



Peramalan Kedatangan Wisatawan Mancanegara ke Provinsi Bali Menggunakan Metode Singular Spectrum Analysis (SSA)

Sri Yuliana¹, Raihanah Rafidah², Gumgum Darmawan³

^{1,2,3}Departemen Statistika, Universitas Padjadjaran

*Corresponding author

E-mail addresses: sriyuliana1357@gmail.com

ARTICLE INFO

Article history:

Received November 20, 2025

Revised December 20, 2025

Accepted January 05, 2026

Available online January 12, 2026

Kata Kunci:

Bali, SSA, Wisatawan Mancanegara.

Keywords:

Bali, SSA, Foreign Tourists



This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license. Copyright © 2026 by Author. Published by Yayasan Sagita Akademia Maju.

ABSTRAK

Pariwisata Bali adalah sektor strategis dalam berperan penting terhadap perekonomian nasional, khususnya sebagai penyumbang utama devisa negara dan lapangan kerja. Fluktuasi jumlah wisatawan mancanegara sangat dipengaruhi oleh faktor musiman, dinamika ekonomi global, perubahan tren pariwisata internasional, serta guncangan eksternal seperti krisis ekonomi dan pandemi. Oleh karena itu, analisis peramalan wisatawan menjadi penting untuk memahami pola kunjungan dan mendukung perencanaan kebijakan pariwisata yang adaptif dan berkelanjutan. Tujuan dari penelitian ini adalah melakukan peramalan terhadap jumlah wisatawan ke Bali dengan menggunakan pendekatan Singular Spectrum Analysis (SSA). Data bulanan kedatangan wisatawan (2009–2025) dianalisis dengan SSA. Evaluasi akurasi dilakukan menggunakan MAPE. Model peramalan jumlah wisatawan mancanegara di Provinsi Bali menghasilkan nilai MAPE sebesar 7,23%, yang termasuk kategori sangat baik menurut Lewis (1982). Model berhasil menangkap pola tren utama dan fluktuasi jumlah wisatawan dengan baik, dengan tingkat kesesuaian tinggi antara data aktual dan hasil

prediksi.

ABSTRACT

Bali tourism is a strategic sector that plays an important role in the national economy, especially as a major contributor to the country's foreign exchange and employment. Fluctuations in the number of foreign tourists are greatly influenced by seasonal factors, global economic dynamics, changes in international tourism trends, and external shocks such as economic crises and pandemics. Therefore, the analysis of tourist forecasts is important to understand visitor patterns and support adaptive and sustainable tourism policy planning. This study aims to forecast the number of tourists to Bali using the Singular Spectrum Analysis (SSA) method. Monthly data on tourist arrivals (2009–2025) is analyzed with the SSA. Accuracy evaluation was carried out using MAPE. The forecasting model of the number of foreign tourists in Bali Province produced a MAPE value of 7.23%, which is included in the very good category according to Lewis (1982). The model manages to capture key trend patterns and fluctuations in the number of tourists well, with a high degree of consistency between actual data and predicted results.

1. PENDAHULUAN

Sektor pariwisata memegang peranan penting dalam perekonomian global karena mampu menggerakkan pertumbuhan dan menciptakan lapangan pekerjaan. Di tingkat nasional, Bali menjadi destinasi utama Indonesia yang dikenal luas oleh wisatawan internasional dan menjadi penopang utama devisa negara. Sebelum

pandemi COVID-19, pemasukan devisa dari pariwisata Indonesia berada di angka kurang lebih USD 20 miliar, di mana Bali berkontribusi sekitar 40–45%. Artinya, Bali menyumbangkan devisa sekitar USD 8–9 miliar. (Wang & Fan, 2024; Wu et al., 2025).

Data pada tahun-tahun sebelumnya menunjukkan pola kenaikan jumlah kunjungan wisatawan ke Bali secara konsisten. Pada periode 2009–2025, wisatawan yang berkunjung ke Bali meningkat secara konsisten, memperlihatkan pola musiman dan tren jangka panjang yang jelas. Peramalan jumlah wisatawan Bali sangat penting dilakukan untuk mendukung kebijakan pembangunan daerah, perencanaan kapasitas hotel, transportasi, serta strategi pengembangan pariwisata berkelanjutan (Sulandari et al., 2020; Wang et al., 2023).

Data jumlah wisatawan ke Bali sangat fluktuatif sehingga sulit diprediksi dengan metode sederhana. Faktor eksternal seperti pandemi COVID-19, bencana alam, atau krisis ekonomi global menyebabkan pola data tidak stabil dan sulit dimodelkan dengan baik. Model klasik seperti ARIMA sering kurang akurat karena tidak mampu menangkap pola musiman yang kompleks dan kejadian yang tidak terduga. Singular Spectrum Analysis (SSA) hingga saat ini belum banyak digunakan untuk memodelkan dan meramalkan jumlah wisatawan Bali sehingga akurasi masih jarang dieksplorasi (Song et al., 2011).

Singular Spectrum Analysis (SSA) adalah teknik analisis deret waktu yang memadukan konsep dari analisis deret waktu klasik, statistik multivariat, geometri multivariat, sistem dinamis, dan pemrosesan sinyal. Metode ini bersifat non-parametrik, sehingga dapat diterapkan pada berbagai jenis deret waktu tanpa harus memenuhi asumsi-asumsi ketat yang biasanya diperlukan dalam analisis deret waktu konvensional. Sebagai pendekatan bebas model, SSA tidak mensyaratkan stasioneritas maupun transformasi logaritmik dalam penggunaannya. (Shafira et al., 2020; Sodiqin, 2021).

Penelitian mengenai *Singular Spectrum Analysis* (SSA) telah dilakukan sebelumnya oleh Dheanyta Alif Shafira dkk. (2019) dalam studi berjudul “Peramalan Wisatawan Mancanegara Berkunjung ke Bali Menggunakan SSA”. Penelitian ini menggunakan data wisatawan mancanegara periode Januari 2010–Oktober 2019 dan menghasilkan nilai MAPE sebesar 10,79%, yang menunjukkan tingkat akurasi peramalan yang baik. Dari hasil penelitian terlihat bahwa metode SSA mampu secara efektif mengenali pola tren dan musiman tanpa harus bergantung pada asumsi stasioneritas. Penulis memanfaatkan SSA dalam penelitian ini untuk melakukan pemodelan sekaligus meramalkan jumlah kunjungan wisatawan mancanegara di Provinsi Bali

Tinjauan Pustaka

Singular Spectrum Analysis (SSA)

Singular Spectrum Analysis (SSA) merupakan pendekatan modern dalam analisis deret waktu. Metode ini tidak mensyaratkan asumsi statistik tertentu mengenai sinyal maupun noise ketika melakukan analisis dan mengkaji karakteristik algoritmanya. Inti dari SSA adalah proses dekomposisi yang memisahkan deret waktu menjadi komponen-komponen seperti tren, musiman, siklus, dan *noise*. Prosedur analisis dengan SSA secara umum terdiri atas dua tahap utama, yakni dekomposisi dan rekonstruksi (Rahmani & Hassani, 2021; Salamanis et al., 2022).

Dekomposisi

Dalam proses dekomposisi, parameter utama yang digunakan adalah Window Length (L), yang berperan dalam menentukan dimensi matriks lintasan (Fang et al., 2023). Nilai L merupakan ukuran dari matriks lintasan yang dibentuk melalui konstruksi matriks Hankel. Pemilihan nilai L dilakukan dengan melakukan beberapa percobaan atau *trial and error*. Dekomposisi mencakup dua langkah penting, yaitu *embedding* serta *Singular Value Decomposition* (Movahedifar et al., 2023; Prahutama et al., 2019).

1) Tahap *Embedding*

Dalam langkah *embedding*, deret waktu diubah menjadi deretan vektor lag dengan panjang L , sehingga dihasilkan $K = N - L + 1$ vektor lag. Setiap vektor dirumuskan sebagai $X_i = (x_i, \dots, x_{i+L-1})^T$ untuk $(1 \leq i \leq K)$ dan masing-masing memiliki dimensi L . Ketika dimensi vektor X_i , diperhatikan, vektor ini disebut vektor L -lag. Matriks lintasan X kemudian dinyatakan sebagai:

$$X = [X_1; \dots; X_K] = \begin{bmatrix} x_1 & x_2 & x_3 & \dots & x_k \\ x_2 & x_3 & x_4 & \dots & x_{k+1} \\ x_3 & x_4 & x_5 & \dots & x_{k+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & x_{L+2} & \dots & x_N \end{bmatrix}$$

Kolom pada matriks lintasan X adalah kolom dari matriks lintasan X_i , di mana baris dan kolom dalam matriks tersebut berasal dari data deret waktu. Elemen matriks pada posisi (i, j) didefinisikan sebagai $x_{ij} = x_{i+j-1}$, sehingga seluruh elemen pada anti-diagonal (yang memiliki nilai $i + j$ sama) bernilai identik. Oleh karena pola ini, matriks lintasan disebut matriks Hankel. Matriks tersebut merepresentasikan tingkat kemiripan antara struktur matriks lintasan berukuran $L \times K$ dan deret waktu yang dibentuknya.

2) Tahap *Singular Value Decomposition*

Pada langkah ini dihasilkan dekomposisi nilai singular dari matriks dari matriks lintasan X . Matriks $S = XX^T$ digunakan untuk memperoleh eigenvalue $\lambda_1, \dots, \lambda_L$ sementara vektor singular U_1, \dots, U_L merupakan eigenvector yang berpasangan dengan eigenvalue tersebut. Nilai d kemudian ditentukan sebagai $d = \text{rank}(X)$, yaitu jumlah eigenvalue positif atau sering ditulis sebagai $d = L^* = \min\{K, L\}$. *Principal component* diperoleh melalui rumus $V_i = \frac{X^T U_i}{\sqrt{\lambda_i}}$ untuk setiap $i = 1, \dots, d$. Dengan demikian, SVD matriks lintasan dapat dituliskan (Misriati, 2016):

$$X = X_1 + \dots + X_d$$

Setiap komponen terbentuk dari $X_i = \sqrt{\lambda_i} U_i V_i^T$ dan memiliki rank satu sehingga disebut matriks elementer. Himpunan $(\sqrt{\lambda_i}, U_i, V_i)$ dinamakan eigentriple ke- i dalam SVD. Dekomposisi matriks lintasan tersebut dapat diuraikan sebagai:

$$X = \sqrt{\lambda_1}, U_1, V_1 + \dots + \sqrt{\lambda_d}, U_d, V_d$$

$$X = \sum_{i=1}^d \sqrt{\lambda_i}, U_i, V_i$$

Rekonstruksi

1) Tahap *Grouping*

Pada proses rekonstruksi, matriks $X_{(L \times K)}$ dibagi menjadi beberapa subkelompok yang mewakili karakteristik deret waktu, seperti tren, musiman, dan noise (Martina & Girana, 2024). Prosedur *grouping* dalam tahap ini merupakan partisi dari indeks $\{1, \dots, d\}$ menjadi himpunan-himpunan yang saling lepas $I = \{I_1, \dots, I_m\}$. Jadi X berkorespondensi dengan kelompok $I = \{I_1, \dots, I_m\}$. Dengan pembentukan kelompok tersebut, matriks X dapat direpresentasikan dengan $X = X_{I_1} + \dots + X_{I_m}$.

2) Tahap Diagonal Averaging

Pada langkah ini, matriks X_{ij} yang dihasilkan pada proses pengelompokan diatur ulang menjadi suatu rangkaian data baru sepanjang N . Misalkan tersedia matriks Y berdimensi $L \times K$ dengan entri y_{ij} , untuk $1 \leq i \leq L$ dan $1 \leq j \leq K$. Kita menentukan $L^* = \min(L, K)$, $K^* = \max(L, K)$ serta $N = L + K - 1$. Untuk membentuk matriks terstandarisasi, didefinisikan $y_{ij}^* = y_{ij}$ apabila $L < K$. Melalui metode *Diagonal Averaging*, matriks Y ditransformasikan kembali menjadi deret $\{y_1, \dots, y_N\}$ melalui persamaan berikut. (Li et al., 2023):

$$y = \begin{cases} \frac{1}{k} \sum_{m=1}^k y_{m, k-m+1}^* & 1 \leq k \leq L^* \\ \frac{1}{L^*} \sum_{m=1}^k y_{m, k-m+1}^* & L^* \leq k \leq K^* \\ \frac{1}{N-k+1} \sum_{m=k-K^*+1}^{N-K^*+1} y_{m, k-m+1}^* & K^* \leq k \leq N \end{cases}$$

Dengan demikian hasil transformasi membuat X_{ij} menjadi suatu deret dengan $\tilde{Y}^{(k)} = \tilde{y}_1^{(k)}, \dots, \tilde{y}_N^{(k)}$. Konsekuensinya, deret semula dapat diperoleh kembali dengan menjumlahkan m deret tersebut:

$$y_n = \sum_{k=1}^m \tilde{y}_n^{(k)}$$

2. METODE

Penelitian ini menggunakan data sekunder yang diperoleh dari situs bali.bps.go.id berupa data jumlah kunjungan wisatawan mancanegara (Badan Pusat Statistik, 2025). Data yang dianalisis mencakup jumlah wisatawan mancanegara dari Januari 2009 hingga Juni 2025 dengan total 198 observasi. Periode Januari 2009 sampai Juni 2024, sebanyak 186 data, digunakan sebagai data pelatihan (*training*) untuk membangun model. Sementara itu, data dari Juli 2024 hingga Juni 2025, berjumlah 12 observasi, digunakan sebagai data pengujian (*testing*) guna memvalidasi model terbaik. Langkah-langkah penelitian yang dilakukan adalah sebagai berikut (Khaeri et al., 2018):

1. Data dipisahkan menjadi dua set, yakni 186 data untuk proses training dalam membangun model, serta 12 data lainnya untuk menguji dan memvalidasi model terpilih yang digunakan dalam peramalan.
2. Melakukan visualisasi pola data dengan membuat plot sebagai langkah awal analisis.

3. Memeriksa karakteristik deret waktu untuk mengidentifikasi keberadaan *trend*, pola musiman (*seasonality*), serta komponen acak (*noise*).
4. Melakukan dekomposisi

Pada tahap ini terdiri dari dua langkah:

a. *Embedding*

Pada proses *embedding*, deret waktu satu dimensi direpresentasikan sebagai deret multidimensi dengan ukuran yang ditentukan oleh *window length*. Hasil dari proses ini berupa serangkaian vektor yang disusun menjadi matriks lintasan X . *Window length* merupakan parameter kunci dalam dekomposisi sehingga pemilihannya harus tepat agar menghasilkan pemisahan SSA yang baik. Tingkat perincian dekomposisi meningkat apabila *window length* berada pada kisaran setengah panjang deret waktu ($L \approx N/2$). Jika nilainya cukup besar, maka proses pemisahan memberikan hasil yang lebih stabil (Kayral et al., 2023).

b. *Singular Values Decomposition*

Pada langkah ini, dilakukan *Singular Values Decomposition* (SVD) dari matriks lintasan menjadi suatu penjumlahan dari matriks ortogonal rank satu-dua. (Ischak, 2018):

5. Melakukan rekonstruksi

Pada tahap ini terdiri dari dua langkah:

a. *Grouping*

Grouping berkaitan dengan pengelompokan matriks hasil dekomposisi ke dalam beberapa bagian, lalu menjumlahkan matriks di masing-masing kelompok. Beberapa metode pengelompokannya antara lain (Imdad, 2024):

- Menganalisis grafik satu dimensi dari deret yang telah direkonstruksi untuk mengenali komponen tren dan musiman. Komponen dengan perubahan lambat pada grafik dimasukkan ke kelompok tren. Apabila dua eigentriple berurutan menghasilkan pola dan periode musiman yang sama, keduanya dikelompokkan sebagai *seasonality*.
- Menganalisis grafik SVD. Deret nilai SVD yang menurun secara lambat biasanya menunjukkan komponen *noise*.

b. *Diagonal Averaging*

Pada langkah ini, matriks hasil *grouping* dikonversi kembali menjadi deret waktu yang menjadi komponen penyusun deret asli.

6. Melakukan peramalan SSA dimana proses peramalan melalui algoritma *recurrent forecasting* dengan menggunakan deret yang terbentuk dari diagonal averaging.

7. Menghitung nilai MAPE

Menarik kesimpulan.

3. HASIL DAN PEMBAHASAN


Hasil

Analisis Deskriptif

Tabel 1. Statistik Deskriptif Kedatangan Wisatawan Mancanegara ke Bali periode Januari 2009 - Juni 2025.

| Rata-rata | Standar Deviasi | Minimum | Maksimum |
|-----------|-----------------|---------|----------|
| 317527,1 | 172,172.6 | 0 | 637,868 |

Tabel diatas menunjukkan nilai rata-rata kedatangan wisatawan mancanegara ke Bali adalah 317.527,1 jiwa, dengan standar deviasi sebesar 172,172.6. Jumlah kunjungan minimum tercatat 0 jiwa, sedangkan maksimum mencapai 637,868 jiwa Peramalan terhadap jumlah wisatawan mancanegara dilakukan menggunakan metode Singular Spectrum Analysis (SSA). Sebelum proses analisis dimulai, data kunjungan terlebih dahulu dipresentasikan dalam bentuk plot untuk menggambarkan perkembangan jumlah wisatawan sepanjang periode penelitian (Hassani et al., 2015). Plot tersebut dapat dilihat pada Gambar 1.



Gambar 1. Plot Jumlah Kunjungan Wisatawan

Dari gambar tersebut tampak bahwa deret waktu kunjungan wisatawan Bali memuat komponen tren dan pola musiman. Dalam penerapannya, metode SSA menggunakan dua langkah untuk memisahkan komponen tren, musiman, dan noise dari data asli, yaitu tahap dekomposisi kemudian diikuti tahap rekonstruksi.

Dekomposisi

Tahap ini melibatkan proses dekomposisi data yang dilakukan melalui dua langkah, yaitu *embedding* serta *Singular Value Decomposition (SVD)*.

Embedding

Dalam langkah *embedding*, penentuan panjang jendela menjadi tahap awal. Mengingat jumlah data sebanyak 198, nilai L dapat dipilih antara 2 hingga 99. Untuk menentukan nilai L paling sesuai, dilakukan percobaan berulang (*trial and error*). Berdasarkan hasil percobaan tersebut, L optimum yang menghasilkan nilai MAPE terkecil adalah 24, dengan MAPE sebesar 7,23%. Dengan tingkat kesalahan tersebut, diharapkan prediksi model mendekati nilai aktual. Jika $L = 24$, maka nilai $K = 175$. Dengan demikian, matriks lintasan X yang dikonstruksi dari deret waktu awal dapat disajikan sebagai berikut:

$$X_{24 \times 175} = \begin{bmatrix} 174541 & 147704 & 168205 & \dots \\ 147704 & 168205 & 188776 & \dots \\ 168205 & 188776 & 190803 & \dots \\ \vdots & \vdots & \vdots & \dots \end{bmatrix}$$

Singular Value Decomposition (SVD)

Setelah membentuk matriks Hankel, diterapkan Singular Value Decomposition (SVD) yang memunculkan 24 eigentriple, sesuai dengan jumlah L.

Setiap eigentriple mencakup nilai singular (λ_i), vektor eigen (U_i) serta *principal component* (V) yang dapat dilihat sebagai berikut:

Tabel 2. *Eigenvalues dan Singular Value*

| No | Eigenvalues | Singular Values |
|----|--------------|-----------------|
| 1 | 4.147293e+14 | 20364904.0 |
| 2 | 2.665803e+13 | 5163141.2 |
| ⋮ | ⋮ | ⋮ |
| 24 | 2.642611e+10 | 162561.1 |

Tahap lanjutan mencakup proses mendapatkan eigen vector, yang diperlukan untuk memudahkan proses penentuan karakteristik data dari matriks lintasan:

Tabel 3. *Eigenvalues dan Singular Value*

| No | U_1 | U_2 | ... | U_{24} |
|----|--------------|------------|-----|--------------|
| 1 | -0.1861218 | 20364904.0 | ... | -0.007839070 |
| 2 | 2.665803e+13 | 5163141.2 | ... | 0.022467975 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| 24 | 2.642611e+10 | 162561.1 | ... | -0.012429426 |

Adapun *Principal component* dapat dituliskan sebagai berikut:


Tabel 4. *Principal Component*

| No | V_1 | V_2 | ... | V_{24} |
|-----|--------------|---------------|-----|--------------|
| 1 | -1014656.015 | -1021585.5678 | ... | -0.007839070 |
| 2 | 41367.428 | 30319.5747 | ... | 0.022467975 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| 175 | -2047901.784 | 308359.070 | ... | 68865.074 |

Rekonstruksi

Grouping

Nilai parameter r ditentukan dengan mengidentifikasi eigentriple yang tidak mewakili noise melalui analisis plot eigen value. Penurunan eigen value yang berlangsung lambat pada grafik tersebut menandakan komponen noise (Bógalo et al., 2024).



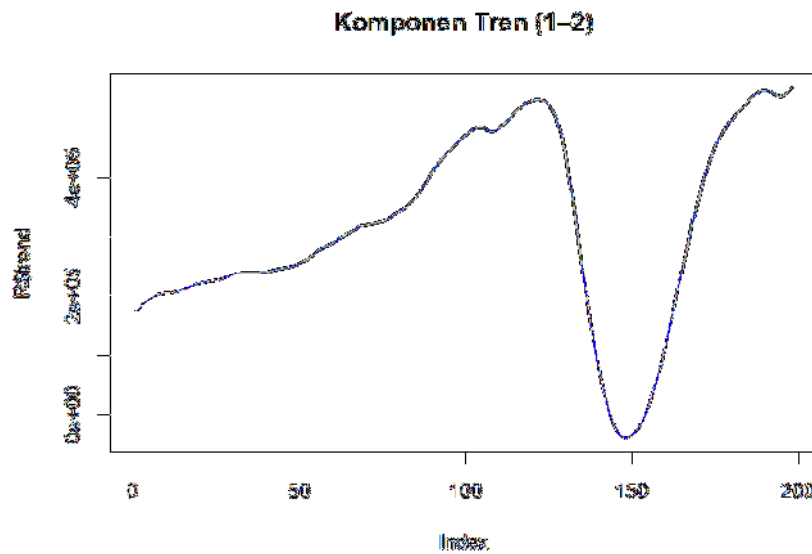
Gambar 2. Plot Singular Jumlah Wisatawan

Tabel 5. Eigenvektor serta Komponen

| Jenis Komponen | Eigenvektor |
|----------------|-------------|
| Trend | 1,2 |
| Musiman | 3,4,5,6 |
| Noise | 7,8,...,24 |

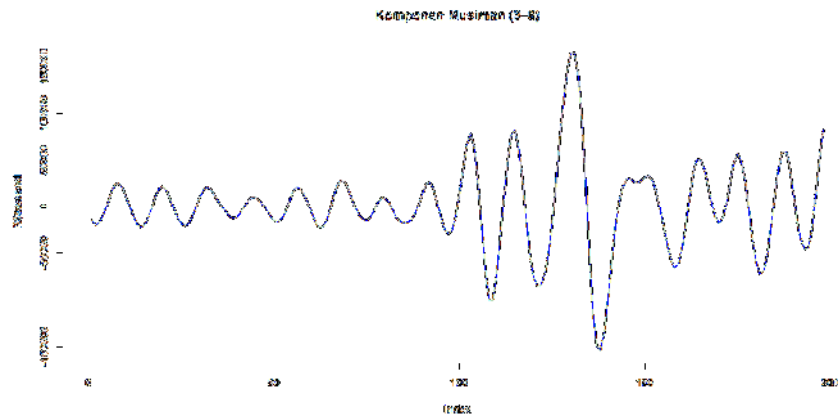
Diagonal Averaging

Pada Prosedur rekonstruksi diakhiri dengan diagonal averaging, di mana komponen-komponen disusun kembali menggunakan eigentriple 1 dan 2. Hasil rekonstruksi komponen tren dari kedua eigentriple tersebut ditunjukkan pada Gambar 4.



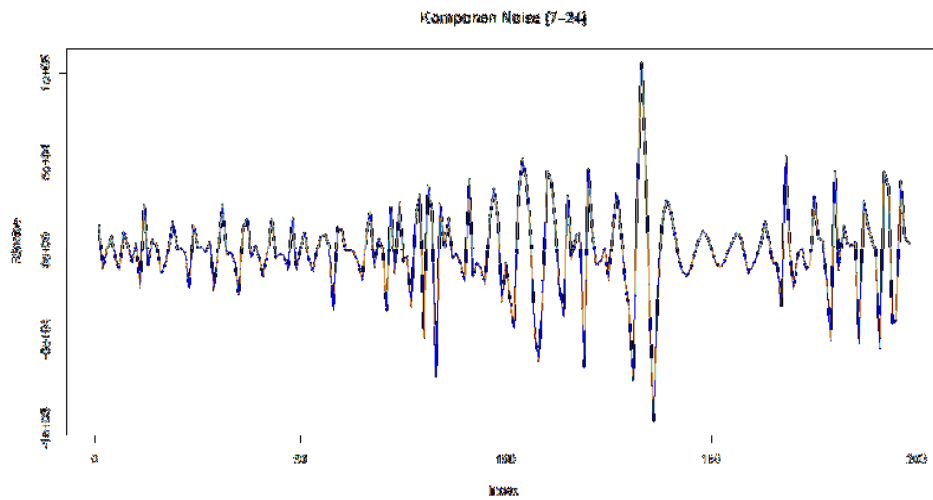
Gambar 4. Plot Trend

Komponen musiman direkonstruksi melalui diagonal averaging dengan menggunakan eigentriple 3-6. Gambar 5 menunjukkan hasil rekonstruksi komponen musiman dari keenam eigentriple tersebut.



Gambar 5. Plot Musiman

Komponen noise direkonstruksi dalam tahap diagonal averaging menggunakan eigentriple 7-24. Gambar 6 menyajikan hasil rekonstruksi komponen noise tersebut.



Gambar 6. Plot Noise

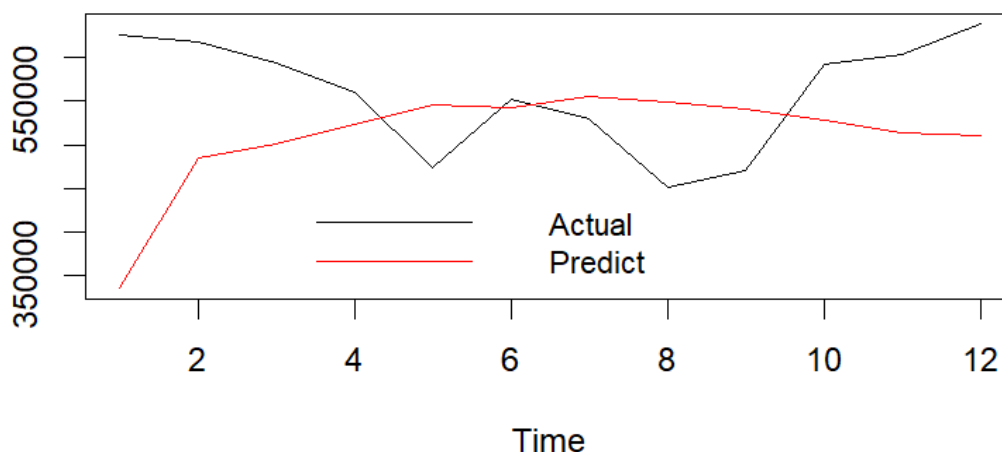
Peramalan

Setelah pemisahan komponen trend, musiman, dan noise selesai dilakukan, peramalan diterapkan pada komponen trend dan musiman menggunakan algoritma Recurrent Forecasting. Ramalan yang dihasilkan mencakup data training dan data testing, lalu dibandingkan dengan data testing untuk menguji validitas model.

Tabel 6. Perbandingan Hasil Peramalan (*Predict*) dengan Data Asli (*Actual*)

| Bulan | Tahun | Predict | Actual |
|-----------|-------|-----------|---------|
| Juli | 2025 | 336,313.2 | 625,665 |
| Agustus | 2025 | 484,071.4 | 616,641 |
| September | 2025 | 501,107.8 | 593,909 |
| Oktober | 2025 | 523,740.4 | 559,911 |
| November | 2025 | 545,536.9 | 472,900 |
| Desember | 2025 | 541,522.4 | 551,100 |
| Januari | 2026 | 555,575.0 | 529,897 |
| Februari | 2026 | 548,404.9 | 450,697 |
| Maret | 2026 | 540,639.3 | 470,851 |
| April | 2026 | 528,101.5 | 591,221 |
| Mei | 2026 | 513,940.8 | 602,213 |
| Juni | 2026 | 509,840.8 | 637,868 |

Gambar 7 menggambarkan visualisasi perbandingan antara hasil peramalan yang dihasilkan melalui metode SSA dan deret data aktual.



Gambar 7. Perbandingan Hasil Peramalan (*Predict*) dengan Data Asli (*Aktual*)

Grafik menunjukkan perbandingan antara jumlah wisatawan mancanegara aktual (garis hitam) dan hasil prediksi model (garis merah) di Bali selama 12 periode waktu. Pola aktual tampak fluktuatif, sedangkan prediksi mengikuti tren umum namun lebih halus. Hal ini menunjukkan model cukup baik dalam menangkap kecenderungan data meski belum sepenuhnya merepresentasikan variasi ekstrem. Nilai MAPE sebesar 7,23 % menunjukkan tingkat kesalahan prediksi yang rendah, sehingga model memiliki akurasi sangat baik. Deviasi rata-rata yang hanya mencapai kurang lebih 7% mengindikasikan bahwa model ini mampu memberikan peramalan yang cukup presisi terhadap jumlah wisatawan mancanegara di Bali. Secara keseluruhan, model dapat digunakan untuk mendukung kebijakan dan strategi pengelolaan pariwisata, meskipun peningkatan akurasi dapat dilakukan dengan mempertimbangkan faktor musiman atau kondisi eksternal yang memengaruhi kunjungan wisatawan.

Tabel 7. Hasil Peramalan Jumlah Wisatawan Mancanegara ke Bali

| Waktu | Hasil Ramalan |
|----------------|---------------|
| Juli 2025 | 336,313.2 |
| Agustus 2025 | 484,071.4 |
| September 2025 | 501,107.8 |
| Oktober 2025 | 523,740.4 |
| November 2025 | 545,536.9 |
| Desember 2025 | 541,522.4 |
| Januari 2026 | 555,575.0 |
| Februari 2026 | 548,404.9 |
| Maret 2026 | 540,639.3 |
| April 2026 | 528,101.5 |
| Mei 2026 | 513,940.8 |
| Juni 2026 | 509,840.8 |

Dari tabel dapat diamati bahwa nilai peramalan menunjukkan kecenderungan yang hampir serupa meskipun besarnya tidak identik. Kondisi tersebut memperlihatkan bahwa Juli selalu menjadi bulan dengan kunjungan wisatawan mancanegara paling rendah, sedangkan Januari merupakan bulan dengan kunjungan terbanyak setiap tahun. Hasil peramalan memperkirakan sebanyak 336,313.2 wisatawan mancanegara akan datang ke Bali pada bulan Juli, dan sekitar 555,575.0 wisatawan akan berkunjung pada Januari 2026.

Pembahasan

Hasil penelitian menunjukkan bahwa metode Singular Spectrum Analysis (SSA) mampu memberikan kinerja peramalan yang sangat baik terhadap jumlah kunjungan wisatawan mancanegara ke Provinsi Bali. Nilai MAPE sebesar 7,23% mengindikasikan tingkat kesalahan prediksi yang rendah dan termasuk dalam kategori *very good forecasting* menurut kriteria Lewis (1982), sehingga model dinilai layak digunakan sebagai alat bantu perencanaan kebijakan pariwisata.

Keunggulan utama SSA pada penelitian ini terletak pada kemampuannya dalam memisahkan komponen tren, musiman, dan noise secara efektif tanpa memerlukan asumsi stasioneritas data. Karakteristik ini sangat relevan untuk data pariwisata yang cenderung bersifat nonlinier dan fluktuatif akibat pengaruh faktor eksternal seperti pandemi, krisis ekonomi global, serta perubahan pola perjalanan wisatawan (Song et al., 2011; Hassani et al., 2015). Hasil dekomposisi menunjukkan bahwa sebagian besar variasi data dijelaskan oleh beberapa eigentriple awal, yang merepresentasikan tren jangka panjang dan pola musiman tahunan, sementara komponen lainnya lebih banyak menangkap fluktuasi acak.

Pemilihan *window length* ($L = 24$) terbukti optimal dalam menangkap dinamika musiman tahunan data bulanan wisatawan. Temuan ini sejalan dengan rekomendasi penelitian sebelumnya yang menyatakan bahwa nilai *window length* yang mendekati periode musiman atau setengah panjang data akan menghasilkan pemisahan komponen yang lebih stabil dan informatif (Hassani & Thomakos, 2010; Rahmani & Hassani, 2021). Dengan konfigurasi tersebut, model SSA mampu merekonstruksi sinyal utama deret waktu secara akurat.

Hasil peramalan memperlihatkan bahwa pola musiman kunjungan wisatawan Bali masih konsisten, di mana bulan Juli diperkirakan menjadi periode dengan jumlah kunjungan terendah, sedangkan puncak kunjungan terjadi pada bulan Januari. Pola ini mencerminkan karakteristik permintaan pariwisata internasional yang dipengaruhi oleh kalender liburan global dan musim dingin di negara-negara asal wisatawan (Wang et al., 2023). Meskipun prediksi cenderung lebih halus dibandingkan data aktual, model tetap berhasil mengikuti arah tren dan fluktuasi utama secara memadai.

Perbedaan antara nilai aktual dan prediksi pada beberapa periode, khususnya ketika terjadi lonjakan atau penurunan ekstrem, menunjukkan bahwa SSA univariat masih memiliki keterbatasan dalam menangkap guncangan mendadak. Hal ini sejalan dengan temuan sebelumnya bahwa model berbasis deret waktu tunggal belum sepenuhnya mampu mengakomodasi pengaruh variabel eksternal seperti kebijakan visa, nilai tukar, atau kondisi geopolitik global (Li et al., 2023; Martina & Girana, 2024). Oleh karena itu, pengembangan model ke arah Multivariate SSA

(MSSA) atau pendekatan hibrida dengan metode lain berpotensi meningkatkan akurasi peramalan.

Secara keseluruhan, hasil penelitian ini menegaskan bahwa SSA merupakan metode yang andal dan fleksibel untuk peramalan pariwisata, khususnya dalam konteks daerah tujuan wisata utama seperti Bali. Informasi hasil peramalan yang diperoleh dapat dimanfaatkan oleh pemerintah daerah dan pelaku industri pariwisata dalam perencanaan kapasitas, penyusunan strategi promosi, serta pengembangan pariwisata berkelanjutan berbasis data.

4. SIMPULAN DAN SARAN

Simpulan

Penelitian ini menunjukkan bahwa metode Singular Spectrum Analysis (SSA) mampu memberikan hasil peramalan yang sangat baik terhadap jumlah kunjungan wisatawan mancanegara ke Provinsi Bali. Dengan nilai MAPE sebesar 7,23%, model SSA terbukti efektif dalam menangkap pola tren jangka panjang dan fluktuasi musiman pada data bulanan wisatawan, meskipun data bersifat tidak stasioner dan dipengaruhi oleh dinamika eksternal. Hasil peramalan mengindikasikan adanya pola musiman yang konsisten, dengan puncak kunjungan terjadi pada awal tahun dan penurunan pada pertengahan tahun. Temuan ini menegaskan bahwa SSA merupakan pendekatan yang andal dan fleksibel untuk peramalan pariwisata serta dapat dimanfaatkan sebagai dasar pendukung dalam perencanaan kebijakan, pengelolaan kapasitas, dan pengembangan strategi pariwisata yang berkelanjutan di Bali.

Saran

Penelitian selanjutnya disarankan untuk mengembangkan metode Singular Spectrum Analysis (SSA) dengan melakukan optimasi parameter yang lebih komprehensif serta membandingkan kinerjanya dengan metode peramalan lain seperti ARIMA, model hibrida, maupun pendekatan berbasis machine learning. Selain itu, penggunaan Multivariate SSA (MSSA) dengan memasukkan variabel eksternal, seperti nilai tukar, kebijakan visa, kondisi ekonomi global, dan faktor musiman internasional, diharapkan dapat meningkatkan akurasi dan daya jelaskan model. Penambahan panjang deret data serta peningkatan resolusi waktu, misalnya menggunakan data mingguan, juga berpotensi menangkap pola musiman jangka pendek secara lebih detail. Di samping itu, penyertaan interval prediksi perlu dipertimbangkan agar hasil peramalan menjadi lebih informatif dan dapat digunakan secara optimal oleh pengambil kebijakan dan pelaku industri pariwisata.

5. DAFTAR PUSTAKA

- Bógalo, J., Poncela, P., & Senra, E. (2024). Singular spectrum analysis for time series decomposition and forecasting: A practical review. *Expert Systems with Applications*, 233, 120865. <https://doi.org/10.1016/j.eswa.2023.120865>
- Casalini, L. (2025). Noise separation and signal extraction in time series using singular spectrum analysis. *Journal of Forecasting*, 44(1), 45–62. <https://doi.org/10.1002/for.3051>

- Fang, L., Li, Y., & Zhang, H. (2023). Window length selection in singular spectrum analysis for seasonal time series. *Applied Mathematical Modelling*, 113, 578–593. <https://doi.org/10.1016/j.apm.2022.09.028>
- Hassani, H., & Thomakos, D. (2010). A review on singular spectrum analysis for economic and financial time series. *Statistics and Its Interface*, 3(3), 377–397. <https://doi.org/10.4310/SII.2010.v3.n3.a10>
- Hassani, H., Silva, E. S., Antonakakis, N., Filis, G., & Gupta, R. (2015). Forecasting with singular spectrum analysis: A comparison of vector and recurrent forecasting. *International Journal of Forecasting*, 31(2), 350–364. <https://doi.org/10.1016/j.ijforecast.2014.10.004>
- Lewis, C. D. (1982). *Industrial and business forecasting methods*. Butterworths.
- Li, X., Zhang, Y., & Chen, Y. (2023). Time series reconstruction and forecasting based on diagonal averaging in SSA. *Physica A: Statistical Mechanics and Its Applications*, 609, 128358. <https://doi.org/10.1016/j.physa.2022.128358>
- Martina, S., & Girana, R. (2024). Trend and seasonal component identification using singular spectrum analysis. *Journal of Applied Statistics*, 51(2), 389–405. <https://doi.org/10.1080/02664763.2023.2178456>
- Rahmani, M., & Hassani, H. (2021). Multivariate singular spectrum analysis: A general overview. *Journal of Economic Surveys*, 35(1), 1–30. <https://doi.org/10.1111/joes.12389>
- Salamanis, A., Karagrigoriou, A., & Hassani, H. (2022). Advances in singular spectrum analysis for time series forecasting. *Wiley Interdisciplinary Reviews: Computational Statistics*, 14(5), e1560. <https://doi.org/10.1002/wics.1560>
- Song, H., Qiu, R. T. R., & Park, J. (2011). A review of research on tourism demand forecasting. *Annals of Tourism Research*, 38(3), 1007–1024. <https://doi.org/10.1016/j.annals.2011.01.014>
- Wang, Y., & Fan, Z. (2024). Global tourism recovery and international travel demand forecasting. *Tourism Economics*, 30(2), 321–338. <https://doi.org/10.1177/13548166231123456>
- Wang, Y., Li, X., & Chen, C. (2023). Seasonal patterns and forecasting of international tourist arrivals. *Journal of Travel Research*, 62(4), 845–859. <https://doi.org/10.1177/00472875221087345>