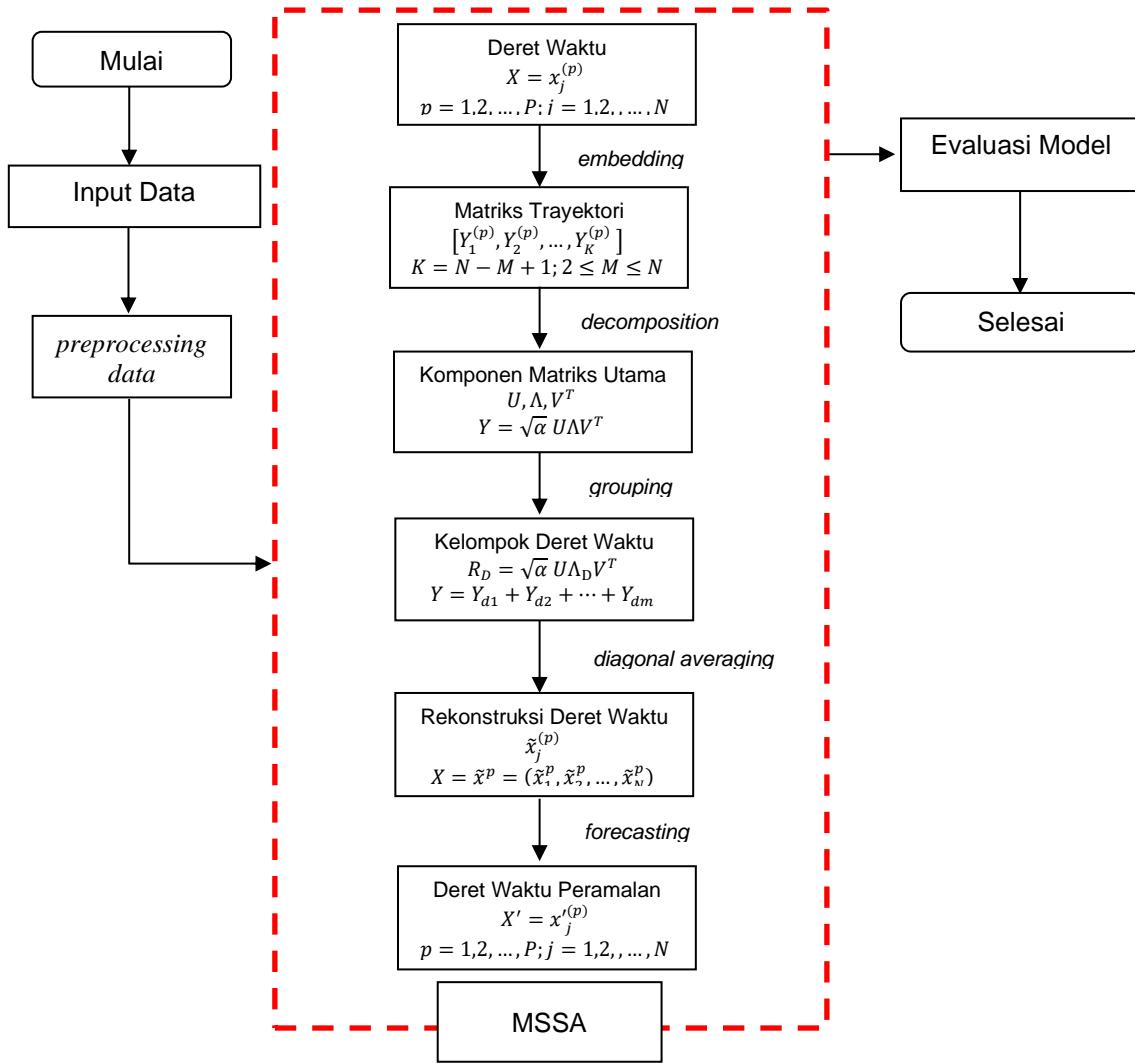
## 2. Mean Absolute Deviation (MAD)

Mean Absolute Deviation (MAD) mengukur rata-rata dari nilai absolut perbedaan antara nilai yang diprediksi oleh model dan nilai aktual yang diamati. Untuk sebuah *time series* dengan  $n$  observasi, di mana  $y_t$  adalah nilai aktual pada waktu  $t$  dan  $\hat{y}_t$  adalah nilai yang diprediksi pada waktu  $t$ , MAD dapat dihitung dengan persamaan berikut [16]:

$$MAD = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (12)$$

## Bahan dan Metode

Penelitian ini adalah penelitian dengan pendekatan kuantitatif. Data penelitian ini adalah data sekunder yang diperoleh dari stasiun BMKG. Data berupa data harian dengan lima variabel yaitu suhu, kelembaban udara, curah hujan, lamanya peninjoran matahari dan kecepatan angin pada periode Januari 2023 hingga Mei 2024. Berikut adalah alur penelitian:



**Gambar 2.** Diagram Alur Penelitian

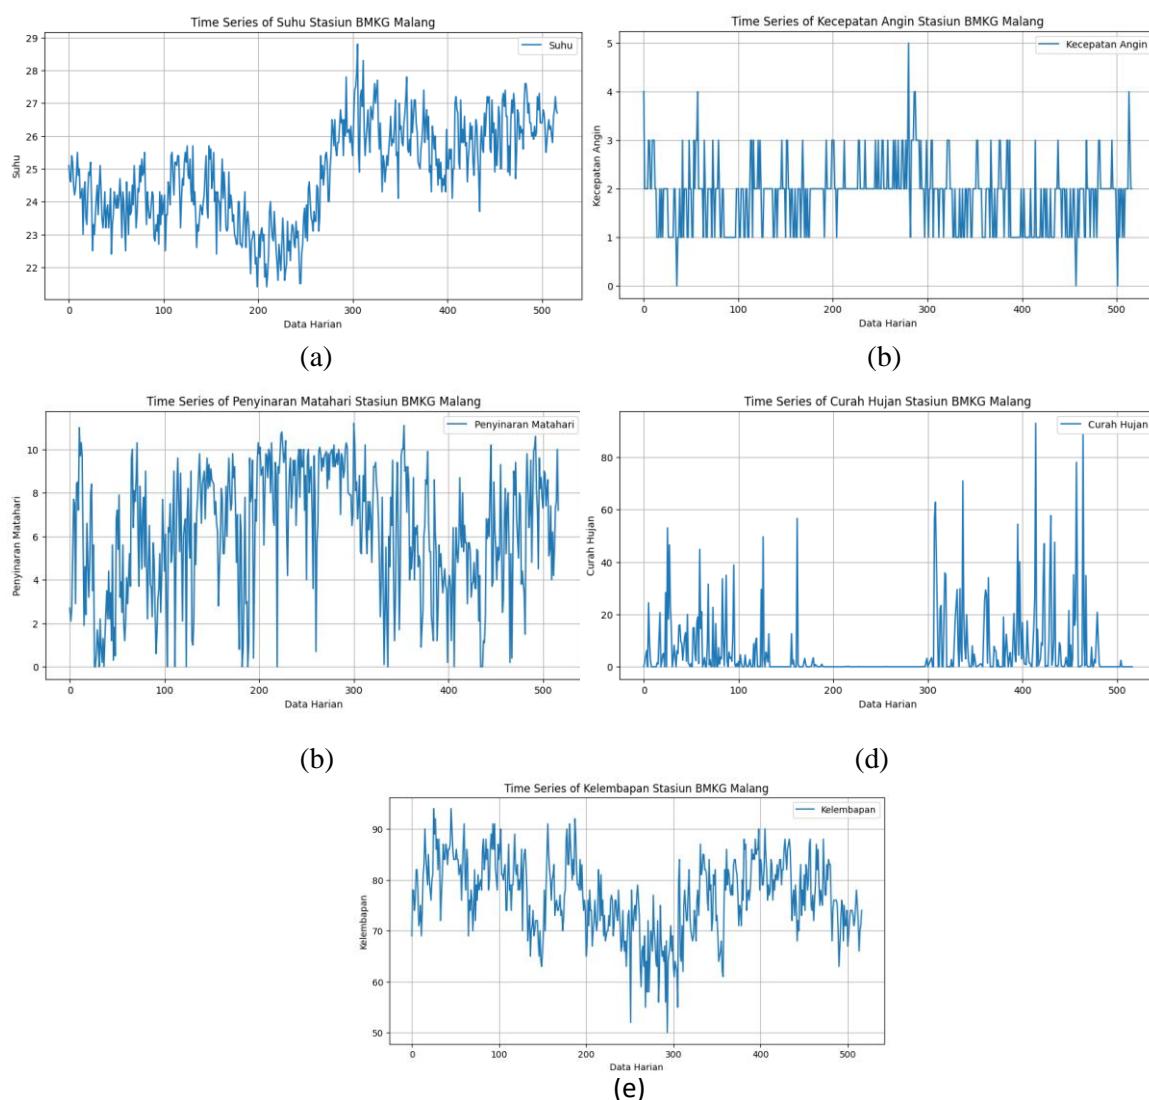
Langkah-langkah dalam penelitian analisis parameter klimatologi di Jawa Timur adalah sebagai berikut:

1. Melakukan studi literatur penelitian, yaitu pemahaman tentang SSA dan MSSA.
2. Melakukan pengambilan data parameter klimatologi di Stasiun Klimatologi Malang.
3. Melakukan input data time series untuk lima variabel dengan membagi menjadi data *training* dan *testing* dengan perbandingan 70:30.
4. Melakukan *preprocessing* data berupa *cleaning* data.
5. Melakukan analisis data *time series* menggunakan MSSA sebagai berikut:
  - a. Membentuk data deret waktu berdasarkan Persamaan (2).
  - b. Membentuk matriks trayektori Hankel berukuran  $M \times PK$  berdasarkan Persamaan (5) dan selanjutnya dekomposisi matriks dengan *Singular Value Decomposition* (SVD) berdasarkan Persamaan (6).
  - c. Membentuk komponen matriks utama berdasarkan Persamaan (9).
  - d. Melakukan pengelompokan data deret waktu tren, musiman dan *noise*.
  - e. Merekonstruksi data deret waktu dengan menentukan nilai *diagonal averaging*.
6. Mendapatkan nilai prediksi data deret waktu.
7. Mengevaluasi model MSSA yang telah terbentuk dengan MAD.

## Hasil dan Pembahasan

Penelitian ini menggunakan data dengan lima variabel yang meliputi suhu, kelembapan udara, curah hujan, lamanya peninjoran matahari dan kecepatan angin. Data parameter klimatologi yang diambil dari tanggal 1 Januari 2023 sampai dengan 31 Mei 2024 dari Stasiun Klimatologi Malang sebanyak 517 data. Proses pengolahan data dibagi menjadi data *training* dan *testing* dengan perbandingan 70:30. Data *training* sebanyak 365 data dan data *testing* sebanyak 152 data. Hasil plot dari masing-masing variabel disajikan pada Gambar 3.

Gambar 3 (a) menyatakan data rata-rata suhu pada pos pengamatan di stasiun klimatologi Malang merupakan data time series yang fluktuatif. Dimana rata-rata suhu tertinggi tidak sampai  $29^{\circ}$  C. Gambar 3 (b) menyatakan rata-rata kecepatan angin pada pos pengamatan di stasiun klimatologi Malang merupakan data time series yang fluktuatif. Dimana rata-rata kecepatan angin tertinggi adalah 5 m/s dan terendahnya adalah 0 m/s. Gambar 3 (c) menyatakan data durasi peninjoran matahari pada pos pengamatan di stasiun klimatologi Malang merupakan data time series yang fluktuatif. Dimana durasi peninjoran terlama mencapai lebih dari 10 jam. Gambar 3 (d) menyatakan data curah hujan pada pos pengamatan di stasiun klimatologi Malang merupakan data time series yang fluktuatif. Sekitar data ke 200 sampai dengan ke 300 terlihat bahwa curah hujan menyentuh angka 0 mm yang artinya tidak terjadi hujan sama sekali. Gambar 3 (e) menyatakan data rata-rata kelembapan udara pada pos pengamatan di stasiun klimatologi Malang merupakan data time series yang fluktuatif. Dimana data kelembapan udara tertinggi lebih dari 95% pada satu hari.



**Gambar 3.** (a) Rata-rata suhu pada Stasiun Klimatologi Malang, (b) Rata-rata kecepatan angin pada Stasiun Klimatologi Malang, (c) Durasi Penyinaran Matahari pada Stasiun Klimatologi Malang, (d) Curah Hujan pada Stasiun Klimatologi Malang, (e) Rata-rata Kelembapan Udara pada Stasiun Klimatologi Malang

### Hasil Parameter Pemodelan MSSA Terbaik

Pada tahap ini data berdimensi satu diubah menjadi multidimensi yang dinamakan matrik lintasan  $X$  yang memiliki  $M \times K$ . Penentuan nilai  $M$  (*window length*) ditentukan dengan melakukan uji coba dengan ketentuan  $2 \leq M \leq N_{train}$  dimana  $N_{train}$  adalah jumlah seluruh data. Untuk memudahkan pencarian  $M$  optimum maka dilakukan uji coba nilai  $M = 50, 100, 150, 200, 250$  dengan nilai MAD minimum. Hasil *trial and error* dapat dilihat pada Tabel 1.

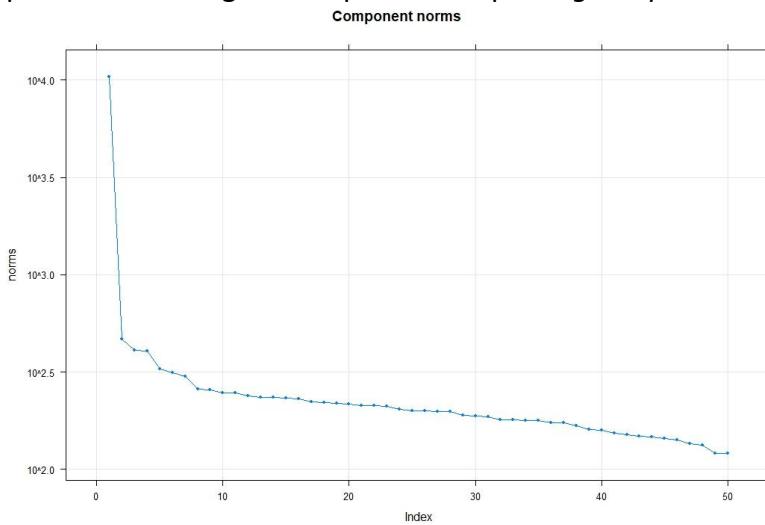
Berdasarkan Tabel 1, nilai  $M = 50$  menghasilkan MAD minimum pada variabel dan kelembapan, curah hujan, penyinaran matahari dan kecepatan angin. Sedangkan untuk variabel suhu nilai MAD yang minimum dihasilkan antara  $M = 100$ . Sehingga pada model MSSA parameter klimatologi pada stasiun BMKG Malang menggunakan  $M = 50$ .

**Tabel 1.** Hasil MAD

M	MAD Suhu		MAD Kelembapan		MAD Curah Hujan		MAD Penyinaran Matahari		MAD Kecepatan Angin	
	Suhu	Kelembapan	Curah Hujan	Penyinaran Matahari	Kecepatan Angin					
50	0.8589562	4.349427	10.97505	1.984248	0.5708323					
100	0.8366587	5.326554	12.08627	2.029300	0.6024000					
150	2.1900016	9.591133	11.99529	2.350467	0.6245820					
200	3.3589471	12.542944	15.00490	2.977759	0.7994349					
250	3.6286270	10.031344	13.34419	2.759197	0.6423717					

### Hasil Rekonstruksi Data Time Series

Tahap ini akan diawali dengan proses *grouping* dimana menentukan jumlah *eigentriple* yang tidak termasuk dalam komponen *noise* dengan memperhatikan plot *eigentriple* di bawah ini:

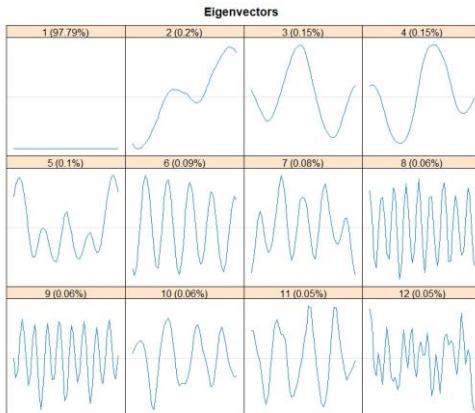


**Gambar 4.** Plot *Eigentriple*

Berdasarkan Gambar 4 diperoleh bahwa plot *eigentriple* mulai menurun secara lambat pada *eigentriple* ke 13 sampai 50 sehingga dapat dikatakan *eigentriple* tersebut merupakan komponen *noise*. Berdasarkan hal tersebut maka 12 *eigentriple* yang tidak teridentifikasi sebagai komponen *noise*

merupakan nilai parameter *Grouping Effect* ( $r$ ) yang akan digunakan untuk mengidentifikasi komponen tren dan musiman.

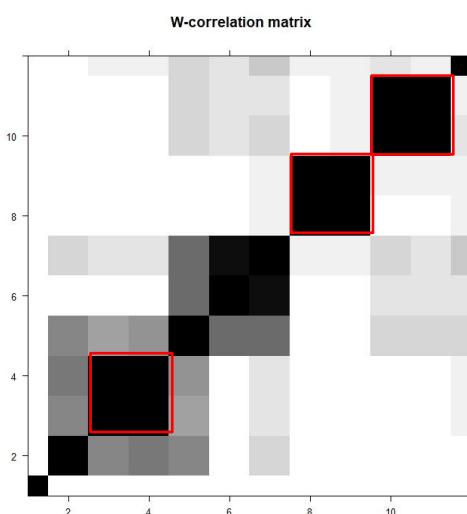
Setelah komponen *noise* berhasil dikelompokan, maka selanjutnya akan dilakukan pengelompokan terhadap *eigentriple* yang mencerminkan komponen tren dan musiman. Jumlah *eigentriple* yang digunakan adalah 10 *eigentriple* yang terdiri dari *eigentriple* 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, dan 12. Untuk melakukan identifikasi terhadap komponen tren dan musiman yaitu dengan menggunakan plot dari deret yang telah direkonstruksi berikut:



**Gambar 4.** Plot *Eigen Vectors*

Berdasarkan Gambar 4 dapat dideskripsikan bahwa deret yang di rekonstruksi oleh *eigentriple* 1 dan 2 teridentifikasi ke dalam komponen tren. Setelah komponen tren teridentifikasi, langkah berikutnya adalah melakukan identifikasi terhadap *eigentriple* yang mencerminkan komponen musiman. Pengelompokan komponen musiman dapat dilakukan secara subjektif yaitu dengan melihat kemiripan nilai *singular* dari *eigentriple* yang memiliki pola dan periode musiman yang sama. Terlihat pada plot hasil rekonstruksi dGambar 4, terdapat 3 pasang *eigentriple* yang memiliki kemiripan pola yaitu 3 dan 4, 8 dan 9.

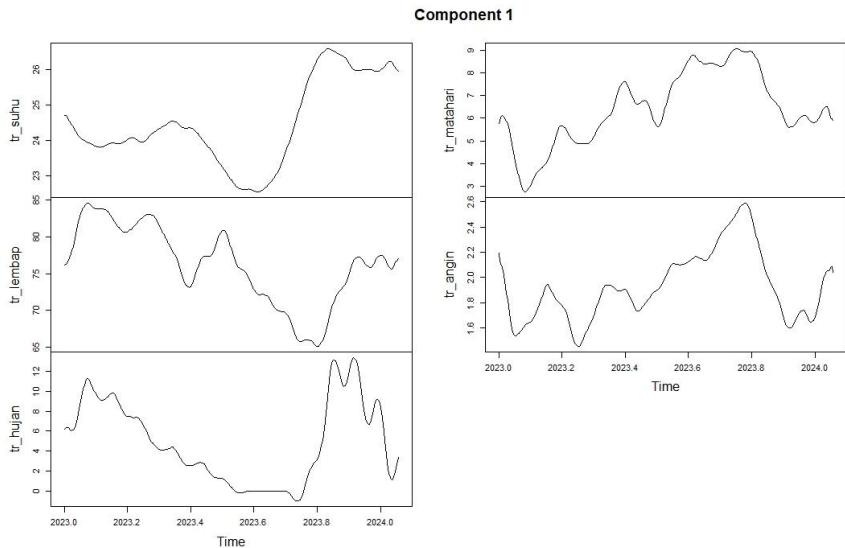
Pengidentifikasi *eigentriple* yang menggambarkan komponen tren dan musiman tidak hanya dapat dilihat pada plot hasil rekonstruksi dan *scatterplot* untuk pasangan *eigen vector* saja, namun pengidentifikasi juga dapat dengan melihat plot *W-correlation*. Plot tersebut berfungsi untuk mengetahui bagaimana korelasi antar *eigentriple*, jika warna plotnya berwarna hitam pekat maka *eigentriple* tersebut memiliki korelasi kuat. Berikut hasil plot *W-correlation* dari 12 *eigentriple*:



**Gambar 5.** Plot *W-Correlation*

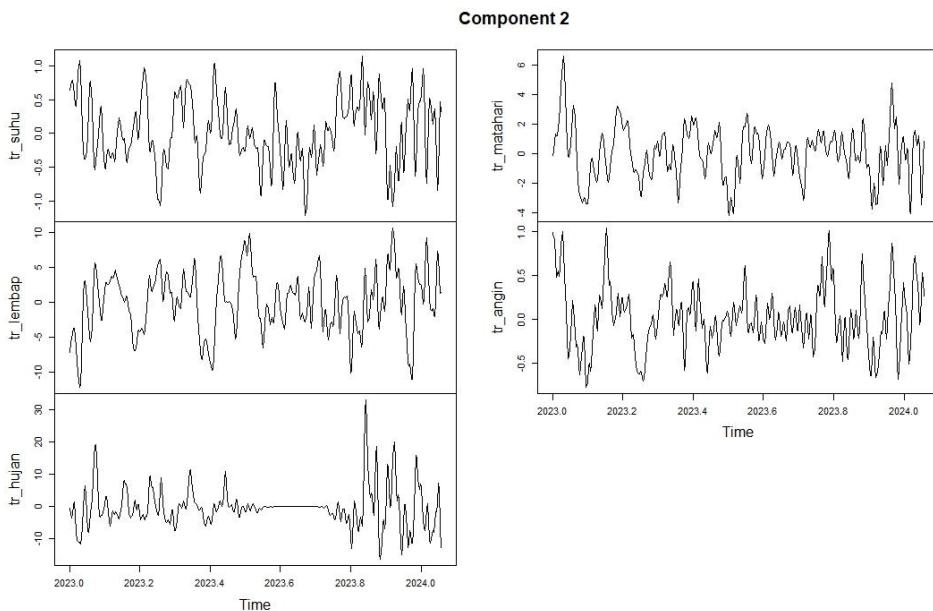
Gambar 5 mendeskripsikan bahwa komponen 1 tidak memiliki korelasi dengan komponen lain melainkan hanya berkorelasi dengan dirinya sendiri sehingga dapat dikelompokkan ke dalam tren. Komponen 3 dan 4, dan komponen 8 dan 9, komponen 10 dan 11 memiliki korelasi yang kuat karena irisan antar komponen tersebut memiliki warna gelap sehingga dapat dikelompokkan ke dalam komponen musiman.

Setelah dapat mengelompokkan komponen yang masuk ke komponen tren dan musiman maka dapat dilakukan rekonstruksi data *time series* pada data *training*. Hasil rekonstruksi data *time series* masing-masing variabel yang masuk komponen tren dapat dilihat pada Gambar 6:



**Gambar 6.** Rekonstrusi Komponen Tren

Pada Gambar 6 terlihat bahwa untuk semua variabel tidak terlihat pola tren yang jelas karena grafiknya menunjukkan fluktuasi. Selanjutnya untuk rekonstruksi data *time series* komponen musiman terlihat pada Gambar 7 berikut:



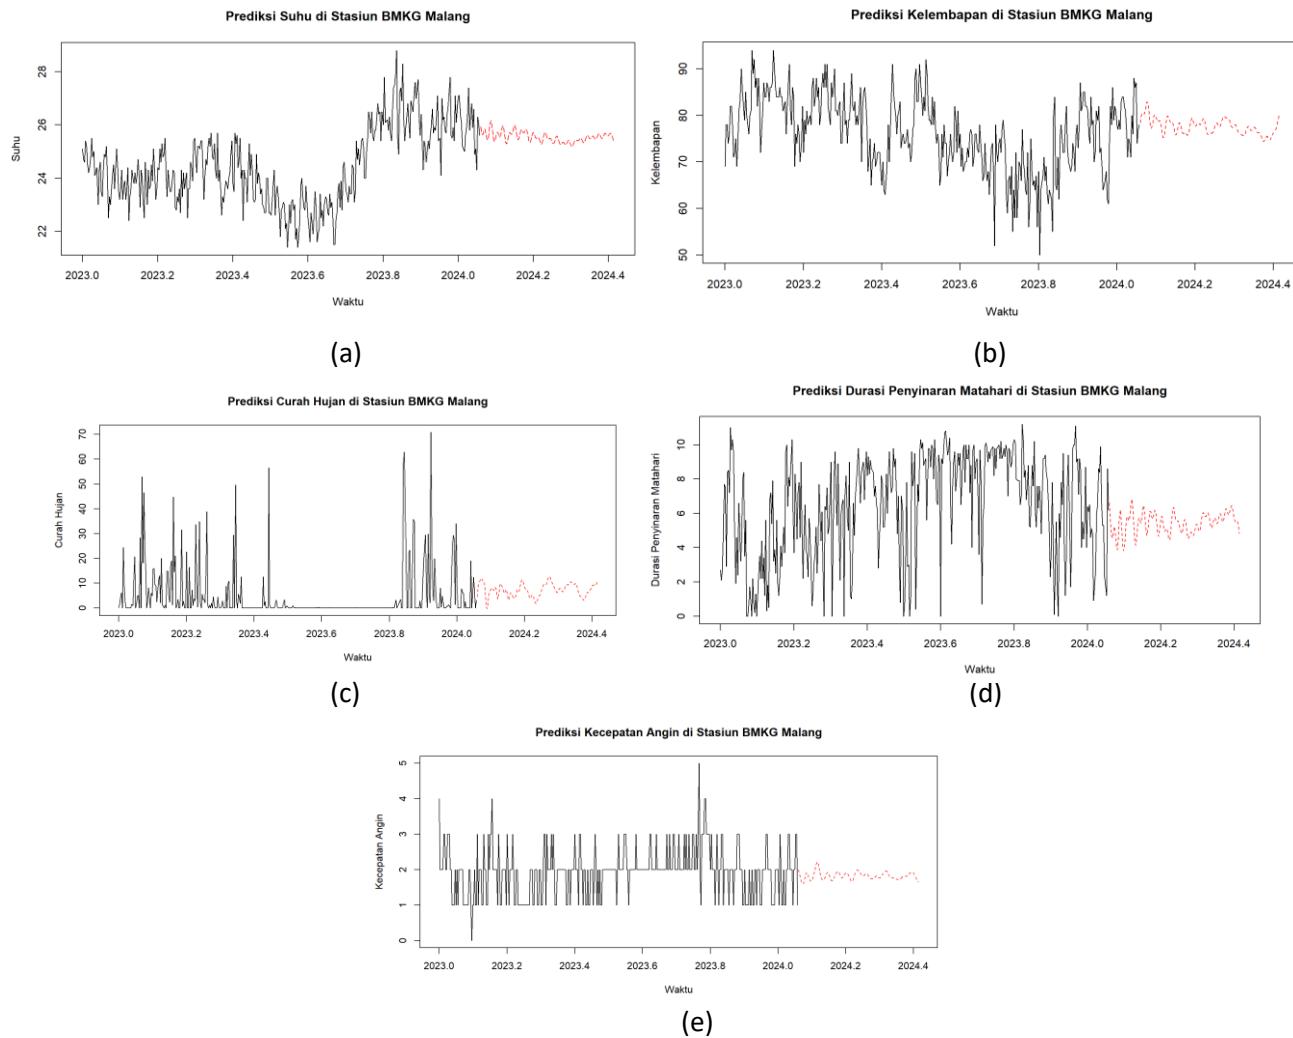
**Gambar 7.** Rekonstrusi Komponen Musiman

Pada Gambar 7, untuk semua variabel pola musiman yang terbentuk memiliki pola musiman yang kurang konsisten. Seperti pada variabel kecepatan angin terlihat pola perulangannya adalah 6 bulan,

sedangkan untuk variabel suhu pola perulangannya adalah 3 bulan. Sehingga perulangan untuk pola musimannya untuk masing-masing variabel berkemungkinan berbeda.

### Hasil Prediksi

Tahap selanjutnya adalah menentukan nilai prediksi berdasarkan model MSSA dengan  $M = 50$  untuk masing-masing variabel parameter klimatologi di stasiun BMKG Malang.



**Gambar 8.** Nilai Prediksi (a) Variabel Suhu (b) Variabel Kelembapan (c) Variabel Curah Hujan (d) Variabel Durasi Penyinaran Matahari (e) Variabel Kecepatan Angin

Berdasarkan hasil prediksi diperoleh bahwa rata-rata parameter klimatologi di stasiun BMKG Malang pada bulan Juni yaitu nilai suhu sebesar 25.45498, kelembapan sebesar 77.22544, curah hujan sebesar 10.56384, durasi penyinaran matahari sebesar 5.93605, dan kecepatan angin sebesar 1.83921. Sehingga dapat dikatakan bahwa selama bulan Juni suhu rata-rata tidak termasuk dalam kategori suhu normal di Malang, sedangkan intensitas untuk curah hujan lebih sering terjadi. Untuk kecepatan angin selama bulan Juni termasuk stabil dikarenakan kecepatan angin dibawah 2 km/h.

Berdasarkan hasil analisis data, dapat disimpulkan bahwa model MSSA dengan parameter  $M = 50$  menunjukkan kinerja terbaik dalam meminimalkan nilai MAD pada sebagian besar parameter klimatologi, seperti kelembapan, curah hujan, penyinaran matahari, dan kecepatan angin di stasiun BMKG Malang. Prediksi parameter klimatologi yang dihasilkan menunjukkan bahwa meskipun

intensitas curah hujan yang lebih sering perlu diantisipasi, tidak terdapat indikasi langsung mengenai potensi bencana besar. Namun demikian, langkah mitigasi tetap diperlukan, khususnya di wilayah yang rentan terhadap banjir atau longsor. Upaya mitigasi seperti pemantauan curah hujan, memastikan sistem drainase berfungsi dengan baik, dan meningkatkan kesadaran masyarakat terhadap risiko bencana sangat penting untuk meminimalkan dampak yang mungkin terjadi.

## Referensi

- [1] Bayong Tjasyono HK, *Klimatologi*. Bandung: ITB Press, 2004.
- [2] I. W. YASA, Y. SAADI, H. SULISTYONO, E. SETIAWAN, H. HARTANA, and I. D. G. JAYA NEGARA, "ANALISIS KARAKTERISTIK KEDALAMAN HUJAN DAN IKLIM DI PULAU LOMBOK," *GANECK SWARA*, vol. 15, no. 2, p. 1067, Sep. 2021, doi: 10.35327/GARA.V15I2.219.
- [3] BNPB, *Data Bencana Indonesia 2023*, vol. 3. Jakarta: Pusat Data Informasi dan Komunikasi Kebencanaan BNPB, 2024.
- [4] BNPB, *Data dan Informasi Kebencanaan Bulanan Teraktual*, vol. 4, no. 4. Jakarta: Bidang Pengelolaan Data dan Sistem Informasi BNPB, 2024.
- [5] "Jumlah Bencana Menurut Jenis Bencana dan Kecamatan di Kota Malang," BPS Kota Malang.
- [6] P. C. S. Reddy, Y. Sucharitha, and G. S. Narayana, "DEVELOPMENT OF RAINFALL FORECASTING MODEL USING MACHINE LEARNING WITH SINGULAR SPECTRUM ANALYSIS," *IIUM Engineering Journal*, vol. 23, no. 1, 2022, doi: 10.31436/IIUMEJ.V23I1.1822.
- [7] A. N. Aini, P. K. Intan, and N. Ulinnuha, "Prediksi Rata-Rata Curah Hujan Bulanan di Pasuruan Menggunakan Metode Holt-Winters Exponential Smoothing," *JRST (Jurnal Riset Sains dan Teknologi)*, vol. 5, no. 2, 2022, doi: 10.30595/jrst.v5i2.9702.
- [8] S. W. Haryas and S. Bayu, "PREDIKSI KEKERINGAN BERBASIS STANDARDIZED PRECIPITATION INDEX (SPI) MENGGUNAKAN MULTI LAYER PERCEPTRON (MLP) FORECASTING DROUGHT BASED STANDARDIZED PRECIPITATION INDEX (SPI) USING MULTI LAYER PERCEPTRON (MLP)," 2023. [Online]. Available: <http://satellite.nsmc.org.cn/PortalSite/>
- [9] H. Sharfina, P. Y. Utami, and I. Fakhruzi, "Prediksi Bencana Banjir Menggunakan Algoritma Deep Learning H2O Berdasarkan Data Curah Hujan," 2023. [Online]. Available: <http://jurnal.mdp.ac.id>
- [10] X. Mao and P. Shang, "Multivariate singular spectrum analysis for traffic time series," *Physica A: Statistical Mechanics and its Applications*, vol. 526, 2019, doi: 10.1016/j.physa.2019.121063.
- [11] K. Patterson, H. Hassani, S. Heravi, and A. Zhigljavsky, "Multivariate singular spectrum analysis for forecasting revisions to real-time data," *J Appl Stat*, vol. 38, no. 10, 2011, doi: 10.1080/02664763.2010.545371.
- [12] W. Dianita Utami, A. Candra Agustina, and A. History, "Implementation of singular spectrum analysis in the forecasting of seawater wave height," *Desimal: Jurnal Matematika*, vol. 6, pp. 285–294, 2023, doi: 10.24042/djm.
- [13] N. A. G. Utami, W. Sulandari, and S. S. Handajani, "Peramalan Curah Hujan Bulanan di Pos Hujan Jatisrono Dengan Metode Singular Spectrum Analysis (SSA)," *Prosiding Seminar Nasional Aplikasi Sains & Teknologi (SNAST)*, no. mm, 2021.
- [14] M. Le, D. K. Le, and J. Lee, "Multivariate singular spectral analysis for heartbeat extraction in remote sensing of uwb impulse radar," *Sens Actuators A Phys*, vol. 306, 2020, doi: 10.1016/j.sna.2020.111968.
- [15] A. Marjuni, "Peramalan Harga Saham Serentak Menggunakan Model Multivariate Singular Spectrum Analysis," *JURNAL SISTEM INFORMASI BISNIS*, vol. 12, no. 1, 2022, doi: 10.21456/vol12iss1pp17-25.
- [16] U. Khair, H. Fahmi, S. Al Hakim, and R. Rahim, "Forecasting Error Calculation with Mean Absolute Deviation and Mean Absolute Percentage Error," in *Journal of Physics: Conference Series*, 2017. doi: 10.1088/1742-6596/930/1/012002.