

APLIKASI METODE *SINGULAR SPECTRUM ANALYSIS* (SSA) PADA PERAMALAN CURAH HUJAN DI PROVINSI GORONTALO

Eka Purnama¹

¹ Program Studi Ekonomi Syariah, Fakultas Ekonomi dan Bisnis Islam,
IAIN Sultan Amai Gorontalo

e-mail: ekapurnama@iaingorontalo.ac.id

Abstrak

Penelitian ini bertujuan untuk mempelajari model peramalan curah hujan di Provinsi Gorontalo dan melakukan peramalan untuk tahun 2022-2023. Biasanya, data curah hujan mengandung pola musiman. Dalam penelitian ini akan dilakukan peramalan menggunakan metode *Singular Spectrum Analysis* (SSA) dengan metode *Linear Recurrent Formula* (LRF). Hasil penelitian menunjukkan bahwa model peramalan curah hujan di Gorontalo menggunakan SSA dengan *windows length* $L = 36$ diperoleh MAPE hasil peramalan pada data *out-sample* sebesar 0,029 atau 2,9 %. Sehingga, SSA sangat akurat untuk meramalkan curah hujan di Provinsi Gorontalo tahun 2022-2023. Dari hasil peramalan terlihat bahwa curah hujan pada umumnya masih relatif tinggi. Sehingga perlu bagi pemerintah untuk mengambil kebijakan demi menghindari dampak negatif yang dapat ditimbulkan.

Kata Kunci: *Singular Spectrum Analysis* (SSA), Peramalan, *Linear Recurrent Formula* (LRF), Curah Hujan.

Abstract

This paper aims to study the forecasting model of rainfall in Gorontalo Province and forecast it for 2022-2023. Usually, rainfall data is seasonal. In this study, we used Singular Spectrum Analysis (SSA) with the Linear Recurrent Formula (LRF) method. The result showed that the models of rainfall forecasting in Gorontalo using SSA with windows length $L=36$ obtained MAPE of forecasting in out-sample was 0,029 or 2,9 %. So that SSA was very accurate in forecasting rainfall in Gorontalo Province in 2022-2023. The forecasting result showed that rainfall was relatively high generally. So, it is necessary for the government to take policies to avoid the negative impact that can be caused.

Keywords: *Singular Spectrum Analysis*(SSA), Forecasting, *Linear Recurrent Formula*, Rainfall

1. PENDAHULUAN

Analisis runtun waktu (*time series*) adalah suatu pengamatan terhadap pola data dalam suatu deret waktu. Dalam analisis ini, pengamatan dari data sebelumnya digunakan untuk memprediksi nilai tertentu di masa yang akan datang. Secara periodik, data dikumpulkan dalam rentang waktu tertentu, baik jam, hari, minggu, bulan, atau tahun. Selanjutnya, dilakukan peramalan (*forecasting*) nilai di masa mendatang dengan menggunakan metode tertentu (Basari dan Achmad, 2021).

Ada berbagai metode yang dapat digunakan untuk melakukan peramalan. Salah satu metode yang sedang berkembang saat ini adalah *Singular Spectrum Analysis* (SSA). SSA merupakan salah satu metode dalam analisis *time series* yang menggabungkan antara analisis *time series* klasik, statistik multivariat, geometri multivariat, sistem dinamik dan sinyal proses. Tujuan SSA adalah untuk membuat dekomposisi deret asli menjadi sejumlah komponen yang independen dan dapat diinterpretasi, misalnya tren yang lambat, komponen yang bergerak dan *noise* yang tidak terstruktur (Hassani, 2007).

Beberapa penelitian sebelumnya telah membandingkan SSA dengan berbagai metode peramalan lain. Diantaranya Hassani (2007) melakukan perbandingan beberapa metode yaitu SSA, algoritma ARAR, model SARIMA, algoritma *Holt-Winter Seasonal* (HWS) dan memperoleh hasil bahwa SSA lebih akurat dibandingkan metode yang lain dengan membandingkan nilai *Mean Absolute Error* (MAE) dan *Mean Relative Absolute Error* (MRAE) dari SSA lebih kecil dibandingkan metode lain. Ruhiat dkk. (2020) juga melakukan perbandingan antara SSA dengan SARIMA pada data berpola musiman dan memperoleh hasil bahwa SSA relatif lebih baik dibandingkan SARIMA.

Peramalan dengan metode SSA telah digunakan untuk memprediksi berbagai bidang. Siregar dkk. (2017) menggunakan SSA dalam peramalan pertumbuhan Ekonomi Indonesia menggunakan metode *recurrent* dan *bootstrap confidence interval* untuk melihat selang kepercayaan. Utami dkk. (2007) melakukan peramalan beban listrik Daerah Istimewa Yogyakarta menggunakan *SSA-Linear Recurrent Formula* (LRF), Sodikin dkk. (2021) juga menggunakan SSA dalam meramalkan jumlah turis mancanegara di Ibukota Jakarta dengan membandingkan antara metode *recurrent* dan metode vektor dalam SSA.

Metode *recurrent* dan metode vektor merupakan dua metode yang digunakan dalam *forecasting* SSA. Metode *recurrent* merupakan metode dasar yang relatif lebih mudah, sedangkan metode vektor adalah metode *recurrent* yang telah dimodifikasi. Perbedaannya terletak pada kontinuasinya. Metode *recurrent* melakukan kontinuitas secara langsung dengan bantuan LRF, sedangkan metode vektor berhubungan dengan L-kontinuasinya (Sakinah, 2018).

Peramalan merupakan hal yang sangat penting dalam membuat keputusan, dengan memprediksi kondisi di masa yang akan datang, seseorang atau sebuah lembaga dapat membuat perencanaan atau menentukan kebijakan. Salah satunya dengan melakukan peramalan terhadap curah hujan. Adanya perubahan iklim secara global berakibat pada perubahan pola curah hujan, termasuk di wilayah Provinsi Gorontalo.

Tingginya curah hujan, kerusakan alam dan kurangnya antisipasi dari pemerintah mengakibatkan banjir melanda beberapa daerah di Gorontalo. Curah hujan yang tinggi juga berimplikasi pada sektor pertanian seperti sawah gagal panen atau tanaman pertanian membusuk. Oleh karena itu, memprediksi kondisi curah hujan sangat penting sebagai acuan yang dapat membantu membuat berbagai keputusan, misalnya menentukan waktu-waktu yang tepat untuk menanam padi, mengantisipasi cuaca ekstrem, banjir, kekeringan dan sebagainya.

2. METODE PENELITIAN

Metode penelitian yang digunakan dalam penelitian ini adalah analisis data statistik dengan menggunakan data runtun waktu (*time series*). Data yang digunakan adalah data curah hujan setiap bulan di Provinsi Gorontalo yang bersumber dari Badan Meteorologi, Klimatologi dan Geofisika (BMKG) Provinsi Gorontalo dari tahun 2014-2021. Metode SSA yang digunakan yaitu metode *Linear Recurrent Formula* (LRF). Analisis data dilakukan dengan bantuan Program R.

Singular Spectrum Analysis (SSA) adalah sebuah teknik analisis *time series* yang baik untuk mengekstrak tren dan komponen-komponen lain dalam data ke dalam struktur data yang sederhana (Myung, 2009). Istilah *singular* didefinisikan sebagai dekomposisi spektral atau dekomposisi nilai *eigen* dari matriks lintasan. Sedangkan istilah *spectrum* adalah jumlah himpunan nilai *eigen* setelah dekomposisi spektral (Elsner and Tsonis, 1999). Penelitian ini dilakukan dengan tiga tahap yaitu identifikasi data, analisis data menggunakan SSA dan peramalan curah hujan untuk 2 (dua) tahun ke depan.

2.1 Identifikasi Data

Tahap ini dilakukan untuk identifikasi awal pola yang terdapat pada data. Dengan menggunakan plot *time series* serta melalui plot *autocorrelation function* (ACF) dan *partial autocorrelation function* (PACF) dapat diidentifikasi apakah data mengandung tren atau musiman. Selain itu, juga dilakukan uji untuk mengetahui apakah data stasioner atau tidak. SSA tidak memerlukan asumsi normalitas seperti pada model parametrik.

2.2 Analisis Data

Sebelum melakukan analisis SSA terlebih dahulu data dibagi menjadi dua bagian, yaitu data *in-sample* dan data *out-sample*. Data *in-sample* digunakan untuk menganalisis data. Sedangkan data *out-sample* digunakan untuk menguji tingkat keakuratan hasil peramalan. SSA terdiri atas dua tahap. Tahap pertama yaitu dekomposisi dan tahap kedua yaitu rekonstruksi.

a. Dekomposisi

Tahapan dekomposisi terbagi atas dua tahap, yaitu *embedding* dan *Singular Value Decomposition* (SDV).

Embedding

Pada tahap *embedding*, data *in-sample* diubah menjadi data multidimensi yang disebut sebagai matriks lintasan \mathbf{X} , dengan orde $L \times K$. Parameter nilai L (*windows length*) merupakan salah satu parameter penting dalam SSA. Rentang pemilihan nilai L adalah $2 < L < N/2$, dimana N adalah jumlah data. Matriks lintasan \mathbf{X} yang dibentuk disebut juga sebagai matriks hankel dan dinyatakan dalam bentuk berikut (Irwan dkk., 2020):

$$\mathbf{X} = (\mathbf{x}_i)_{L \times K} = [x_1, x_2, \dots, x_N] = \begin{bmatrix} x_1 & x_2 & \dots & x_K \\ x_2 & x_3 & \dots & x_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & \dots & x_N \end{bmatrix} \quad (1)$$

Singular Value Decomposition (SDV)

SDV bertujuan untuk memisahkan komponen dalam dekomposisi dari data runtun waktu. Langkah pertama yang dilakukan yaitu membentuk matriks simetris $\mathbf{S} = \mathbf{X}\mathbf{X}^T$. Selanjutnya, menggunakan persamaan $\det(\mathbf{S} - \lambda\mathbf{I}) = 0$ diperoleh *eigenvalue* $\lambda_i = \lambda_1, \dots, \lambda_L$ dimana $\lambda_1 \geq \dots \geq \lambda_L \geq 0$ dan *eigenvector* $\mathbf{U}_i = \mathbf{U}_1, \dots, \mathbf{U}_L$ dari matriks \mathbf{S} . Matriks *singular value* merupakan akar positif dari *eigenvalue* ($\sqrt{\lambda_i}$). Setelah itu menghitung *principal component* menggunakan persamaan berikut :

$$\mathbf{V}_i = \frac{\mathbf{X}^T \mathbf{U}_i}{\sqrt{\lambda_i}} \quad (2)$$

Sehingga diperoleh SDV dari matriks lintasan \mathbf{X} adalah :

$$\mathbf{X}_i = \sqrt{\lambda_i} \mathbf{U}_i \mathbf{V}_i^T \quad (3)$$

Matriks \mathbf{X}_i disebut *eigen triple* yang terdiri atas *singular value*, *eigenvector* dan *principal component* untuk $i = 1, \dots, d$ dimana $d = \max\{i\}$. SDV untuk matriks \mathbf{X}_i dapat dituliskan sebagai berikut :

$$\mathbf{X}_i = \mathbf{X}_1 + \dots + \mathbf{X}_d \quad (4)$$

b. Rekonstruksi

Tahap rekonstruksi terbagi menjadi dua yaitu *grouping* dan *diagonal averaging*.

Grouping

Grouping merupakan tahap pengelompokan *eigentriple* berdasarkan karakteristik tertentu yang dimiliki oleh setiap komponen. Grouping dilakukan dengan mengelompokkan himpunan indeks $i = \{1, 2, \dots, d\}$ ke dalam m subset disjoint I_1, I_2, \dots, I_m dengan $m = d$. Selanjutnya X_i disesuaikan dengan kelompok I . sehingga persamaan (4) dapat diekspansi menjadi:

$$X_1 = X_{I1} + X_{I2} + \dots + X_{Im} \quad (5)$$

Diagonal Averaging

Pada tahap *diagonal averaging* dilakukan rekonstruksi pada masing-masing kelompok X_i menjadi sebuah data runtun waktu yang baru dengan panjang N . Misalkan matriks Y adalah matriks berukuran $L \times K$ sebagai berikut :

$$Y = \begin{bmatrix} y_{11} & y_{12} & \dots & y_K \\ y_{21} & y_{22} & \dots & y_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ y_L & y_{L+1} & \dots & y_N \end{bmatrix} \quad (6)$$


Matriks Y diubah menjadi bentuk deret g_1, g_2, \dots, g_N melalui *diagonal averaging* sebagai berikut:

$$g_k = \frac{\sum_{(l,k) \in A_s} y_{lk}}{|A_s|} \quad (7)$$


3. HASIL DAN PEMBAHASAN

3.1 Identifikasi Data

Data yang dianalisis pada penelitian ini adalah data jumlah curah hujan setiap bulan di provinsi Gorontalo dari tahun 2014-2021. Tahap awal adalah melakukan identifikasi kecenderungan data. Data curah hujan di Provinsi Gorontalo mengalami kenaikan dan penurunan secara berulang (lihat Gambar 1), dari fluktuasi data dapat diidentifikasi bahwa data tersebut merupakan data musiman. Plot *autocorrelation function* (ACF) dan *partial autocorrelation function* (PACF) menunjukkan terjadi korelasi parsial pada lag $k = 6$.



Gambar 1. Plot *Time Series* Data Curah Hujan Provinsi Gorontalo Tahun 2014-2021



Gambar 2. Plot ACF dan PACF Data Curah Hujan Provinsi Gorontalo

Selanjutnya untuk mengidentifikasi apakah data stasioner atau tidak dilakukan uji *Augmented Dickey-Fuller* (ADF). Dari hasil uji ADF diperoleh nilai Dickey-Fuller = -3,5149 dan p-value = 0,04469 < 0,05, sehingga dapat disimpulkan bahwa data tersebut stasioner.

3.2 Analisis Data

Pada penelitian ini data *in-sample* yang diambil yaitu data curah hujan dari tahun 2014-2020. Sedangkan data *out-sample* yang digunakan untuk memvalidasi peramalan, digunakan data curah hujan pada tahun 2021.

3.3 Dekomposisi

Pada tahap dekomposisi, dilakukan dua langkah yaitu *embedding* dan *singular value decomposition* (SDV).

1. Embedding

Penelitian ini menggunakan data sebanyak $N = 84$ sehingga nilai L dipilih pada rentang $2 < L < 42$. Belum ada kriteria khusus dalam pemilihan nilai L yang tepat, sehingga pemilihan nilai L dilakukan dengan *trial and error* dan diharapkan memberikan nilai *Mean Absolut Percentage Error* (MAPE) terkecil.

Berdasarkan hasil plot ACF dan PACF menunjukkan bahwa data tersebut adalah musiman 6, sehingga dipilih nilai L pada kelipatan 6 (Hassani, 2007). Pada penelitian ini dilakukan uji terhadap beberapa nilai L yaitu 6, 12, 18, 24, 30 dan 36. Hasil yang diperoleh bahwa $L = 36$ memberikan nilai MAPE terkecil, sehingga dipilih nilai $L = 36$. Nilai K dihitung berdasarkan persamaan $K = N - L + 1$ dan diperoleh $K = 49$. Sehingga matriks lintasan yang dibentuk sebagai berikut :

$$\mathbf{X}_{(36 \times 49)} = \begin{bmatrix} 146 & 15 & \dots & 187 \\ 15 & 108 & \dots & 148 \\ \vdots & \vdots & \ddots & \vdots \\ 293 & 199 & \dots & 119 \end{bmatrix}$$

2. Singular Value Decomposition

Langkah kedua yaitu *singular value decomposition* (SVD) dengan mencari nilai *eigen triple* dari matriks lintasan $\mathbf{X}_{(36 \times 49)}$. Sebelum mencari nilai *eigen triple*, terlebih dahulu dibuat matriks simetris dengan rumus $\mathbf{S} = \mathbf{X}\mathbf{X}^T$, sehingga diperoleh matriks simetris berikut:

$$\mathbf{S}_{(36 \times 36)} = \begin{bmatrix} 1096028 & 884094 & \dots & 749457 \\ 884094 & 1096616 & \dots & 677185 \\ \vdots & \vdots & \ddots & \vdots \\ 749457 & 677185 & \dots & 1054126 \end{bmatrix}$$


Selanjutnya dari matriks S dihitung nilai *eigenvalue* (λ_i) dan *singular value* ($\sqrt{\lambda_i}$) dimana $i = 1, 2, \dots, 36$ dan diperoleh hasil seperti yang ditunjukkan pada Tabel 1.

Tabel 1. Nilai *Eigenvalue* dan *Singular Value*

| i | <i>Eigenvalue</i> | <i>Singular Value</i> |
|----------|-------------------|-----------------------|
| 1 | 28983213,66 | 5383,6060 |
| 2 | 1335535,55 | 1155,6537 |
| 3 | 1267193,35 | 1125,6968 |
| \vdots | \vdots | \vdots |
| 36 | 23071,20 | 151,8921 |

Langkah awal sebelum melakukan rekonstruksi adalah mengidentifikasi pengelompokan *eigentruple* yang terdiri dari tren, musiman dan *noise*.

Gambar 3 menunjukkan bahwa *singular value* menurun secara lambat pada *eigentruple* ke 7 sehingga dapat diidentifikasi bahwa *eigentruple* ke 1 sampai ke 6 adalah komponen tren dan musiman sedangkan 7 sampai ke 36 merupakan komponen *noise*.



Gambar 3. Plot *Singular Value*

Setelah memperoleh nilai *eigenvalue* dan *singular value*, selanjutnya menghitung *eigenvector* (U_i). Hasil *eigenvector* disajikan dalam Tabel 2.

Tabel 2. Nilai *Eigenvector*

| i | U_1 | U_2 | U_3 | ... | U_{36} |
|----------|-----------|-----------|-----------|----------|-----------|
| 1 | -0,156755 | 0,248243 | 0,027751 | ... | 0,427722 |
| 2 | -0,157789 | 0,349510 | -0,027437 | ... | -0,308530 |
| 3 | -0,161505 | 0,166592 | -0,166761 | ... | 0,040679 |
| \vdots | \vdots | \vdots | \vdots | \ddots | \vdots |
| 36 | -0,163140 | -0,125900 | 0,075568 | ... | -0,360616 |

Langkah selanjutnya yaitu menghitung nilai *principal component* dan diperoleh hasil sebagai berikut :

Tabel 3. Nilai *Principal Component*


| i | V_1 | V_2 | V_3 | ... | V_{36} |
|----------|-----------|-----------|-----------|----------|-----------|
| 1 | -0,123627 | -0,256057 | -0,081308 | ... | -0,044114 |
| 2 | -0,125559 | -0,313341 | -0,145067 | ... | 0,003139 |
| 3 | -0,130031 | -0,099638 | -0,085283 | ... | 0,150516 |
| \vdots | \vdots | \vdots | \vdots | \ddots | \vdots |
| 49 | -0,128693 | -0,090857 | -0,093580 | ... | -0,096675 |

3.4 Rekonstruksi

Tahap yang kedua yaitu tahap rekonstruksi. Pada tahap ini terdiri dari dua langkah yaitu *grouping* dan *diagonal averaging*.


1. Grouping

Grouping merupakan tahap pengelompokan *eigenvector* berdasarkan kesamaan karakteristik yang dimiliki. Pada Gambar 4 menunjukkan plot dari *eigenvector*. Dari gambar tersebut dapat dilihat bahwa komponen pertama merupakan tren, komponen 2-4 menunjukkan pola musiman, komponen 5 dan 6 juga menunjukkan tren, sedangkan komponen 7-9 adalah *noise*.



Gambar 4. Plot 9 *Eigenvector* Pertama

Dari Gambar 4 terlihat bahwa beberapa komponen memiliki pola dan karakteristik yang sama. Komponen kedua dan keempat dapat dikelompokkan berdasarkan persamaan karakteristiknya. Pasangan *eigenvector* yang lain yaitu komponen 22 dan 23, komponen 24 dan 25, serta komponen 34 dan 35 seperti yang terlihat pada Gambar. 5.



Gambar 5. Scatter Plot *Eigenvector* Berpasangan

Gambar 5 menunjukkan bahwa *eigenvector* yang memiliki kesamaan karakteristik cenderung membentuk sebuah pola. Dari plot *eigenvector* berpasangan tersebut diperoleh bahwa terdapat 4 *eigenvector* berpasangan yang direduksi menjadi satu komponen. sehingga dari 36 komponen awal dapat direkonstruksi menjadi 32 grup matriks dari komponen berbeda yang berukuran 36×49 sebagai berikut:

$$X_1 = \begin{bmatrix} 104,3297 & 105,9600 & \dots & 108,6044 \\ 105,0179 & 106,6590 & \dots & 109,3208 \\ \vdots & \vdots & \ddots & \vdots \\ 108,5797 & 110,2765 & \dots & 113,0286 \end{bmatrix}$$

$$X_2 = \begin{bmatrix} -27,256607 & -116,205844 & \dots & -27,6720259 \\ -123,649271 & -115,044098 & \dots & -35,9949812 \\ \vdots & \vdots & \ddots & \vdots \\ 56,895359 & 34,404600 & \dots & 12,5364077 \end{bmatrix}$$

$$\vdots$$

$$X_{32} = \begin{bmatrix} -2,866003607 & 0,2039068133 & \dots & -6,280755513 \\ 2,067345098 & -0,1470848640 & \dots & 4,530520858 \\ \vdots & \vdots & \ddots & \vdots \\ 2,416354569 & -0,1719157501 & \dots & 5,295363984 \end{bmatrix}$$

2. Diagonal Averaging

Pada tahap *grouping* diperoleh 32 grup matriks yang mewakili karakteristik tiap komponen. Dari hasil *diagonal averaging* dari 32 matriks tersebut, diperoleh hasil sebagai berikut:

Tabel 4. Hasil *Diagonal Averaging*

| No | Grup 1 | Grup 2 | Grup 3 | ... | Grup 32 |
|----|----------|------------|------------|-----|------------|
| 1 | 106,9051 | -28,273191 | 11,782578 | ... | -3,7875512 |
| 2 | 107,2441 | -81,525126 | -30,757861 | ... | 1,3226801 |
| 3 | 109,0224 | -74,327871 | -32,753186 | ... | 0,6814013 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| 96 | 147,7358 | 53,289725 | -23,369202 | ... | -4,0839052 |

Dari tabel 4 diperoleh 32 grup dimana setiap grup mewakili karakteristik komponen. Setiap matriks tersebut kemudian diubah menjadi data *time series* sesuai dengan karakteristik yang dimiliki.

3.5 Peramalan


Setelah memperoleh hasil *diagonal averaging*, langkah berikutnya adalah melakukan peramalan pada data *out-sample* menggunakan metode *Linear Recurrent Formula*. Akurasi hasil peramalan dihitung menggunakan *Mean Absolute Percentage Error* (MAPE). Hasil peramalan dan akurasi peramalan dapat dilihat pada Tabel 5.

Tabel 5. Hasil Peramalan dan Akurasi Hasil Peramalan

| Tahun | Bulan | Data Aktual | Data Ramalan | Percentage of Error |
|-------|----------|-------------|--------------|---------------------|
| 2021 | Januari | 202 | 209,64034 | 0,037823488 |
| | Februari | 89 | 88,46415 | 0,006020839 |
| | Maret | 138 | 137,68063 | 0,002314284 |
| | April | 244 | 245,46050 | 0,005985646 |
| | Mei | 397 | 391,52453 | 0,013792119 |
| | Juni | 48 | 53,25293 | 0,109436132 |
| | Juli | 101 | 99,61672 | 0,013695842 |

| | | | |
|-------------|-----|-----------|-------------------|
| Agustus | 108 | 109,35350 | 0,012532453 |
| September | 249 | 251,90780 | 0,011677920 |
| Oktober | 194 | 182,56543 | 0,058941058 |
| November | 405 | 405,82833 | 0,002045261 |
| Desember | 107 | 115,24302 | 0,077037565 |
| MAPE | | | 0,02927522 |

Dari Tabel 5 di atas terlihat bahwa terdapat *error* yang cukup kecil antara data peramalan dengan data aktual. Dilihat dari MAPE sebesar 0,029 atau 2,9%, hal ini menunjukkan bahwa hasil peramalan dengan metode SSA sangat akurat karena memiliki *error* yang kecil.



Gambar 6. Plot Perbandingan Data Aktual tahun 2021 dengan Data Hasil Peramalan

Hasil perbandingan melalui plot pada Gambar 6 juga terlihat bahwa data hasil peramalan tidak jauh dari data aktual. Dengan demikian, peramalan curah hujan menggunakan metode SSA dengan *windows length* $L = 36$ sangat akurat dan dapat digunakan untuk meramalkan curah hujan di masa yang akan datang.

Hasil peramalan curah hujan di Provinsi Gorontalo dapat dilihat pada Tabel 6 sebagai berikut:

Tabel 6. Hasil Peramalan Curah Hujan Tahun 2022 dan 2023

| No | Bulan | 2022 | 2023 |
|----|-----------|------------|------------|
| 1 | Januari | 285,078588 | 393,995775 |
| 2 | Februari | -9,283362 | 215,078659 |
| 3 | Maret | 381,231979 | 441,207042 |
| 4 | April | 187,934016 | 23,638749 |
| 5 | Mei | 323,023485 | 297,508574 |
| 6 | Juni | 117,098623 | 137,824467 |
| 7 | Juli | 525,247102 | 226,144484 |
| 8 | Agustus | 42,366606 | 72,688491 |
| 9 | September | 319,500098 | 506,921838 |
| 10 | Oktober | 127,869697 | 263,340106 |
| 11 | November | 382,120724 | 273,697429 |
| 12 | Desember | -67,568264 | 204,472404 |

Tabel 6 menunjukkan hasil ramalan curah hujan di Provinsi Gorontalo pada tahun 2022-2023. Dari hasil peramalan terlihat bahwa curah hujan perbulan pada umumnya masih relatif tinggi. Kondisi ini dapat menjadi patokan terutama bagi pemerintah untuk mengambil kebijakan dan langkah-langkah antisipatif untuk menghindari dampak negatif yang dapat ditimbulkan dari tingginya curah hujan di Provinsi Gorontalo.

4. KESIMPULAN

Berdasarkan hasil penelitian diperoleh kesimpulan bahwa peramalan curah hujan menggunakan metode *Singular Spectrum Analysis* (SSA) dengan *windows length* $L = 36$ sangat akurat dengan MAPE sebesar 2,9% dan dapat digunakan untuk meramalkan curah hujan tahun 2022-2023. Dari hasil peramalan terlihat bahwa curah hujan perbulan pada umumnya masih relatif tinggi. Sehingga perlu bagi pemerintah untuk mengambil kebijakan demi menghindari dampak negatif yang dapat ditimbulkan.

DAFTAR PUSTAKA

- Basari, M. S. N. and Achmad, A. I. (2021) 'Metode *Singular Spectrum Analysis* untuk Meramalkan Indeks Harga Konsumen Indonesia Tahun 2019', in *Prosiding Statistika SPeSIA*, 7(2), pp. 484-491. doi: <http://dx.doi.org/10.29313/v0i0.28777>
- Elsner, J. B. and Tsonis, A. A. (1999) *Singular Spectrum Analysis : A New Tool in Time Series Analysis*. New York : Plenum Press.
- Hassani, H. (2007) 'Singular Spectrum Analysis : Methodology and Comparison', *Journal of Data Science (JDS)*, 5(2), pp. 239-257. doi: [https://doi.org/10.6339/JDS.2007.05\(2\).396](https://doi.org/10.6339/JDS.2007.05(2).396)
- Irwan, Sauddin, A., and Kaimuddin, A. (2022) 'Proyeksi Produksi Padi Kabupaten Pinrang dengan Metode Singular Spectrum Analysis', *Jurnal Matematika dan Statistika serta Aplikasinya (JMSA)*, 10(1), pp. 100-109. doi: <https://doi.org/10.24252/msa.v10i1.29869>
- Myung, N. K. (2009) *Singular Spectrum Analysis*. California: University of California.
- Ruhyat, D., Andriani, D. and Kamilah, W. N. (2020) 'Forecasting Data Runtun Waktu Musiman Menggunakan Metode Singular Spectrum Analysis (SSA)', *Teorema : Teori dan Riset Matematika*, 5(1), pp. 47-16. doi: <http://doi.org/10.25157/teorema.v5i1.3286>
- Sakinah, A. M. (2008) 'Akurasi Peramalan Long Horizon dengan Singular Spectrum Analysis', *Kubik*, 3(2), pp. 93-99. doi: <http://doi.org/10.15575/kubik.v3i2.4111>
- Siregar, R. S. K., Prariesa, D. and Darmawan, G. (2017) 'Aplikasi Metode Singular Spectrum Analysis (SSA) dalam Peramalan Pertumbuhan Ekonomi Indonesia Tahun 2017', *Jurnal Matematika Mantik*, 3(1), pp. 5-12. doi: <http://doi.org/10.15642/mantik.2017.3.1.5-12>
- Sodiqin, M. A., Sulandari, W., and Respatiwan, (2021) 'The Application of Singular Spectrum Analysis Method in Forecasting the number of Foreign Tourist Visit to Special Capital Region of Jakarta', *Jurnal Riset dan Aplikasi Matematika (JRAM)*, 5(2), pp. 92-102. doi: <http://doi.org/10.26740/jram.v5n2>
- Utami, H., Sari, Y.W., Subanar, S., Abdurrakhman, A. and Gunardi, G. (2007) 'Peramalan Beban Listrik Daerah Istimewa Yogyakarta dengan Metode Singular Spectrum Analysis (SSA)', *Media Statistika*, 12(2), pp. 214-225. doi: <http://doi.org/10.14710/medstat.12.2.214-225>