# Aplikasi Metode Singular Spectrum Analysis (SSA) dalam Peramalan Produksi Padi di Provinsi Sulawesi Tenggara

Ega Sarmita*[1], Gusti Ngurah Adhi Wibawa[2], Bahridin Abapihi[3], Ruslan[4], Lilis Laome[5], Agusrawati[6]
Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Halu Oleo, Kendari, Indonesia[1,2,3,4,5,6]
*e-mail: egasarmita289@gmail.com

**ABSTRAK**

Penelitian ini bertujuan untuk meramalkan produksi padi di Provinsi Sulawesi Tenggara menggunakan metode Singular Spectrum Analysis (SSA) dan membandingkannya dengan metode Autoregressive Integrated Moving Average (ARIMA). Data produksi padi di Provinsi Sulawesi Tenggara dari tahun 2018 hingga 2021 dijadikan dasar untuk peramalan tahun 2022. Metode SSA digunakan untuk meramalkan produksi padi, dan hasilnya dibandingkan dengan metode ARIMA untuk menilai akurasi peramalan. Hasil penelitian menunjukkan bahwa model SSA dengan window length (panjang jendela) L=25 merupakan model terbaik untuk meramalkan produksi padi di Provinsi Sulawesi Tenggara selama dua belas bulan ke depan (yi = yiT + yiS). Model ini memiliki nilai Mean Absolute Percentage Error (MAPE) sebesar 23,68%, menunjukkan tingkat akurasi yang tinggi dalam meramalkan produksi padi. Perbandingan akurasi peramalan antara metode SSA dan ARIMA menunjukkan bahwa SSA lebih unggul. Akurasi peramalan dengan SSA mencapai 23,68%, sementara ARIMA memiliki MAPE sebesar 48,16%. Hal ini menegaskan bahwa SSA lebih efektif dan akurat dalam meramalkan produksi padi di Provinsi Sulawesi Tenggara dibandingkan dengan ARIMA. Kesimpulan dari penelitian ini adalah bahwa metode SSA dapat menjadi pilihan yang lebih tepat dan efektif dalam meramalkan produksi padi di daerah ini. Keakuratan peramalan yang tinggi menunjukkan potensi aplikasi SSA dalam mendukung perencanaan dan pengambilan keputusan terkait produksi padi di Provinsi Sulawesi Tenggara.

***Kata kunci*** : *ARIMA; Produksi Padi; Seasonality; Singular Spectrum Analysis(SSA); Tren*

***ABSTRACT***

*This study aims to forecast rice production in the Southeast Sulawesi Province using the Singular Spectrum Analysis (SSA) method and comparing it with the Autoregressive Integrated Moving Average (ARIMA) method. Rice production data in Southeast Sulawesi Province from 2018 to 2021 serves as the basis for forecasting in 2022. The SSA method is employed to forecast rice production, and its results are compared with the ARIMA method to assess forecasting accuracy. The research findings indicate that the SSA model with a window length (L) of 25 is the most effective model for forecasting rice production in Southeast Sulawesi Province for the next twelve months (yi = yiT + yiS). This model exhibits a Mean Absolute Percentage Error (MAPE) of 23.68%, demonstrating a high level of accuracy in predicting rice production. A comparison of forecasting accuracy between the SSA and ARIMA methods reveals the superiority of SSA. The forecasting accuracy with SSA reaches 23.68%, while ARIMA has a MAPE of 48.16%. This confirms that SSA is more effective and accurate in predicting rice production in Southeast Sulawesi Province compared to ARIMA. The conclusion drawn from this research is that the SSA method is a more suitable and effective choice for forecasting rice production in this region. The high forecasting accuracy suggests the potential application of SSA in supporting planning and decision-making related to rice production in the Southeast Sulawesi Province.*

***Keywords :*** *ARIMA; Rice Production; Seasonality; Singular Spectrum Analysis(SSA); Tren*

## PENDAHULUAN

Bidang studi statistik memainkan peran sentral dalam pengembangan ilmu pengetahuan dan penelitian. Penerapan konsep persamaan matematika menjadi kunci dalam menganalisis model statistik, memungkinkan kita menjelajahi berbagai aspek pengetahuan ilmiah. Proses peramalan, sebagai kegiatan yang meramalkan peristiwa masa depan, memegang peranan penting dalam menyusun prediksi mengenai

situasi atau kondisi yang akan muncul. Para peneliti sering kali mengandalkan metode peramalan sebagai alat kuantitatif untuk memproyeksikan peristiwa berdasarkan data yang relevan dari masa lalu. Salah satu pendekatan peramalan yang populer adalah analisis deret waktu, atau lebih dikenal sebagai "time series." Menurut Harsyiah et al. (2020), metode seri waktu diperkenalkan melalui buku "Time Series Analysis: Forecasting and Control" oleh George E.P. Box dan Gwilym M. Jenkins pada tahun 1970. Deret waktu mencakup nilai pengamatan yang diukur selama periode waktu tertentu, disusun berdasarkan interval waktu yang tetap. Metode seri waktu bertujuan untuk memanfaatkan data historis dan mengekstrapolasikan pola yang teridentifikasi ke masa depan. Pendekatan ini memungkinkan kita meramalkan potensi situasi yang akan muncul, seperti yang dijelaskan oleh Sarwo dan Hermawan (2019). Dengan demikian, pemahaman mendalam terhadap metode ini menjadi krusial dalam menghadapi tantangan meramalkan dan menginterpretasi peristiwa yang akan datang.

Analisis Spektrum Tunggal (AST) merupakan teknik peramalan data deret waktu yang tengah mengalami perkembangan pesat. Pada tahun 2019, Sari dkk. melakukan perbandingan antara AST, SARIMA, ARAR, dan Holt-Winter Seasonal dalam meramalkan jumlah kematian akibat kecelakaan di Amerika Serikat pada tahun 1973. Berdasarkan Mean Absolute Error (MAE) dan Mean Relative Absolute Error (MRAE), AST terbukti sebagai salah satu metode terunggul dalam melakukan peramalan. AST menjadi metode analisis data deret waktu yang sangat efektif untuk mengungkap pola tren dan elemen lainnya dalam struktur secara sederhana. AST menandai kehadiran metode analisis deret waktu inovatif yang menggabungkan pemrosesan sinyal, sistem dinamis, statistika multivariat, geometri multivariat, dan unsur analisis deret waktu klasik. Konsep AST, seperti yang diuraikan oleh Marjuni (2022), adalah untuk memisahkan data asli menjadi segmen-segmen kecil yang bersifat independen, memudahkan pemahaman. Temuan penelitian oleh Susila dkk. (2023) menunjukkan bahwa Model AST memiliki keunggulan dibandingkan dengan model deret waktu lainnya, termasuk ARIMA. Model AST terlihat lebih fleksibel dan mampu memodelkan musiman dengan waktu multiperiode dan musiman yang kompleks. Lebih lanjut, model AST tidak terikat oleh persyaratan seperti independensi dan normalitas residual, yang mengungguli ARIMA sebagai model peramalan yang lebih optimal.

Dalam peramalan jangka pendek, metode Autoregresif Integrated Moving Average (ARIMA) atau dikenal sebagai metode Box-Jenkins dalam analisis runtun waktu telah terbukti sangat efisien (Garini & Anbiya, 2022). Walaupun demikian, peramalan jangka panjang seringkali menunjukkan tingkat akurasi yang kurang memuaskan, terutama saat grafik cenderung datar atau konstan dalam jangka waktu yang lebih luas. ARIMA mampu memberikan prediksi yang cepat dan tepat dengan menggunakan data dari variabel dependen saat ini dan masa lalu, tanpa melibatkan variabel independen dalam proses peramalan. Kelebihan dari model ARIMA adalah kemampuannya menyesuaikan diri dengan situasi di mana observasi dalam deret waktu saling berhubungan secara statistik, mencerminkan adanya keterkaitan dependen di antara mereka (Kontopoulou et al., 2023). Model ARIMA bertujuan untuk mengidentifikasi hubungan statistik yang signifikan antara variabel yang akan diprediksi dengan nilai historis variabel tersebut. Hal ini memungkinkan pembuatan prediksi yang dapat diandalkan melalui penerapan model ini (Pradana et al., 2020). ARIMA mengikuti tiga langkah utama: identifikasi, penaksiran, dan pengujian, serta pemeriksaan diagnostik (Garini & Anbiya, 2022). Perlu diingat bahwa sebagian besar deret waktu berkala bersifat tidak stasioner, yang berarti data cenderung mengalami pertumbuhan atau penurunan. Oleh karena itu, unsur Autoregresif (AR) dan Moving Average (MA) dari model ARIMA hanya berlaku pada deret waktu berkala yang stasioner (Purnama & Juliana, 2020). Penggunaan ARIMA sangat tergantung pada stasioneritas, di mana data tidak mengalami perubahan atau fluktuasi yang signifikan seiring waktu (Qadrini et al., 2020). Untuk mencapai stasioneritas, deret waktu yang awalnya tidak stasioner harus melalui proses differencing, yaitu menghitung perubahan atau perbedaan nilai yang teramati. Hasil differencing kemudian diperiksa untuk memastikan bahwa stasioneritas tercapai. Jika varians tetap tidak stasioner, transformasi logaritma juga dapat diaplikasikan.

Indonesia, dengan kekayaan alamnya yang melimpah, seharusnya memprioritaskan ketahanan pangan sebagai strategi utama dalam persaingan internasional. Sayangnya, realitasnya menunjukkan bahwa Indonesia masih berjauhan dengan pencapaian tersebut, terutama dalam menghadapi tekanan untuk

mempertahankan ekspor produk pangan. Sebagai informasi, Indonesia saat ini menduduki peringkat keempat sebagai negara pengimpor beras terbesar di dunia, suatu fakta yang mencerminkan karakteristik pertanian di negeri ini (Arsani, 2020). Melihat sejarahnya, Indonesia pernah mencapai swasembada pangan pada periode 1984-1986, dengan konsumsi nasional hanya mencapai 25 juta ton dan menghasilkan surplus sebesar 2 juta ton. Pada tahun 2014, Indonesia bahkan masih menjadi produsen beras tertinggi ketiga di dunia setelah Tiongkok dan India, mencerminkan tingginya tingkat produksi beras pada masa itu. Sayangnya, tren ini berubah, dengan produksi padi Indonesia yang mencapai 59 juta ton pada tahun 2018, namun mengalami penurunan menjadi 54 juta ton pada tahun 2019. Sejak tahun 2000, Indonesia terus melakukan impor beras untuk memastikan ketersediaan di dalam negeri. Alasan di balik tingginya jumlah impor beras adalah populasi yang besar dan tingginya tingkat konsumsi di Indonesia. Bandingkan dengan negara lain, konsumsi beras per kapita di Indonesia jauh lebih tinggi. Meskipun konsumsi beras global hanya sekitar 60 kilogram per tahun, di Indonesia, angka tersebut bisa mencapai hampir 120 kilogram per tahun (Ariska & Bagus, 2021). Fakta ini menunjukkan perlunya langkah-langkah konkret untuk mengatasi tantangan ketahanan pangan agar Indonesia dapat menghadapi persaingan global dengan lebih efektif.

Penelitian ini meramalkan produksi padi di Provinsi Sulawesi Tenggara, Indonesia, dengan menggunakan metode Singular Spectrum Analysis (SSA). Meskipun metode peramalan kuantitatif seperti ARIMA telah terbukti efektif, SSA menawarkan pendekatan yang lebih mutakhir dan fleksibel dalam menganalisis deret waktu. Keistimewaan SSA dalam menguraikan pola tren dan komponen lainnya dengan struktur yang sederhana membuatnya mendapat perhatian khusus dalam konteks peramalan produksi padi. Penelitian ini memberikan kontribusi berharga terhadap literatur dengan melakukan perbandingan antara SSA, SARIMA, ARAR, dan Seasonal Holt-Winter, sebagaimana dilakukan oleh Sari et al pada tahun 2019. Hasil evaluasi Mean Absolute Error (MAE) dan Mean Relative Absolute Error (MRAE) menunjukkan bahwa SSA merupakan salah satu metode terbaik. Temuan ini tidak hanya memperkaya pemahaman tentang keunggulan SSA dalam meramalkan data deret waktu, tetapi juga mengarah pada pemahaman yang lebih mendalam terkait tantangan ketahanan pangan di tingkat regional. Dalam konteks ketahanan pangan Indonesia, terutama dalam menghadapi persaingan ekspor dan mencapai swasembada pangan, penelitian ini memberikan fokus khusus pada analisis peramalan produksi padi di Provinsi Sulawesi Tenggara. Implikasi dari penelitian ini dapat mendukung perumusan kebijakan ekonomi makro yang stabil, memastikan ketersediaan dan stabilitas harga pangan di masa depan. Oleh karena itu, penelitian ini tidak hanya berperan dalam perkembangan metodologi peramalan, tetapi juga memiliki dampak praktis yang signifikan dalam konteks pembangunan ekonomi dan ketahanan pangan di Indonesia.

## METODE PENELITIAN

Penelitian ini dilakukan di Laboratorium Statistika, Lantai 3 Gedung A Fakultas Matematika dan Ilmu Pengetahuan Alam (MIPA) Universitas Halu Oleo, Kota Kendari, Provinsi Sulawesi Tenggara, mulai bulan Oktober 2021 hingga Maret 2022. Jenis penelitian yang diadopsi adalah penelitian terapan, dengan fokus pada pemecahan masalah praktis dunia modern, khususnya dalam hal peramalan produksi padi. Metodologi penelitian bersifat kuantitatif, dengan penekanan pada pengolahan data yang sistematis untuk menjawab pertanyaan spesifik terkait permasalahan praktis tersebut. Data yang digunakan berasal dari Badan Pusat Statistik (BPS) Provinsi Sulawesi Tenggara, mencakup Hasil Produksi Padi dari bulan Januari 2018 hingga Desember 2021. Variabel penelitian yang digunakan adalah Jumlah Produksi Padi di Provinsi Sulawesi Tenggara. Data tersebut dibagi menjadi dua bagian, yaitu data in-sample (36 data dari Januari 2018 hingga Desember 2020) dan data out-sample (12 data dari Januari hingga Desember 2021). Metode peramalan yang diterapkan dalam penelitian ini melibatkan Singular Spectrum Analysis (SSA) dan Autoregressive Integrated Moving Average (ARIMA), dengan fokus pada variabel tunggal, yaitu Jumlah Produksi Padi di Provinsi Sulawesi Tenggara selama periode tersebut. Prosedur penelitian mencakup langkah-langkah mulai dari persiapan data, plot analisis data, tahap dekomposisi (embedding dan Singular Value Decomposition), tahap rekonstruksi (grouping dan diagonal averaging), pembentukan model SSA, hingga peramalan menggunakan SSA dan ARIMA. Pengolahan data dilakukan menggunakan teknik peramalan time series dengan metode SSA, dan penyimpanan serta pengolahan data menggunakan Microsoft Excel dan software R. Akurasi peramalan akan dievaluasi dan dibandingkan dengan metode time series klasik, ARIMA, untuk menentukan model terbaik. Analisis data terfokus pada tahap dekomposisi dan rekonstruksi, dengan

langkah-langkah rinci seperti embedding, SVD, grouping, dan diagonal averaging. Penelitian ini tidak hanya mencari solusi praktis terkait peramalan produksi padi, tetapi juga memberikan kontribusi terhadap literatur melalui penerapan metode peramalan yang inovatif dalam konteks ketahanan pangan di Indonesia.

## HASIL DAN PEMBAHASAN

### Peramalam Data Simulasi menggunakan Metode SSA

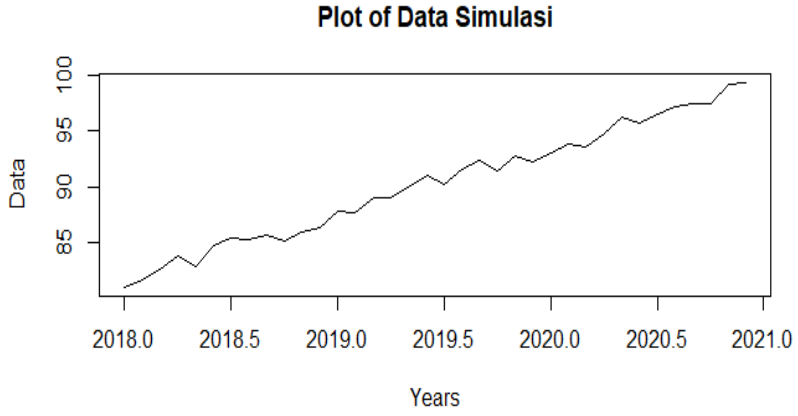
Dalam upaya untuk meramalkan produksi padi, langkah awal yang perlu dipahami adalah kajian mengenai metode Singular Spectrum Analysis (SSA) dengan menggunakan data simulasi. Pada tahap awal ini, fokus akan diberikan pada pemahaman metode SSA, yang akan diterapkan pada sampel data simulasi sebanyak 48 observasi (n = 48) dengan rentang waktu t = 1, 2, ..., 48. Data simulasi tersebut dihasilkan secara acak (Ɛt) menggunakan program R, dengan nilai rata-rata 0 dan simpangan baku sebesar 10, yang mengikuti distribusi normal. Neog et al., (2022) menyatakan untuk membentuk data acak menjadi suatu rangkaian waktu, digunakan persamaan Yt = α + bt + Ɛt, di mana α dan b masing-masing setara dengan 80 dan 2. Oleh karena itu, hasil simulasi dari data ini akan dibahas lebih lanjut dan diuraikan dalam Tabel 1.

**Tabel 1.** Pembangkitan Data Simulasi

| $T$ | $\hat{Y}_t$ | $\varepsilon_t$ | $Y_t$ |
|---|---|---|---|
| 1 | 80.765 | 0.265 | 81.03 |
| 2 | 81.372 | 0.372 | 81.744 |
| 3 | 82.072 | 0.572 | 82.644 |
| 4 | 82.908 | 0.908 | 83.816 |
| 5 | 82.701 | 0.201 | 82.902 |
| 6 | 83.898 | 0.898 | 84.796 |
| 7 | 84.445 | 0.945 | 85.39 |
| 8 | 84.66 | 0.66 | 85.32 |
| 9 | 85.129 | 0.629 | 85.758 |
| 10 | 85.062 | 0.062 | 85.124 |
| 11 | 85.706 | 0.206 | 85.912 |
| 12 | 86.176 | 0.176 | 86.352 |
| 13 | 87.186 | 0.686 | 87.872 |
| 14 | 87.384 | 0.384 | 87.768 |
| 15 | 88.269 | 0.769 | 89.038 |
| 16 | 88.497 | 0.497 | 88.994 |
| 17 | 89.217 | 0.717 | 89.934 |
| 18 | 89.992 | 0.992 | 90.984 |
| 19 | 89.88 | 0.38 | 90.26 |
| 20 | 90.777 | 0.777 | 91.554 |
| 21 | 91.435 | 0.935 | 92.37 |
| 22 | 91.212 | 0.212 | 91.424 |
| 23 | 92.151 | 0.651 | 92.802 |
| 24 | 92.125 | 0.125 | 92.25 |
| 25 | 92.767 | 0.267 | 93.034 |
| 26 | 93.386 | 0.386 | 93.772 |
| 27 | 93.513 | 0.013 | 93.526 |
| 28 | 94.382 | 0.382 | 94.764 |
| 29 | 95.369 | 0.869 | 96.238 |
| 30 | 95.34 | 0.34 | 95.68 |

| | | | |
|---|---|---|---|
| 31 | 95.982 | 0.482 | 96.464 |
| 32 | 96.599 | 0.599 | 97.198 |
| 33 | 96.992 | 0.492 | 97.484 |
| 34 | 97.186 | 0.186 | 97.372 |
| 35 | 98.327 | 0.827 | 99.154 |
| 36 | 98.668 | 0.668 | 99.336 |
| 37 | 99.294 | 0.794 | 100.088 |
| 38 | 99.108 | 0.108 | 99.216 |
| 39 | 100.223 | 0.723 | 100.946 |
| 40 | 100.411 | 0.411 | 100.822 |
| 41 | 101.321 | 0.821 | 102.142 |
| 42 | 101.646 | 0.646 | 102.292 |
| 43 | 102.282 | 0.782 | 103.064 |
| 44 | 102.552 | 0.552 | 103.104 |
| 45 | 103.029 | 0.529 | 103.558 |
| 46 | 103.789 | 0.789 | 104.578 |
| 47 | 103.523 | 0.023 | 103.546 |
| 48 | 104.477 | 0.477 | 104.954 |

Pada simulasi ini, terdapat dua komponen utama dalam data, yaitu komponen tren dan komponen musiman. Data tersebut dibagi menjadi dua kelompok, yaitu data in-sample yang mencakup 36 observasi dengan rentang waktu t = 1,2,...,36, dan data out-sample dengan 12 observasi yang meliputi rentang waktu t = 37,38,...,48. Gambar 1 menunjukkan plot time series dari data simulasi, memberikan gambaran visual terhadap pola dan karakteristik data tersebut.

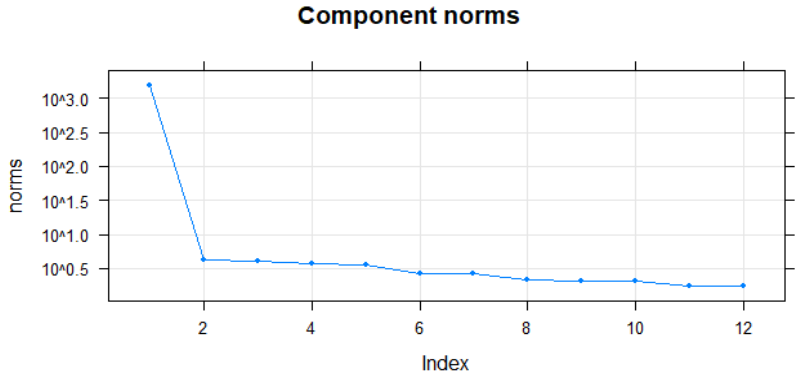



**Gambar 1.** Plot *Time Series* Data Simulasi

Dalam analisis data simulasi, Gambar 1 menunjukkan pola musiman dengan periode musiman 3 dan tren kenaikan tahunan. Pola ini terlihat dalam plot time series yang memiliki pergerakan yang konsisten setiap periode 3. Metode Singular Spectrum Analysis (SSA) digunakan untuk memisahkan komponen trend, seasonality, dan noise dari deret waktu (Amalia, 2022). Tahap pertama, dekomposisi, melibatkan embedding deret waktu F = (69.69, 81.04, ..., 299.70) dengan panjang N = 48 dan penggunaan parameter window length (L) sebesar 25 untuk menghasilkan nilai MAPE yang optimal. Matriks lintasan X kemudian didekomposisi menggunakan singular value decomposition (SVD) menjadi 12 eigentriple.

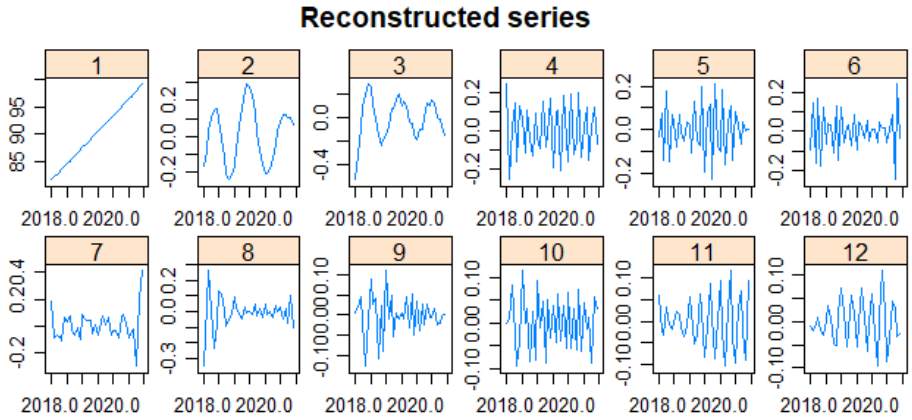
$$X = [X_1 : \ldots : X_{44}] = (x_{ij})_{i,j=1}^{25,48} = \begin{bmatrix} 81{,}03 & 81{,}74 & \cdots & 86{,}35 \\ 81{,}74 & 82{,}64 & \cdots & 87{,}87 \\ \vdots & \vdots & \ddots & \vdots \\ 93{,}03 & 93{,}77 & \cdots & 99{,}34 \end{bmatrix}$$

Tahap kedua, rekonstruksi, memanfaatkan hasil dekomposisi tersebut. Penelitian oleh (Sari et al., 2019) menunjukkan langkah pengelompokan pada tahap rekonstruksi menggunakan parameter effect grouping (r) untuk membatasi eigentriple yang digunakan dalam identifikasi komponen trend dan seasonality, dengan nilai r ditentukan berdasarkan plot singular dari data simulasi (Gambar 2).




**Gambar 2.** Plot Singular Data Simulasi

Berdasarkan Gambar 2, terlihat bahwa nilai singular menurun lambat dari eigentriple 6 hingga eigentriple 10, yang kemudian diidentifikasi sebagai komponen noise dengan parameter effect grouping (r) sebesar 7. Meskipun identifikasi komponen noise telah dilakukan, kemungkinan jumlah eigentriple yang mencerminkan noise dapat bertambah. Setelah pengelompokan komponen noise, langkah selanjutnya adalah mengelompokkan eigentriple yang terkait dengan trend dan seasonality. Sebanyak 7 eigentriple digunakan untuk mengidentifikasi komponen trend dan seasonality, termasuk eigentriple 1 hingga 5, serta eigentriple 11 dan 12 (Gambar 3).




**Gambar 3.** Plot Deret Rekontruksi

Eigentriple 1 menemukan komponen tren karena deret yang direkonstruksinya menunjukkan variasi yang lambat. Nilai singular yang mirip digunakan untuk mengatur eigentriple yang terkait dengan seasonality. Untuk ilustrasi, eigentriple 4 dan 5 dikategorikan ke dalam kategori musiman karena memiliki pola musiman yang sebanding, yaitu sekitar 3 bulan. Sebaliknya, eigentriple 11 dan 12 dikategorikan ke dalam kategori musiman karena memiliki periode musiman yang sama, yaitu 4 bulan (Tabel 2). Metode ESPRIT digunakan untuk menghitung periode musiman eigentriple yang memiliki nilai singular yang sama..

**Tabel 2.** Komponen yang Berhubungan dengan *Seasonality*

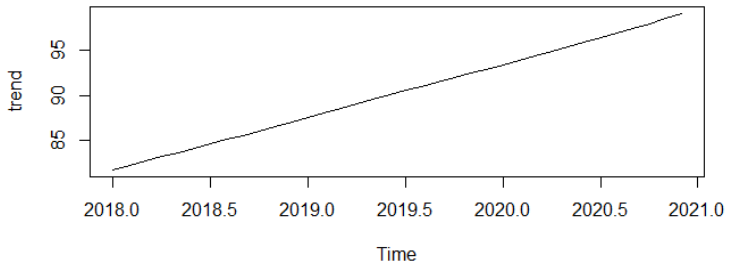
| ***Eigentriple*** | **Bulan** |
|---|---|
| 4 | 3 |
| 5 | 3 |
| 11 | 4 |
| 12 | 4 |

Dengan demikian sisa *eigentriple* yang tidak dikelompokan ke dalam kelompok *trend* dan *seasonality* dari 7 *eigentriple* sebelumnya akan dikelompokan ke dalam kelompok *noise*. Sisa *eigentriple* yang tidak dikelompokan ke dalam kelompok *trend* dan *seasonality* dari 7 *eigentriple* pada plot sebelumnya terdiri dari *eigentriple* 2 dan 3 masuk ke dalam komponen *noise*. Berikut merupakan Tabel 3 menyajikan secara lengkap 12 *eigentriple* dan komponen yang terkait.

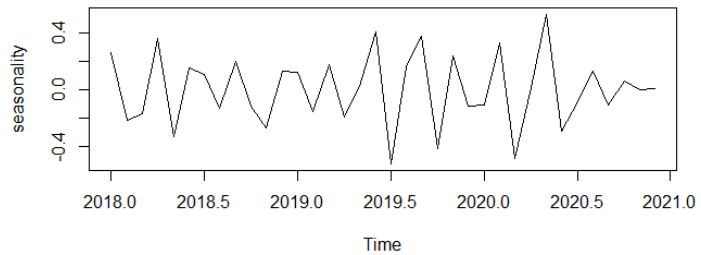
**Tabel 3.** *Eigentriple* Komponen

| **Jenis Komponen** | ***Eigentriple*** |
|---|---|
| *Seasonality* | 4, 5, 11 dan 12 |
| *Trend* | 1 |
| *Noise* | 2, 3, 6, 7, .., dan 10 |

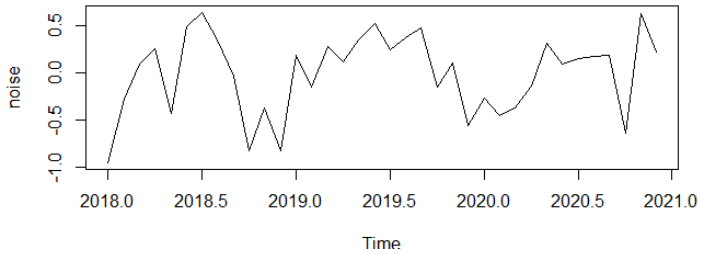
Diagonal averaging adalah langkah terakhir dalam tahap rekonstruksi data. Pada titik ini, setiap bagian dipulihkan dengan eigentriple yang sesuai. Komponen tren direkonstruksi menggunakan eigentriple 1 karena menunjukkan pola lambat yang berbeda dari eigentriple lainnya. Ini terlihat pada Gambar 4 yang menunjukkan hasil rekonstruksi komponen trend menggunakan eigentriple 1. Selain itu, komponen musim direkonstruksi oleh eigentriple 4, 5, 11, dan 12, seperti yang terlihat pada Gambar 5. Komponen suara direkonstruksi menggunakan eigentriple 2, 3, serta eigentriple 6 hingga 10.




**Gambar 4.** Plot *Trend* Rekontruksi




**Gambar 5.** Plot *Seasonality* Rekontruksi




**Gambar 6.** Plot *Noise* Rekontruksi

Pada tahap peramalan, setelah berhasil memisahkan komponen trend, seasonality, dan noise, langkah selanjutnya menggunakan peramalan berulang SSA. Peramalan dilakukan terpisah untuk komponen trend dan komponen seasonality. Model SSA menghasilkan nilai ramalan untuk data in-sample dan data out-sample. Untuk komponen trend, metode SSA secara matematis menuliskan peramalan untuk data in-sample dan out-sample.

1. Untuk data *in-sample*

   Metode SSA menghasilkan *trend* yang direkontruksi, yaitu $y_0^T, y_1^T, ..., y_{24}^T$.

   dimana $y_i^T = 99{,}11130 y_{i-1}^T + 9852210 y_{i-2}^T + ... + 8171865 y_{i-24}^T$,

   untuk $i$ = 25,26,...,35

2. Untuk data *out-sample*

   Metode SSA menghasilkan *trend* yang direkontruksi, yaitu $y_0^T, y_1^T, ..., y_{24}^T$.

$$y_{36}^T = 99{,}11130 y_{35}^T + 98{,}52210 y_{34}^T + ... + 81{,}71865 y_{12}^T$$

$$y_{37}^T = 99{,}11130 y_{36}^T + 98{,}52210 y_{35}^T + ... + 81{,}71865 y_{13}^T$$

$$y_{38}^T = 99{,}11130 y_{37}^T + 98{,}52210 y_{36}^T + ... + 81{,}71865 y_{14}^T$$

$$y_{39}^T = 99{,}11130 y_{38}^T + 98{,}52210 y_{37}^T + ... + 81{,}71865 y_{15}^T$$

$$y_{40}^T = 99{,}11130 y_{39}^T + 98{,}52210 y_{38}^T + ... + 81{,}71865 y_{16}^T$$

$$y_{41}^T = 99{,}11130 y_{40}^T + 98{,}52210 y_{39}^T + ... + 81{,}71865 y_{17}^T$$

$$y_{42}^T = 99{,}11130 y_{41}^T + 98{,}52210 y_{40}^T + ... + 81{,}71865 y_{18}^T$$

$$y_{43}^T = 99{,}11130 y_{42}^T + 98{,}52210 y_{41}^T + ... + 81{,}71865 y_{19}^T$$

$$y_{44}^T = 300{,}17206 y_{43}^T + 290{,}94528 y_{42}^T + ... + 95{,}96591 y_{20}^T$$

$$y_{45}^T = 99{,}11130 y_{44}^T + 98{,}52210 y_{43}^T + ... + 81{,}71865 y_{21}^T$$

$$y_{46}^T = 99{,}11130 y_{45}^T + 98{,}52210 y_{44}^T + ... + 81{,}71865 y_{22}^T$$

$$y_{47}^T = 99{,}11130 y_{46}^T + 98{,}52210 y_{45}^T + ... + 81{,}71865 y_{23}^T$$

Sementara itu, peramalan untuk komponen seasonality dihasilkan dengan metode SSA yang juga dituliskan secara matematis untuk data in-sample dan out-sample.

1. Untuk data *in-sample*

   Metode SSA menghasilkan *seasonality* yang direkontruksi, yaitu $y_0^S, y_1^S, ..., y_{24}^S$.

dimana $y_i^S = 0{,}004570y_{i-1}^S - 0{,}003865y_{i-2}^S + ... + 0{,}261105y_{i-24}^S$,

untuk $i$ = 25,26,...,35

2. Untuk data *out-sample*

SSA menghasilkan *seasonality* yang direkontruksi, yaitu $y_0^S, y_1^S, ..., y_{24}^S$.

$y_{36}^S = 0{,}004570y_{35}^S - 0{,}003865y_{34}^S + ... + 0{,}261105y_{12}^S$

$y_{37}^S = 0{,}004570y_{36}^S - 0{,}003865y_{35}^S + ... + 0{,}261105y_{13}^S$

$y_{38}^S = 0{,}004570y_{37}^S - 0{,}003865y_{36}^S + ... + 0{,}261105y_{14}^S$

$y_{39}^S = 0{,}004570y_{38}^S - 0{,}003865y_{37}^S + ... + 0{,}261105y_{15}^S$

$y_{40}^S = 0{,}004570y_{39}^S - 0{,}003865y_{38}^S + ... + 0{,}261105y_{16}^S$

$y_{41}^S = 0{,}004570y_{40}^S - 0{,}003865y_{39}^S + ... + 0{,}261105y_{17}^S$

$y_{42}^S = 0{,}004570y_{41}^S - 0{,}003865y_{40}^S + ... + 0{,}261105y_{18}^S$

$y_{43}^S = 0{,}004570y_{42}^S - 0{,}003865y_{41}^S + ... + 0{,}261105y_{19}^S$

$y_{44}^S = 0{,}004570y_{43}^S - 0{,}003865y_{42}^S + ... + 0{,}261105y_{20}^S$

$y_{45}^S = 0{,}004570y_{44}^S - 0{,}003865y_{43}^S + ... + 0{,}261105y_{21}^S$

$y_{46}^S = 0{,}004570y_{45}^S - 0{,}003865y_{44}^S + ... + 0{,}261105y_{22}^S$

$y_{47}^S = 0{,}004570y_{46}^S - 0{,}003865y_{45}^S + ... + 0{,}261105y_{23}^S$

Setelah mendapatkan hasil peramalan untuk masing-masing komponen, nilai ramalan total diperoleh dengan menjumlahkan nilai ramalan dari komponen trend dan seasonality. Model SSA secara keseluruhan memberikan nilai ramalan untuk seluruh data in-sample dan out-sample, dijelaskan dengan rumus matematis.

1. Data *in-sample*

$y_i = y_i^T + y_i^S$

Untuk $i$ = 0,1,2,...,35

2. Data *out-sample*

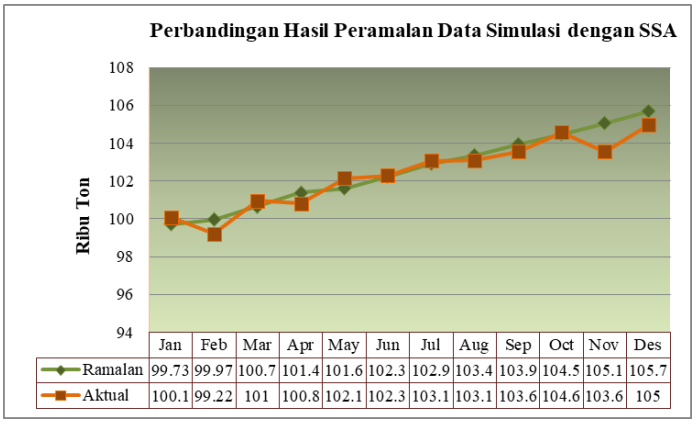
$y_i = y_i^T + y_i^S$

Untuk $i$ = 35,36,...,47

Hasil peramalan berulang SSA untuk data out-sample dari komponen trend dan seasonality ditampilkan untuk 12 bulan ke depan (Tabel 4) dan (Gambar 7).

**Tabel 4.** Hasil Peramalan Untuk Data *Out-Sample* Dengan Komponen *Trend* Dan *Seasonality*

| **Bulan** | ***Trend*** | ***Seasonality*** | **Ramalan** | **Aktual** |
|---|---|---|---|---|
| Januari | 48,16 | -31,53 | 99,73 | 100,09 |
| Februari | 48,39 | -39,92 | 99,97 | 99,22 |
| Maret | 48,64 | -28,46 | 100,67 | 100,95 |
| April | 48,88 | 33,52 | 101,38 | 100,82 |
| Mei | 49,12 | 43,35 | 101,61 | 102,14 |
| Juni | 49,36 | -8,54 | 102,25 | 102,29 |
| Juli | 49,59 | -22,38 | 102,92 | 103,06 |
| Agustus | 49,83 | -20,57 | 103,35 | 103,10 |
| September | 50,08 | -4,15 | 103,93 | 103,55 |
| Oktober | 50,32 | 54,23 | 104,47 | 104,58 |
| November | 50,54 | 49,38 | 105,05 | 103,55 |
| Desember | 50,77 | -19,89 | 105,68 | 104,95 |




**Gambar 7.** Plot Perbandingan Ramalan dan Aktual Data Simulasi

Berdasarkan gambar di atas, hasil peramalan data simulasi tampak mendekati nilai aktualnya. Proses trial dan error digunakan untuk mendapatkan data simulasi dengan window length (L) sebesar 25. Penentuan nilai window length (L) yang baik dilakukan dengan menghitung akurasi menggunakan Mean Absolute Percentage Error (MAPE), yang memberikan informasi persentase kesalahan hasil peramalan terhadap hasil aktual selama periode tertentu. Rumus matematis MAPE adalah:

$$MAPE = \sum_{t=1}^{12} \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \times 100\%$$

$$MAPE = \left( \left| \left( \frac{100{,}09 - 99{,}73}{100{,}09} \right) + \left( \frac{99{,}22 - 99{,}97}{99{,}22} \right) + .. + \left( \frac{104{,}95 - 105{,}68}{104{,}95} \right) \right| \right) \times 100\%$$

$$MAPE = 0{,}46\%$$

Dalam penelitian ini, dengan window length (L) sebesar 25, didapatkan nilai MAPE sebesar 0,46%, yang menunjukkan akurasi peramalan sangat baik karena nilai MAPE lebih kecil dari 10%. Semakin kecil nilai MAPE, semakin baik akurasi hasil peramalan.

**Peramalam Data Simulasi menggunakan Metode ARIMA**

Dalam penelitian ini, analisis time series menggunakan metode ARIMA dilakukan sebagai bahan perbandingan untuk mendapatkan metode terbaik. Proses identifikasi model ARIMA melibatkan empat tahap sesuai dengan Prosedur Box-Jenkins, yaitu identifikasi model, penaksiran parameter, pemeriksaan diagnostik, dan penerapan model untuk peramalan. Langkah pertama adalah pemeriksaan kestasioneran menggunakan Augmented Dickey-Fuller Test (Tabel 5). Hasilnya menunjukkan bahwa data tidak stasioner, dan untuk melanjutkan analisis, dilakukan differencing sebanyak dua kali hingga data menjadi stasioner (Tabel 6).

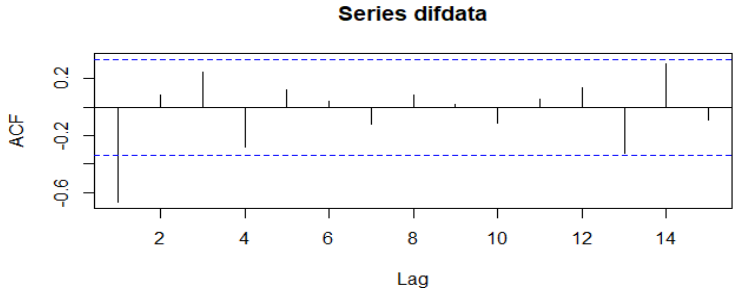
**Tabel 5.** *Dickey-Fuller Test*

| ***Dickey-Fuller*** | ***Lag Order*** | ***P-value*** |
|---|---|---|
| -2,6779 | 3 | 0,3094 |

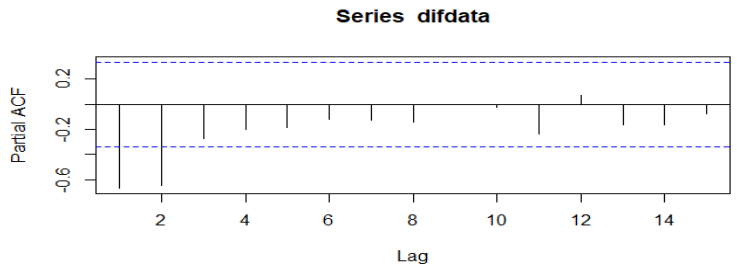
**Tabel 6.** *Dickey-Fuller Test Differencing*

| ***Dickey-Fuller*** | ***Lag Order*** | ***P-value*** |
|---|---|---|
| -4,4453 | 3 | 0,01 |

Setelah itu, proses identifikasi model ARIMA dilakukan dengan memeriksa lag-lag yang signifikan pada plot ACF (Autocorrelation Function) dan PACF (Partial Autocorrelation Function) (Gambar 8) dan (Gambar 9).




**Gambar 8.** Plot ACF




**Gambar 9.** Plot PCAF

Berdasarkan hasil plot ACF, lag yang signifikan adalah lag 1, dan dari plot PACF, lag yang signifikan adalah lag 1 dan lag 2. Dengan mempertimbangkan hasil identifikasi dari lag-lag tersebut, kandidat model ARIMA yang diidentifikasi adalah model ARIMA(0,2,1), ARIMA(1,2,1), dan ARIMA(1,2,2). Proses ini memberikan kerangka kerja yang sistematis untuk pemilihan model terbaik dalam analisis time series menggunakan metode ARIMA.

Setelah diperoleh model ARIMA terbaik, langkah selanjutnya adalah melakukan penaksiran parameter dari model untuk mendapatkan besaran koefisien model. Hasil estimasi parameter dari model ARIMA(0,2,1) dan ARIMA (1,2,1) dan ARIMA (1,2,2) pada data simulasi disajikan pada table 7 sebagai berikut.

**Tabel 7.** Hasil Estimasi Model ARIMA

| **Model ARIMA** | **Estimasi** | **Standar Eror** | **AIC** |
|---|---|---|---|
| ARIMA(0,2,1) | AR –1,000 | 0,0743 | 120,8 |
| ARIMA(1,2,1) | AR –1,9734 | 0,1156 | 103,79 |

| | | | |
|---|---|---|---|
| | MA –1,000 | 0,1122 | |
| ARIMA(1,2,2) | AR–0,4749<br>MA1 –0.9779<br>MA2 1,000 | 0,1484<br>0,1354<br>0,1356 | 86,4 |

Berdasarkan Tabel 7, nilai AIC terkecil terletak pada model ARIMA(1,2,2) sehingga model yang terbentuk selanjutnya digunakan model tersebut. Dalam melakukan pemeriksaan diagnostik pada model ARIMA(1,2,2), dua uji dilakukan, yaitu uji signifikansi parameter dan uji kesesuaian model. Uji kesesuaian model mencakup uji asumsi white noise dan uji asumsi normalitas, dengan taraf signifikansi $\alpha = 0,05$. Hasil uji signifikansi parameter menunjukkan bahwa semua parameter pada model ARIMA(1,2,2) signifikan secara statistik pada taraf signifikansi $\alpha = 0,05$, karena nilai p-value lebih kecil dari 0,05.

**Tabel 8.** Uji Asumsi *White Noise*

| **Model ARIMA** | **Lag** | ***Chi-Square*** | **Df** | ***P-value*** |
|---|---|---|---|---|
| ARIMA (1,2,2) | 3 | 3,8837 | 3 | 0,2743 |

Selanjutnya, asumsi white noise diuji dengan uji Chi-Square (Tabel 8). Nilai p-value untuk uji Chi-Square adalah 0,2743, yang lebih besar dari $\alpha$=0,05. Oleh karena itu, residual dari model ARIMA(1,2,2) memenuhi asumsi white noise. Pada langkah selanjutnya, uji asumsi normalitas pada residual dilakukan dengan uji Kolmogorov-Smirnov. Tidak disebutkan dalam teks, tetapi apabila p-value uji Kolmogorov-Smirnov lebih besar dari $\alpha$=0,05, maka residual tersebut dianggap berdistribusi normal. Untuk analisis tambahan, hasil peramalan model ARIMA(1,2,2) dapat ditampilkan dan diinterpretasikan dengan asumsi white noise dan normalitas terpenuhi (Tabel 9.).

**Tabel 9.** Hasil Peramalan menggunakan ARIMA untuk 12 bulan kedepan di tahun 2022

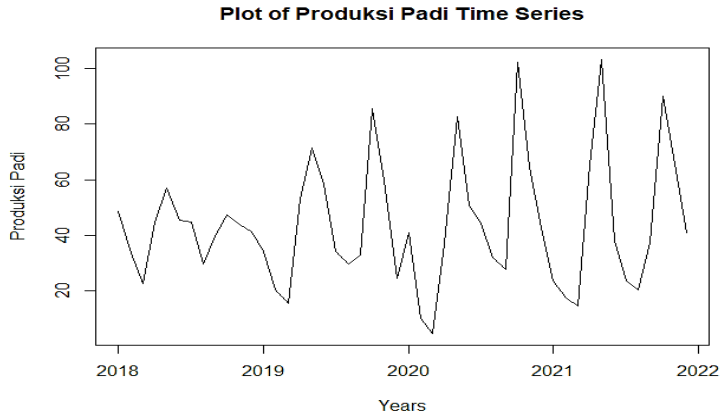
| **Bulan** | **Hasil Peramalan** |
|---|---|
| Januari | 0.744 |
| Februari | 0.506 |
| Maret | 0.648 |
| April | 0.609 |
| Mei | 0.657 |
| Juni | 0.663 |
| Juli | 0.689 |
| Agustus | 0.706 |
| September | 0.727 |
| Oktober | 0.746 |
| November | 0.766 |
| Desember | 0.785 |

Berdasarkan analisis perbandingan nilai MAPE antara metode SSA dan ARIMA pada peramalan data out-sample untuk jangka waktu 12 bulan ke depan, terlihat bahwa metode SSA menghasilkan nilai MAPE sebesar 0,46%, sementara ARIMA memiliki nilai MAPE sebesar 99,33%. Hasil ini menunjukkan bahwa metode SSA lebih akurat dalam meramalkan data simulasi dengan komponen trend dan seasonality dibandingkan dengan ARIMA. Dengan demikian, dapat disimpulkan bahwa metode peramalan terbaik adalah SSA, karena mampu menghasilkan nilai MAPE yang lebih kecil, sehingga memberikan hasil peramalan yang lebih mendekati data aktual. Dalam konteks produksi padi di Sulawesi Tenggara, padi merupakan sumber makanan utama dengan produksi yang terus meningkat dari tahun ke tahun, mencapai 540.3 ton pada tahun 2021. Rata-rata produksi padi dalam sebulan mencapai 45.2 ton pada tahun tersebut, menunjukkan kontribusi yang signifikan dalam pemenuhan kebutuhan pangan masyarakat di provinsi tersebut (Tabel 10).

**Tabel 10.** Statistik Deskriptif Produksi Padi

| Produksi Padi | Mean | Standar Deviasi | Maksimum | Minimum |
|---|---|---|---|---|
| 2018 | 41,59 | 21,86 | 56,92 | 22,73 |
| 2019 | 43,31 | 21,86 | 85,63 | 15,70 |
| 2020 | 44,95 | 27,80 | 102,19 | 4,57 |
| 2021 | 45,02 | 29,52 | 103,36 | 14,56 |

Menurut data produksi padi Provinsi Sulawesi Tenggara, tabel 10 menunjukkan produksi rata-rata sebesar 45,02 ton per bulan pada tahun 2021. Produksi tertinggi tercatat pada bulan Mei sebesar 103,36 ton, sementara produksi terendah tercatat pada bulan Maret sebesar 4,57 ton. Menariknya, pola ini konsisten setiap tahun sejak 2018, dengan produksi rendah selalu terjadi pada bulan Maret dan produksi tertinggi terjadi pada bulan Mei dan Oktober. Faktor musim panen, dengan bebera Namun, iklim, pertanian, dan bencana alam memengaruhi ketidakpastian musim ini, yang menyebabkan fluktuasi produksi yang berbeda setiap bulan dan setiap tahun. Untuk mendapatkan nilai MAPE yang paling baik, peramalan produksi padi menggunakan metode SSA melibatkan langkah-langkah seperti embedding dan tahap dekomposisi, yang dilakukan untuk memisahkan elemen suara, tren, dan musiman dari deret waktu. Window length (L) adalah 25. Tabel 10 menunjukkan data produksi padi di Provinsi Sulawesi Tenggara, yang menunjukkan bahwa produksi padi rata-rata mencapai 45,02 ton per bulan pada tahun 2021, dengan produksi tertinggi sebesar 103,36 ton pada bulan Mei dan produksi terendah sebesar 4,57 ton pada bulan Maret 2020. Menariknya, pola ini berulang setiap tahun sejak 2018, dengan produksi terendah selalu terjadi pada bulan Maret sementara produksi tertinggi terjadi pada bulan Mei dan Oktober. Faktor-faktor yang berkontribusi pada pola ini adalah Namun, iklim, pertanian, dan bencana alam memengaruhi ketidakpastian musim ini, yang menyebabkan fluktuasi produksi yang berbeda setiap bulan dan setiap tahun. Dalam peramalan produksi padi dengan metode SSA, 48 sampel data (n=48) dikumpulkan, dengan rentang waktu t=1,2,...,48. Data in-sample (36 sampel, t=1,2,...,36) dan out-sample (12 sampel, t=37,38,...,48). Gambar 10 menunjukkan plot waktu seri produksi padi di Provinsi Sulawesi Tenggara yang menunjukkan pola musiman dengan empat periode, yang menunjukkan pola pergerakan yang sama untuk setiap periode empat.




**Gambar 10.** Plot *Time Series* Produksi Padi

Metode SSA melibatkan dua tahap, yaitu dekomposisi dan rekonstruksi, untuk memisahkan komponen tren, musiman, dan noise dari deret waktu awal. Pada tahap dekomposisi, dilakukan embedding dengan deret waktu F=(48.78, 33.50, ..., 41.08) untuk t=1,2,...,48. Window length (L) yang diambil adalah 25, karena menghasilkan nilai MAPE yang lebih kecil dibandingkan dengan nilai L lainnya.

**Tabel 11.** Pemilihan *Window Length* model SSA

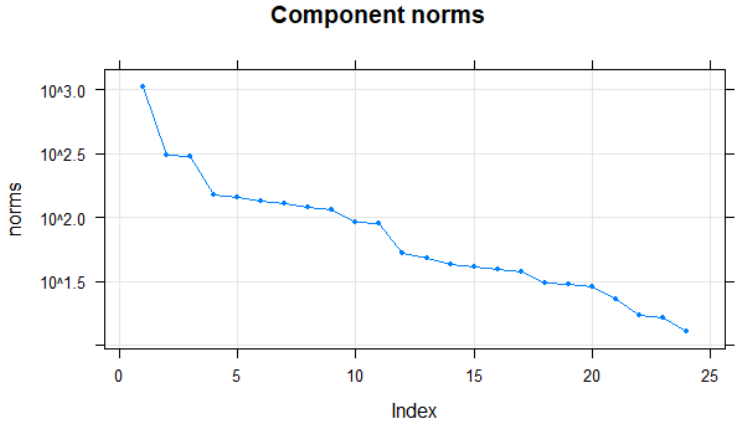
| *Window Length* | MAPE |
|---|---|
| 5 | 113,3472 |
| 10 | 77,12869 |
| 15 | 48,18374 |

| | |
|---|---|
| 17 | 43,90195 |
| 20 | 42,31 |
| 21 | 46,6433 |
| 23 | 32,65667 |
| 24 | 33,59982 |
| 25 | 23,67508 |
| 26 | 35,5172 |
| 30 | 69,54625 |

Dengan demikian matriks lintasan *X* yang dibangun dari deret F dapat digambarkan sebagai berikut:

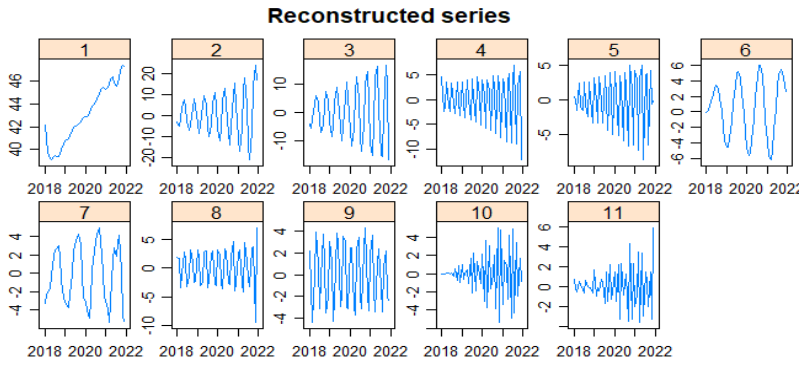
$$X = [X_1 : \ldots : X_{44}] = (x_{ij})_{i,j=1}^{25,48} = \begin{bmatrix} 48,78 & 33,50 & \cdots & 40,97 \\ 33,50 & 22,73 & \cdots & 24,64 \\ \vdots & \vdots & \ddots & \vdots \\ 24,64 & 40,97 & \cdots & 41,08 \end{bmatrix}$$

Dalam metode singular value decomposition (SVD) untuk mendekomposisi data, langkah awalnya terletak pada transformasi matriks lintasan X menjadi 24 eigentriple. Eigentriple ini mencakup 24 nilai eigen, 24 vektor eigen, dan 0 vektor faktor. Proses berikutnya terjadi pada tahap rekonstruksi, di mana komponen tren, musiman, dan noise diperoleh melalui pengelompokan dan averaging diagonal. Pengelompokan komponen noise melibatkan langkah pengelompokan eigentriple yang terkait dengan tren, musiman, dan noise. Parameter kritis dalam proses ini adalah effect grouping (r), yang membatasi jumlah eigentriple yang digunakan untuk mengidentifikasi komponen tren dan musiman. Nilai parameter effect grouping (r) ditentukan berdasarkan analisis plot nilai singular, di mana urutan nilai singular yang menurun lambat mencerminkan komponen noise. Untuk memberikan gambaran, dapat dilihat pada Gambar 11 plot singular dari data Produksi Padi di Provinsi Sulawesi Tenggara.




**Gambar 11.** Plot Singular Produksi Padi

Nilai singular menunjukkan penurunan yang lambat pada eigentriple ke-12 hingga eigentriple ke-24, yang menunjukkan bahwa eigentriple ke-12 hingga eigentriple ke-24 dapat dianggap sebagai komponen noise. Jumlah eigentriple yang tidak mencerminkan noise pada plot nilai singular adalah 11, tetapi eigentriple yang mencerminkan noise adalah 11. Eigentriple yang tidak terkait dengan tren dan musiman dari sebelas eigentriple tersebut kemudian dikelompokkan sebagai komponen noise. Eigentriple yang terkait dengan tren dan musiman juga dikelompokkan. Eigentriple 1–11, total sebelas eigentriple, digunakan untuk menentukan komponen tren dan musiman. Gambar 12 menunjukkan plot deret yang direkonstruksi yang mendukung proses ini.



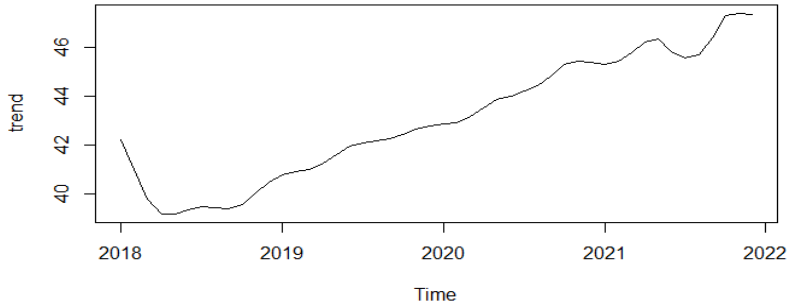

**Gambar 12.** Plot Deret Rekontruksi Produksi Padi

Dalam menganalisis deret waktu, kita mengenal tren sebagai elemen yang secara perlahan berubah tanpa adanya osilasi. Komponen yang mengalami fluktuasi perlahan selama pembangunan kembali deret disebut sebagai tren. Sebagai contoh, Eigentriple 1 dianggap sebagai tren karena menghasilkan deret dengan fluktuasi perlahan, seperti yang dapat kita lihat dalam Gambar 12. Hasil penelitian oleh Andhika dkk. (2020) menunjukkan bahwa eigentriple yang terkait dengan faktor musiman dapat dikelompokkan berdasarkan kesamaan nilai singular dari dua eigentriple yang berurutan. Dalam dua deret yang direkonstruksi oleh eigentriple tersebut, pola musiman dengan periode yang sama dapat terlihat. Sebagai contoh, dalam Gambar 12, kita melihat bahwa Eigentriple 2 dan 3 dikelompokkan sebagai musiman dengan periode 6 bulan. Hal yang serupa terjadi pada Eigentriple 4 dan 5 dengan periode 3 bulan, serta Eigentriple 6 dan 7 dengan periode 12 bulan. Metode ESPRIT digunakan untuk menemukan periode musiman dari deret yang direkonstruksi oleh eigentriple yang memiliki nilai singular yang serupa. Hasil analisis ini kemudian disajikan dalam Tabel 12, menunjukkan eigentriple yang tergolong dalam kategori musiman.

**Tabel 12.** Komponen yang Berhubungan dengan *Seasonality*

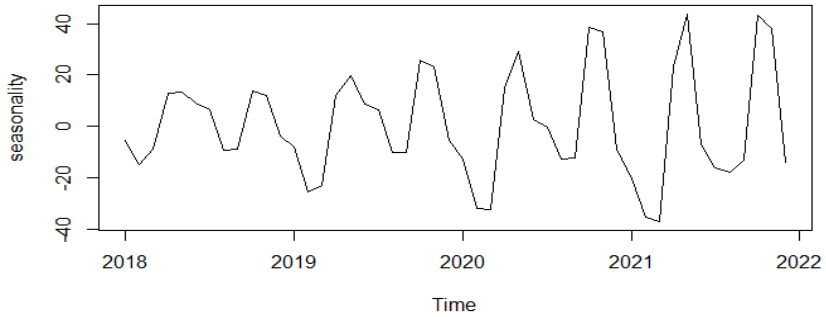
| ***Eigentriple*** | **Bulan** |
|---|---|
| 2 | 6 |
| 3 | 6 |
| 4 | 3 |
| 5 | 3 |
| 6 | 12 |
| 7 | 12 |

Dalam analisis eigentriple, sisa eigentriple dari empat eigentriple sebelumnya yang tidak termasuk dalam kelompok trend dan seasonality akan dimasukkan ke dalam kelompok komponen noise. Hal ini juga berlaku untuk sisa eigentriple dari sebelas eigentriple pada plot sebelumnya, eigentriple 8, 9, 10, dan 11. Eigentriple 2, 3, 4, 5, 6, dan 7 membentuk seasonality; eigentriple 1 menunjukkan trend; dan eigentriple 8 hingga 24 termasuk dalam komponen noise. Diagonal averaging adalah tahap terakhir dalam rekonstruksi, di mana setiap komponen direkonstruksi menggunakan eigentriple terkait. Dalam hal ini, eigentriple 1 merekonstruksi komponen trend karena hanya eigentriple ini yang menunjukkan pola lambat dan tidak serupa dengan eigentriple lainnya. Gambar 13 menunjukkan hasil rekonstruksi komponen trend.



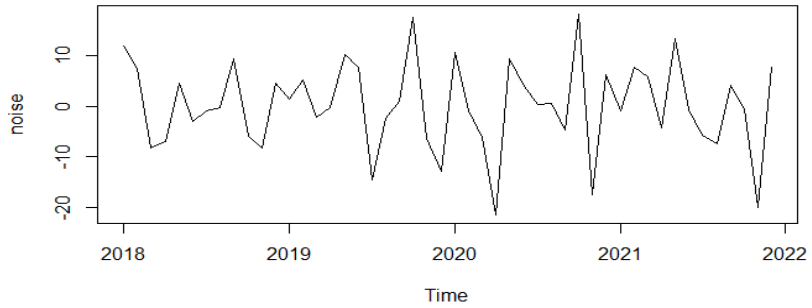

**Gambar 13.** Plot *Trend* Rekontruksi

Pada langkah *diagonal averaging*, komponen *seasonality* direkonstruksi oleh eigentriple 2 dan 3, eigentriple 4, dan 5 serta *eigentriple* 6 dan 7. Berikut Gambar 14 menampilkan hasil dari komponen *seasonality* yang direkonstruksi oleh keempat *eigentriple* tersebut.




**Gambar 14.** Plot *Seasonality* Rekontruksi

Selanjutnya, komponen *noise* direkonstruksi oleh *eigentriple* 7, *eigentriple* 8, .., *eigentriple* 23 dan *eigentriple* 24. Berikut Gambar 15 yang menampilkan hasil dari komponen *noise* yang direkonstruksi.




**Gambar 15.** Plot *Noise* Rekontruksi

Dalam proses peramalan, setelah berhasil memisahkan komponen trend, seasonality, dan noise, langkah selanjutnya adalah melakukan peramalan terhadap masing-masing komponen tersebut. Metode peramalan yang digunakan adalah peramalan berulang SSA. Model SSA digunakan untuk meramalkan komponen trend dan seasonality secara matematis. Untuk komponen trend, nilai ramalan dihasilkan dengan menggunakan rumus tertentu, baik untuk data in-sample maupun data out-sample.

1. Untuk data *in-sample*

   Metode SSA menghasilkan *trend* yang direkontruksi, yaitu $y_0^T, y_1^T, ..., y_{24}^T$.

   dimana $y_i^T = 24{,}09862 y_{i-1}^T + 52{,}301556 y_{i-2}^T + ... + 46{,}17306 y_{i-24}^T$,

   untuk $i = 25,26,...,35$

2. Untuk data *out-sample*

   Metode SSA menghasilkan *trend* yang direkontruksi, yaitu $y_0^T, y_1^T, ..., y_{24}^T$.

$$y_{36}^T = 24{,}09862 y_{35}^T + 52{,}301556 y_{34}^T + ... + 46{,}17306 y_{12}^T$$
$$y_{37}^T = 24{,}09862 y_{36}^T + 52{,}301556 y_{35}^T + ... + 46{,}17306 y_{13}^T$$
$$y_{38}^T = 24{,}09862 y_{37}^T + 52{,}301556 y_{36}^T + ... + 46{,}17306 y_{14}^T$$
$$y_{39}^T = 24{,}09862 y_{38}^T + 52{,}301556 y_{37}^T + ... + 46{,}17306 y_{15}^T$$
$$y_{40}^T = 24{,}09862 y_{39}^T + 52{,}301556 y_{38}^T + ... + 46{,}17306 y_{16}^T$$
$$y_{41}^T = 24{,}09862 y_{40}^T + 52{,}301556 y_{39}^T + ... + 46{,}17306 y_{17}^T$$
$$y_{42}^T = 24{,}09862 y_{41}^T + 52{,}301556 y_{40}^T + ... + 46{,}17306 y_{18}^T$$
$$y_{43}^T = 24{,}09862 y_{42}^T + 52{,}301556 y_{41}^T + ... + 46{,}17306 y_{19}^T$$
$$y_{44}^T = 24{,}09862 y_{43}^T + 52{,}301556 y_{42}^T + ... + 46{,}17306 y_{20}^T$$

$$y_{45}^T = 24{,}09862y_{44}^T + 52{,}301556y_{43}^T + ... + 46{,}17306y_{21}^T$$
$$y_{46}^T = 24{,}09862y_{45}^T + 52{,}301556y_{44}^T + ... + 46{,}17306y_{22}^T$$
$$y_{47}^T = 24{,}09862y_{46}^T + 52{,}301556y_{45}^T + ... + 46{,}17306y_{23}^T$$

Begitu pula untuk komponen seasonality, di mana nilai ramalan dihasilkan menggunakan metode SSA.

$$Y_i^S = [\hat{y}_{i-L+1},..., \hat{y}_{i-1}]^S$$

1. Untuk data *in-sample*

Metode SSA menghasilkan *seasonality* yang direkontruksi, yaitu $y_0^S, y_1^S, ..., y_{24}^S$.

dimana $y_i^S = 5{,}813365y_{i-1}^S + 31{,}176207y_{i-2}^S + ... - 2{,}615654y_{i-24}^S$,

untuk $i$ = 25,26,...,35

2. Untuk data *out-sample*

SSA menghasilkan *seasonality* yang direkontruksi, yaitu $y_0^S, y_1^S, ..., y_{24}^S$.

$$y_{36}^S = 5{,}813365y_{35}^S + 31{,}176207y_{34}^S + ... - 2{,}615654y_{12}^S$$
$$y_{37}^S = 5{,}813365y_{36}^S + 31{,}176207y_{35}^S + ... - 2{,}615654y_{13}^S$$
$$y_{38}^S = 5{,}813365y_{37}^S + 31{,}176207y_{36}^S + ... - 2{,}615654y_{14}^S$$
$$y_{39}^S = 5{,}813365y_{38}^S + 31{,}176207y_{37}^S + ... - 2{,}615654y_{15}^S$$
$$y_{40}^S = 5{,}813365y_{39}^S + 31{,}176207y_{38}^S + ... - 2{,}615654y_{16}^S$$
$$y_{41}^S = 5{,}813365y_{40}^S + 31{,}176207y_{39}^S + ... - 2{,}615654y_{17}^S$$
$$y_{42}^S = 5{,}813365y_{41}^S + 31{,}176207y_{40}^S + ... - 2{,}615654y_{18}^S$$
$$y_{43}^S = 5{,}813365y_{42}^S + 31{,}176207y_{41}^S + ... - 2{,}615654y_{19}^S$$
$$y_{44}^S = 5{,}813365y_{43}^S + 31{,}176207y_{42}^S + ... - 2{,}615654y_{20}^S$$
$$y_{45}^S = 5{,}813365y_{44}^S + 31{,}176207y_{43}^S + ... - 2{,}615654y_{21}^S$$
$$y_{46}^S = 5{,}813365y_{45}^S + 31{,}176207y_{44}^S + ... - 2{,}615654y_{22}^S$$
$$y_{47}^S = 5{,}813365y_{46}^S + 31{,}176207y_{45}^S + ... - 2{,}615654y_{23}^S$$

Setelah mendapatkan hasil peramalan masing-masing komponen, nilai ramalan untuk seluruh data in-sample dan out-sample diperoleh dengan menjumlahkan nilai ramalan dari komponen *trend* dan *seasonality*.

1. Data *in-sample*

$$y_i = y_i^T + y_i^S$$

Untuk $i$ = 0,1,2,...,35

2. Data *out-sample*

$$y_i = y_i^T + y_i^S$$

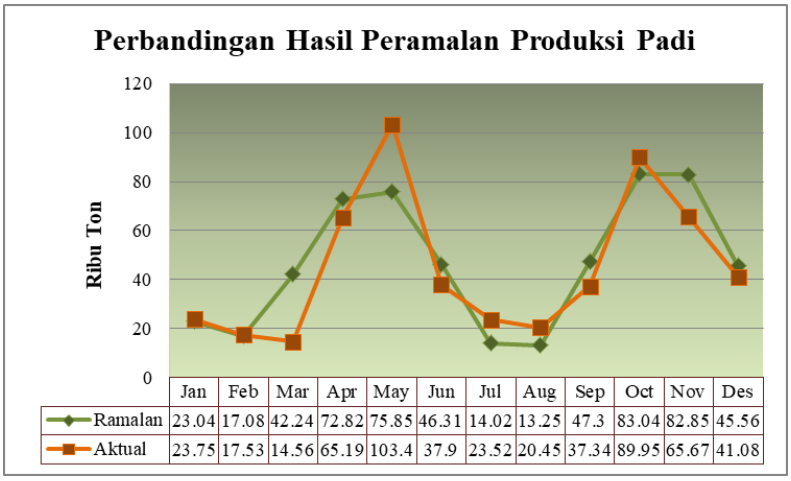
Untuk $i$ = 35,36,...,47

Model SSA secara keseluruhan dapat digambarkan secara matematis untuk kedua jenis data tersebut. Hasil peramalan berulang SSA untuk data out-sample dari kedua komponen tersebut ditampilkan untuk 12 bulan ke depan (Tabel 13) dan (Gambar 16).

**Tabel 13.** Hasil Peramalan untuk data *Out-sample* dengan komponen *trend* dan *seasonality*

| Bulan | *Trend* | *Seasonality* | *Out-sample* | Aktual |
|---|---|---|---|---|
| Januari | 37,27 | -11,96 | 23.04 | 23.75 |
| Februari | 35,10 | -23,93 | 17.08 | 17.53 |
| Maret | 34,46 | -13,89 | 42.24 | 14.56 |

| | | | | |
|---|---|---|---|---|
| April | 36,92 | 11,60 | 72.82 | 65.19 |
| Mei | 41,00 | 25,85 | 75.85 | 103.36 |
| Juni | 45,19 | 11,92 | 46.31 | 37.9 |
| Juli | 49,62 | -15,27 | 14.02 | 23.52 |
| Agustus | 52,30 | -29,71 | 13.25 | 20.45 |
| September | 53,99 | -13,19 | 47.3 | 37.34 |
| Oktober | 56,69 | 23,46 | 83.04 | 89.95 |
| November | 54,35 | 30,17 | 82.85 | 65.67 |
| Desember | 49,68 | 1,61 | 45.56 | 41.08 |




**Gambar 16**. Plot Perbandingan Ramalan SSA dan Aktual Produksi Padi

Berdasarkan gambar 16, hasil peramalan produksi padi menunjukkan ketepatan yang mendekati nilai aktual. Untuk menentukan nilai window length (L), digunakan Mean Absolute Percentage Error (MAPE) sebagai metrik akurasi, dengan hasil perhitungan MAPE sebesar 23,68% untuk window length (L) sebesar 25 pada produksi padi di Provinsi Sulawesi Tenggara.

$$MAPE = \sum_{t=1}^{12} \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \times 100\%$$

$$MAPE = \left( \left| \left( \frac{23{,}75 - 23{,}04}{23{,}75} \right) + \left( \frac{17{,}53 - 17{,}08}{17{,}53} \right) + .. + \left( \frac{41{,}08 - 45{,}56}{41{,}08} \right) \right| \right) \times 100\%$$

$$MAPE = 23{,}68\%$$

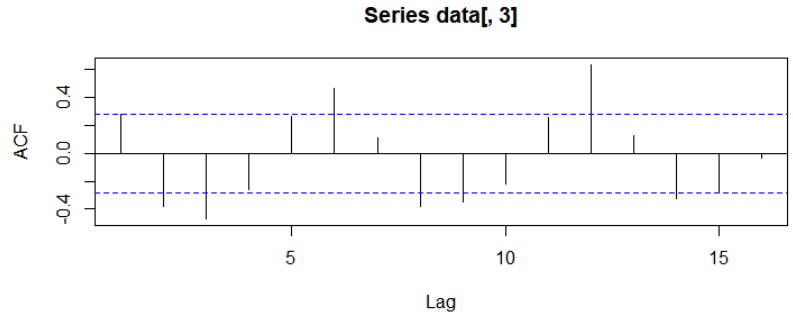
Dengan demikian, metode peramalan menggunakan Singular Spectrum Analysis (SSA) dengan L=25 dapat dianggap efektif dalam meramalkan produksi padi. Selanjutnya, Aizzah et al., (2022) menyatakan, pada proses peramalan menggunakan metode ARIMA, prosedur Box-Jenkins melibatkan empat tahap: identifikasi model, penaksiran parameter, pemeriksaan diagnostik, dan penerapan model untuk peramalan. Tahap identifikasi model dimulai dengan pemeriksaan kestasioneran dalam varian dan rata-rata, menggunakan *Augmented Dickey-Fuller Test* untuk menentukan stasioneritas data (Tabel 14.).

**Tabel 14.** *Dickey-Fuller Test*

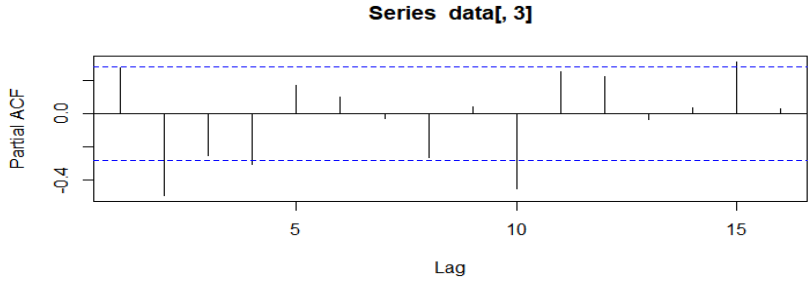
| ***Dickey-Fuller*** | ***Lag Order*** | ***P-value*** |
|---|---|---|
| -6.3979 | 3 | 0,01 |

Berdasarkan tabel diatas, dapat diketahui bahwa nilai *p-value* lebih kecil dari 0,05 sehingga dalah pengambilan keputusan, data dapat dikatakan stasioner. Setelah data sudah stasioner baik dalam variansi maupun dalam rata-rata,

langkah selanjutnya adalah menentukan model ARIMA sementara berdasarkan lag-lag yang signifikan pada plot ACF (Gambar 17) dan PACF (Gambar 18).




**Gambar 17.** Plot ACF




**Gambar 18.** Plot PCAF

Dilihat dari analisis diagram ACF dan PACF pada Gambar 17 dan Gambar 18, tampak bahwa ada lag-lag yang signifikan yang dapat memengaruhi pemodelan ARIMA. Lag 2, 3, 6, 8, 9, 12, dan 14 pada diagram ACF menunjukkan hubungan signifikan, dan lag 2, 3, 10, dan 15 pada diagram PACF juga menunjukkan lag signifikan. Hasil identifikasi ini mendorong pemilihan model ARIMA yang tepat. Oleh karena itu, kandidat model yang muncul adalah ARIMA (2,0,0), ARIMA (0,0,2), dan ARIMA (2,0,1). Setelah memperoleh model ARIMA terbaik, langkah berikutnya adalah penaksiran parameter model untuk mendapatkan koefisiennya. Dalam kasus produksi padi disaj, estimasi parameter model adalah ARIMA (2,0,0), ARIMA (0,0,2), dan ARIMA (2,0,1).

**Tabel 15.** Hasil Estimasi Model ARIMA

| Model ARIMA | Estimasi | Standar Eror | AIC |
|---|---|---|---|
| ARIMA(2,0,0) | 0,4121 | 0,1245 | 424,09 |
| ARIMA(0,0,2) | 0,1636 | 0,1402 | 423,44 |
| ARIMA(2,0,1) | 0,8168 | 0,1600 | 419,93 |

Berdasarkan Tabel 15, model ARIMA(2,0,1) menunjukkan nilai AIC terkecil, sehingga dipilih sebagai model yang paling sesuai. Pada tahap Pemeriksaan Diagnostik, dilakukan dua uji penting, yaitu uji signifikansi parameter dan uji kesesuaian model. Uji kesesuaian model mencakup uji asumsi white noise dan uji asumsi normalitas (Ikram et al., 2022). Dengan menggunakan taraf signifikansi α=0,05, hasil menunjukkan bahwa semua parameter pada model ARIMA(2,0,1) signifikan secara statistik. Selanjutnya, dilakukan uji asumsi white noise menggunakan uji Chi-Square untuk memastikan bahwa residual dari model ARIMA(2,0,1) memenuhi asumsi *white noise* (Tabel 16). Sementara itu, uji Kolmogorov-Smirnov digunakan untuk mengevaluasi apakah residual dari model tersebut berdistribusi normal. Hasil pengujian ini mendukung kevalidan model ARIMA(2,0,1) dalam menganalisis data dengan tingkat signifikansi yang telah ditetapkan.

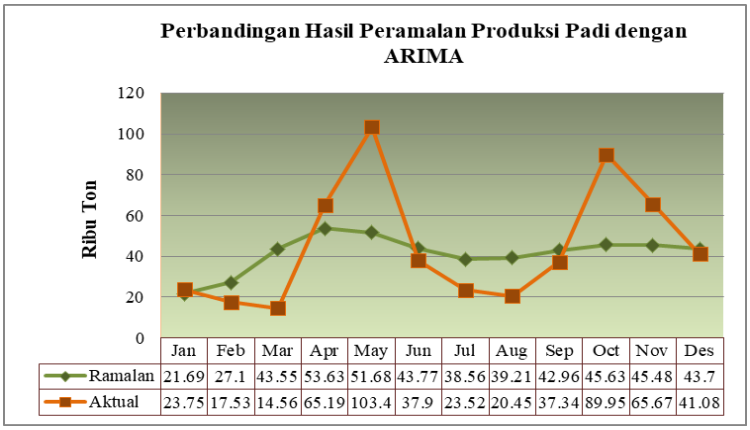
**Tabel 16.** Uji Asumsi *White Noise*

| Model ARIMA | Lag | *Chi-Square* | Df | *P-value* |
|---|---|---|---|---|
| ARIMA(2,0,1) | 3 | 0.87952 | 3 | 0,8304 |

Berdasarkan Tabel 16, diketahui bahwa residual dari model ARIMA (2,0,1) sudah memenuhi asumsi *white noise* karena nilai *p-value* pada uji Chi-Square lebih besar dari α = 0,05. Karena asumsi telah terpenuhi, maka selanjutnya ditampilkan hasil peramalan untu model ARIMA(2,0,1) pada table 17 dan gambar 19 berikut.

**Tabel 17.** Hasil Peramalan untuk Tahun 2022

| Bulan | Ramalan | Aktual |
|---|---|---|
| Januari | 21,69 | 23.75 |
| Februari | 27,10 | 17.53 |
| Maret | 43,55 | 14.56 |
| April | 53,63 | 65.19 |
| Mei | 51,68 | 103.36 |
| Juni | 43,77 | 37.9 |
| Juli | 38,56 | 23.52 |
| Agustus | 39,21 | 20.45 |
| September | 42,96 | 37.34 |
| Oktober | 45,63 | 89.95 |
| November | 45,48 | 65.67 |
| Desember | 43,70 | 41.08 |




**Gambar 19.** Plot Perbandingan Ramalan ARIMA dan Aktual Produksi Padi

Pada perbandingan hasil ramalan produksi padi di Provinsi Sulawesi Tenggara, metode terbaik dinilai berdasarkan nilai Mean Absolute Percentage Error (MAPE), yang mencerminkan akurasi peramalan. Dalam penelitian ini, dua metode peramalan, yaitu Singular Spectrum Analysis (SSA) dan model Autoregressive Integrated Moving Average (ARIMA) dengan parameter (2,0,1), dievaluasi untuk jangka waktu 12 bulan ke depan. Hasil menunjukkan bahwa nilai MAPE yang dihasilkan oleh metode SSA sebesar 23,68%, sementara metode ARIMA mencapai 48,16%. Dengan nilai MAPE yang lebih rendah, SSA dinilai sebagai metode yang lebih akurat dalam meramalkan produksi padi di Provinsi Sulawesi Tenggara. Dengan demikian, SSA dapat diandalkan untuk peramalan jumlah produksi padi dengan jangka waktu 12 bulan ke depan, karena hasil ramalannya lebih mendekati data aktual dibandingkan dengan metode ARIMA.

## SIMPULAN

Berdasarkan hasil penelitian yang telah diuraikan, dapat disimpulkan bahwa penggunaan Model Singular Spectrum Analysis (SSA) berhasil meramalkan produksi padi di Provinsi Sulawesi Tenggara untuk periode dua belas bulan ke depan.

Model *Singular Spectrum Analysis* (SSA) yang digunakan untuk meramalkan produksi padi di Provinsi Sulawesi Tenggara dua belas bulan ke depan yaitu $y_i = y_i^T + y_i^S$, dengan model SSA bagi komponen *trend* adalah sebagai berikut:

$$y_i^T = 24{,}09862\,y_{i-1}^T + 52{,}301556\,y_{i-2}^T + \ldots + 46{,}17306\,y_{i-24}^T$$

dan model SSA bagi komponen *seasonality* adalah sebagai berikut:

$$y_i^S = 5{,}813365\,y_{i-1}^S + 31{,}176207\,y_{i-2}^S + \ldots - 2{,}615654\,y_{i-24}^S$$

Model SSA yang menggambarkan komponen trend dan seasonality dengan nilai window length L=25 menunjukkan kinerja terbaik dengan tingkat Mean Absolute Percentage Error (MAPE) sebesar 23,68%. Hasil perbandingan dengan metode ARIMA menegaskan bahwa SSA memberikan hasil peramalan yang lebih akurat, dengan MAPE sebesar 48,16% pada metode ARIMA. Dengan demikian, SSA merupakan pilihan yang lebih sesuai dan dapat diandalkan untuk meramalkan produksi padi di wilayah tersebut. Berdasarkan kesimpulan tersebut, saran yang dapat diberikan adalah mengadopsi metode SSA untuk peramalan data deret waktu yang memiliki komponen musiman yang kompleks. Semakin kompleks komponen musiman dari data, semakin tinggi tingkat akurasi peramalan yang dapat dicapai oleh Metode SSA. Penelitian mendukung pengembangan lebih lanjut dalam proses pemilihan dan pemisahan komponen trend dan seasonality, dengan mempertimbangkan penerapan teknik seperti periodogram atau scatterplot. Hal ini diharapkan dapat memperbaiki dan mengoptimalkan proses peramalan produksi padi di Provinsi Sulawesi Tenggara serta memberikan kontribusi positif terhadap penelitian selanjutnya dalam bidang ini.

## DAFTAR PUSTAKA


Ahmad, F. (2020). Penentuan Metode Peramalan Pada Produksi Part New Granada Bowl St Di Pt.X. *JISI: Jurnal Integrasi Sistem Industri*, *7*(1), 31. https://doi.org/10.24853/jisi.7.1.31-39

Aizzah, Z., Intan, P. K., & Utami, W. D. (2022). Prediksi Jumlah Gempa Tektonik di Wilayah Jawa Timur dengan Menggunakan Metode ARIMA Box Jenkins dan Kalman Filter. *JRST (Jurnal Riset Sains Dan Teknologi)*, *5*(2), 111. https://doi.org/10.30595/jrst.v5i2.9701

Amalia, I. R. (2022). Penerapan Metode Singular Spectrum Analysis dalam Peramalan Jumlah Produksi Beras di Kabupaten Gowa. *VARIANSI: Journal of Statistics and Its Application on Teaching and Research*, *4*(2), 49–58. https://doi.org/10.35580/variansiunm40

Andhika, G. B., Sumarjaya, I. W., & Srinadi, I. G. A. M. (2020). Peramalan Nilai Tukar Petani Menggunakan Metode Singular Spectrum Analysis. *E-Jurnal Matematika*, *9*(3), 171. https://doi.org/10.24843/mtk.2020.v09.i03.p295

Ariska, F. M., & Bagus, Q. (2021). Perkembangan Impor Bekas di Indonesia. *Jurnal Agrimals*, *1*(1), 27–34. https://doi.org/10.25140/2411-5363-2021-2(24)-235-243

Arsani, A. M. (2020). the Future of Indonesia and Global Agriculture: Rice Consumption and Agricultural Modernization. *Jurnal Litbang Sukowati : Media Penelitian Dan Pengembangan*, *4*(1), 8. https://doi.org/10.32630/sukowati.v4i1.132

Garini, F. C., & Anbiya, W. (2022). Application of GARCH Forecasting Method in Predicting The Number of Rail Passengers (Thousands of People) in Jabodetabek Region. *Jurnal Matematika, Statistika Dan Komputasi*, *18*(2), 198–223. https://doi.org/10.20956/j.v18i2.18382

Habsari, H. D. P., Purnamasari, I., & Yuniarti, D. (2020). Peramalan Menggunakan Metode Double Exponential Smoothing Dan Verifikasi Hasil Peramalan Menggunakan Grafik Pengendali Tracking Signal. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, *14*(1), 013–022.

Harsyiah, L., Fitriyani, N., & Salwa, S. (2020). Peramalan Jumlah Siswa Baru Madrasah Aliyah (MA) Manhalul Ma'arif Darek-Lombok Tengah. *Eigen Mathematics Journal*, *3*(2), 110–117. https://doi.org/10.29303/emj.v3i2.88

Ikram, A. S. M., Makkulau, M., Abapihi, B., Ruslan, R., & Baharuddin, B. (2022). Analisis Intervensi Fungsi Step Pada Peramalan Jumlah Kunjungan Wisatawan. *Jurnal Matematika Komputasi Dan Statistika*, *2*(3), 181–186. https://doi.org/10.33772/jmks.v2i3.24

Kontopoulou, V. I., Panagopoulos, A. D., Kakkos, I., & Matsopoulos, G. K. (2023). A Review of ARIMA vs. Machine Learning Approaches for Time Series Forecasting in Data Driven Networks. *Future Internet*, *15*(8), 1–31. https://doi.org/10.3390/fi15080255

Marjuni, A. (2022). Peramalan Harga Saham Serentak Menggunakan Model Multivariate Singular Spectrum Analysis. *Jurnal Sistem Informasi Bisnis*, *12*(1), 17–25. https://doi.org/10.21456/vol12iss1pp17-25

Neog, B., Gogoi, B., & Patowary, A. N. (2022). Development of Hybrid Time Series Models for Forecasting Autumn Rice Using Arimax- Ann and Arimax-Svm. *Annals of Forest Research*, *65*(1), 9119–9133.

Pradana, M. S., Rahmalia, D., & Prahastini, E. D. A. (2020). Peramalan Nilai Tukar Petani Kabupaten Lamongan dengan Arima. *Jurnal Matematika*, *10*(2), 91. https://doi.org/10.24843/jmat.2020.v10.i02.p126

Purnama, J., & Juliana, A. (2020). Analisa Prediksi Indeks Harga Saham Gabungan Menggunakan Metode Arima. *Cakrawala Management Business Journal*, *2*(2), 454. https://doi.org/10.30862/cm-bj.v2i2.51

Qadrini, L., Asrirawan, A., Mahmudah, N., Fahmuddin, M., & Amri, I. F. (2020). Forecasting Bank Indonesia Currency Inflow and Outflow Using ARIMA, Time Series Regression (TSR), ARIMAX, and NN Approaches in Lampung. *Jurnal Matematika, Statistika Dan Komputasi*, *17*(2), 166–177. https://doi.org/10.20956/jmsk.v17i2.11803

Rahmad, C., Wibowo, R. S., & Puspitasari, D. (2019). Peramalan Penjualan Daging Sapi Menggunakan Metode Trend Least Square. *Jurnal Teknologi Informasi Dan Terapan*, *6*(1), 7–11. https://doi.org/10.25047/jtit.v6i1.104

Salsabilla, S., Deksino, G. R., & Dewi, D. T. T. (2022). Pengelolaan Sumber Daya Air Dan Food Estate Sebagai Faktor Pendukung Penyediaan Logistik Wilayah Untuk Pertahanan Negara. *Jurnal Kewarganegaraan*, *6*(2), 2436–2444. http://journal.upy.ac.id/index.php/pkn/article/view/3021

Sari, M. A. N., Sumarjaya, I. W., & Susilawati, M. (2019). Peramalan Jumlah Kunjungan Wisatawan Mancanegara Ke Bali Menggunakan Metode Singular Spectrum Analysis. *E-Jurnal Matematika*, *8*(4), 303. https://doi.org/10.24843/mtk.2019.v08.i04.p269

Sarwo, & Hermawan. (2019). Prediksi Penerimaan Siswa Baru Pada Madrasah Aliyah Assayafi'Iyah 02 Menggunakan Metode Time Series. *Petir: Jurnal Pengkajian Dan Penerapan Teknik Informatika*, *9*(2), 151–156. https://doi.org/10.33322/petir.v9i2.182

Susila, M. R., Jamil, M., & Santoso, B. H. (2023). Akurasi Model Hybrid ARIMA-Artificial Neural Network dengan Model Non Hybrid pada Peramalan Peredaran Uang Elektronik di Indonesia. *Jambura Journal of Mathematics*, *5*(1), 46–58. https://doi.org/10.34312/jjom.v5i1.14889