

PENGGUNAAN METODE SINGULAR SPECTRUM ANALYSIS DALAM MERAMALKAN HASIL PRODUKSI IKAN CAKALANG DI PROVINSI SULAWESI TENGGARA

USE OF THE SINGULAR SPECTRUM ANALYSIS METHOD IN FORECASTING THE RESULTS OF CAKALANG FISH PRODUCTION IN SOUTHEAST SULAWESI PROVINCE

Intan Faradila Sucahyo
Universitas Halu Oleo, *E-mail*: intanfrdlschy27@gmail.com

ABSTRAK

Tujuan penelitian ini adalah untuk mengetahui hasil peramalan produksi ikan cakalang di Provinsi Sulawesi Tenggara dengan Metode *Singular Spectrum Analysis* (SSA) dan mengetahui akurasi hasil peramalan produksi ikan cakalang di Provinsi Sulawesi Tenggara dengan metode SSA. Penelitian ini menggunakan data bulanan hasil produksi ikan cakalang di Provinsi Sulawesi Tenggara dari bulan Januari 2019 sampai bulan Desember 2022 yang bersumber dari Dinas Kelautan dan perikanan Sulawesi Tenggara. Selanjutnya dilakukan peramalan untuk memprediksi hasil produksi ikan cakalang di Provinsi Sulawesi Tenggara pada tahun 2023. Model SSA terbaik pada penelitian ini dengan nilai $L=10$ serta nilai MAPE sebesar 12,73 %. Hal ini menunjukkan bahwa metode SSA dapat meramalkan produksi ikan cakalang di Provinsi Sulawesi Tenggara dengan akurat dan masuk dalam kategori baik.

Kata Kunci : *Singular Spectrum Analysis, Trend, Seasonality, Noise, Ikan Cakalang*

ABSTRACT

The aim of this research is to determine the results of forecasting skipjack tuna production in Southeast Sulawesi Province using the singular spectrum analysis (SSA) method and to determine the accuracy of forecasting results for skipjack tuna production in Southeast Sulawesi Province using the SSA method. This research uses data month on the production of skipjack fish in Southeast Sulawesi Province. from January 2019 to December 2022 sourced from the Southeast Sulawesi Maritime Affairs and Fisheries Service. Next, forecasting is carried out to predict the production results of skipjack in Southeast Sulawesi Province in 2023. The SSA model is the best in this study with a of $L=10$ and a MAPE value of 12.73%. This shows that the SSA method can predict skipjack tuna production in Southeast Sulawesi Province accurately and is in the good category.

Keywords : *Singular Spectrum Analysis, Trend, Seasonality, Noise, Skipjack Fish*

I. PENDAHULUAN

Sulawesi Tenggara merupakan provinsi yang terletak di Pulau Sulawesi dan merupakan salah satu provinsi penghasil produksi ikan tangkap terbesar di Indonesia. Produksi perikanan tangkap di Sulawesi Tenggara dari Tahun 2014 sampai dengan tahun 2018 terus meningkat. Peningkatan tersebut sangat signifikan, terutama jumlah produksi Tahun 2018. Pemasok utama produksi perikanan tangkap di Sulawesi Tenggara adalah Kota Kendari, Bombana, Kabupaten Buton, Kolaka Utara dan Wakatobi. Terdapat Kabupaten/ Kota pemasok utama ini melebihi 75 % produksi ikan tangkap di Sulawesi Tenggara. Jenis komoditas perikanan yang berkontribusi pada data produksi perikanan tangkap tersebut adalah ikan cakalang, ikan tuna, ikan tongkol dan jenis lainnya seperti ikan lemuru, kakap merah dan kerapu. Provinsi Sulawesi Tenggara merupakan provinsi yang menghasilkan produksi ikan tangkap terbesar di Indonesia khususnya ikan cakalang.

Dinas Kelautan dan Perikanan Provinsi Sulawesi Tenggara memiliki data yang dapat digunakan untuk memprediksi jumlah produksi ikan cakalang Provinsi Sulawesi Tenggara yang nantinya dapat mengambil kebijakan yang tepat kedepannya, tetapi sebelum sampai ketahap itu, diperlukan penelitian dan analisis hasil prediksi agar tercapainya hasil prediksi dengan akurasi yang tepat. Peramalan hasil tangkap ikan sangat penting dilakukan mengingat data hasil tangkap ikan yang ada saat ini umumnya hanya didesiminasikan dalam bentuk laporan tahunan yang bersifat deskriptif. Untuk menjaga keberlanjutan pasokan dan keberlanjutan industri perikanan, khususnya ikan cakalang yang merupakan salah satu komoditas unggulan, diperlukan peramalan yang lebih spesifik dan akurat. Ikan cakalang memiliki nilai ekonomis yang tinggi dan menjadi andalan bagi industri pengalengan serta ekspor, sehingga keberlanjutan ketersediaan ikan ini menjadi fokus utama bagi pemangku kepentingan. Oleh karena itu, peramalan sangat diperlukan untuk memastikan stabilitas pasokan, membantu dalam perencanaan kegiatan penangkapan dan pengelolaan sumber daya agar tetap berkelanjutan serta untuk menghindari overfishing yang dapat berdampak negatif terhadap populasi ikan cakalang.

. Peramalan adalah kegiatan memperkirakan apa yang akan terjadi masa yang akan datang. Sedangkan ramalan adalah sesuatu situasi atau kondisi yang diperkirakan akan terjadi pada masa yang akan datang, ramalan tersebut dapat didasarkan atas bermacam-macam cara yang dikenal dengan metode peramalan. Metode peramalan adalah cara memperkirakan secara kuantitatif apa yang akan terjadi pada masa depan, berdasarkan data yang relevan pada masa lalu. (Robial, 2018)

Salah satu metode peramalan yang dapat digunakan adalah metode *Singular Spectrum Analysis* (SSA). Metode SSA merupakan metode yang fleksibel karena menggunakan pendekatan non-parametrik. Artinya, dalam pengaplikasiannya, metode ini tidak membutuhkan

spesifikasi model dari data deret waktu, serta asumsi-asumsi *parametric*, sehingga diharapkan metode SSA dapat memberikan hasil peramalan yang akurat. Karakteristik pada SSA yang tidak ada di metode lain yaitu metode SSA mendekomposisi data deret waktu asli menjadi suatu penjumlahan dari sejumlah kecil komponen independen seperti komponen *trend*, musiman, dan *noise*. (Wicaksono., *et al*, 2019).

Beberapa hasil penelitian menunjukkan bahwa Model SSA memiliki beberapa keuntungan dibandingkan model *time series* yang lain. Keunggulan dari model SSA terlihat lebih fleksibel dan mampu memodelkan musiman dengan waktu multi periode dan musiman yang kompleks. Akurasi peramalan sebuah metode dikatakan baik apabila memiliki nilai MAPE kurang dari 20% (Siregar., *et al*, 2017).

Pada Penelitian sebelumnya dengan menggunakan Metode *Singular Spectrum Analysis* pernah dilakukan (Jesi, 2020) dalam meramalkan curah hujan di Provinsi Sulawesi Tenggara dengan $L=7$ dan diperoleh MAPE sebesar 33%. Selanjutnya, penelitian dilakukan (Ega., *et al*, 2024) dalam meramalkan produksi padi di Provinsi Sulawesi Tenggara dimana peneliti tersebut menggunakan $L=24$ dan membandingkan metode SSA dan metode ARIMA yang dimana SSA memperoleh MAPE sebesar 23,68 % sementara metode ARIMA memperoleh MAPE sebesar 48,16 % sehingga membuktikan bahwa metode SSA lebih baik dari metode ARIMA.

II. TINJAUAN PUSTAKA

Peramalan

Peramalan merupakan suatu kegiatan untuk memperkirakan sesuatu di masa depan berdasarkan data historis. Metode-metode peramalan yang biasanya digunakan seperti metode rata-rata bergerak, metode deterministik, metode dekomposisi, metode pemulusan eksponensial dan metode ARIMA Box-Jenkins. Metode-metode tersebut dapat digunakan jika mengikuti pola data runtun waktu tertentu dan harus memenuhi asumsi-asumsi tertentu seperti stasioneritas data atau kenormalan residual. Oleh karena itu terdapat beberapa metode yang dikembangkan untuk pola runtun waktu apapun dan atau tanpa memenuhi asumsi-asumsi tertentu salah satunya adalah metode *Singular Spectrum Analysis* (SSA).

Analisis *Time Series*

Metode *time series* diperkenalkan pertama kali pada tahun 1970 oleh George E. P. Box dan Gwilym M. Jenkins melalui bukunya yang berjudul *Time Series Analysis: Forecasting and Control*. Data deret waktu merupakan serangkaian data berdasarkan interval waktu yang tepat (Wei, 2006). Metode *time series* berupaya untuk meramalkan kondisi yang akan datang dengan menggunakan data historis dan mengekstrapolasikan pola tersebut ke masa depan. Dengan demikian tujuan analisis deret waktu adalah untuk memperoleh pola data deret waktu

dengan menggunakan pengamatan sebelumnya untuk memprediksi suatu nilai pada masa yang akan datang.

Metode Singular Spectrum Analysis (SSA)

Singular Spectrum Analysis (SSA) adalah teknik baru dari analisis deret waktu non-parametrik yang digunakan untuk peramalan. SSA juga merupakan metode yang menguraikan serial aslinya menjadi jumlah dari sejumlah kecil komponen ditafsirkan seperti *trend*, *seasonality* dan *noise*. *Trend* sendiri merupakan komponen data yang menunjukkan peningkatan atau penurunan dalam jangka panjang selama periode waktu yang akan diamati, sementara *seasonality* merupakan komponen data yang dimana fluktuasi data yang berulang setiap beberapa periode tertentu, lalu *noise* sendiri adalah komponen data yang tidak masuk kedalam komponen *trend* dan *seasonality*. Pengelompokan komponen-komponen yang ada dalam deret waktu, akan mendukung hasil peramalan yang baik. SSA terdiri dari dua tahap yang saling melengkapi, yaitu tahap dekomposisi dan tahap rekonstruksi. Pada tahap dekomposisi, dua langkah utama yang harus dilakukan untuk memperoleh *eigen triple* (komponen yang didapatkan dari nilai *singular value*, *eigenvector* dan *principal component*) yaitu *embedding* dan *singular value decomposition*. Pada tahap rekonstruksi, dua langkah yang harus dilakukan untuk memperoleh deret yang direkonstruksi, yaitu pengelompokan dan *diagonal averaging*. (Gumgum, *et al.*, 2015).

Algoritma Peramalan Singular Spectrum Analysis (SSA)

Algoritma dasar *Singular Spectrum Analysis* terdiri dari dua buah tahap yaitu dekomposisi dan rekonstruksi (Darmawan, *et al.*, 2015). Dekomposisi adalah proses penguraian bentuk menjadi elemen-elemen yang lebih kecil atau sederhana sehingga memudahkan peneliti untuk menganalisis dan menginterpretasi. Dekomposisi terbagi menjadi 2 proses yaitu proses *Embedding* dan proses *Singular Value Decomposition (SVD)*.

Embedding diartikan sebagai tahap mengubah data deret waktu awal menjadi matriks lintasan (*Trajectory Matrix*), yakni mentransformasi data yang berdimensi satu (vektor) menjadi data multidimensional (matriks). (Asrof, A *et al.*, 2017)

Misalkan terdapat data deret waktu dengan panjang N , tanpa data hilang dinyatakan dengan $X = [x_1, x_2, \dots, x_N]$, data ditransformasi ke dalam bentuk matriks berukuran $L \times K$. Dengan

L merupakan *window length* dengan $2 < L < \frac{N}{2}$. Belum ada metode khusus untuk menentukan nilai L secara pasti, sehingga untuk menentukan nilai L dilakukan dengan proses coba-coba (*trial and error*) dan $K = n - L + 1$. Dalam bentuk matriks dapat ditulis sebagai berikut (Khaeri., *et al.*, 2017) :

$$X_{LK} = \begin{bmatrix} x_1 & x_2 & x_3 & \cdots & x_K \\ x_2 & x_3 & x_4 & \cdots & x_{K+1} \\ x_3 & x_4 & x_5 & \cdots & x_{K+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & x_{L+2} & \cdots & x_{LK} \end{bmatrix}$$

Matriks X disebut juga matriks Hankel yang semua elemen anti diagonalnya bernilai sama. Jadi pada tahap ini *output* yang diperoleh adalah matriks Hankel yang berukuran $L \times K$.

Langkah kedua dalam dekomposisi adalah membuat *Singular Value Decomposition* (SDV) dari matriks lintasan. SDV bertujuan untuk memisahkan komponen dalam dekomposisi dari data runtun waktu. SVD dimulai dengan menentukan *eigenvalue* $(\lambda_1, \lambda_2, \dots, \lambda_L)$ dari matriks simetris $S = XX^T$ dimana $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L > 0$, serta *eigenvector* (u_1, u_2, \dots, u_L) . Dari matriks S tersebut. Dari perkalian matriks XX^T menghasilkan matriks simetris S berukuran $L \times L$. Selanjutnya perhitungan *eigenvalue* dan *eigenvectors* pada matriks S dapat dilakukan dengan persamaan :

$$\det (S - \lambda I) = 0$$

$$(S - \lambda I) \vec{X} = 0$$

Selanjutnya akan diperoleh *eigenvalue* λ_i untuk $i = 1, 2, \dots, L$ dan $U_i = (u_1, u_2, \dots, u_L)$ adalah *eigenvectors* dari *eigenvalue* yang bersesuaian. Lalu dihitung *Singular Value* dari matriks dimana matriks diagonal dengan diagonal utama berisi akar positif dari *eigenvalue* $(\sqrt{\lambda_i})$ dengan urutan menurun $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L > 0$.

Maka
$$\sqrt{\lambda_i} = \begin{bmatrix} \sqrt{\lambda_1} & \cdots & 0_L \\ \vdots & \ddots & \vdots \\ 0_L & \cdots & \sqrt{\lambda_L} \end{bmatrix}$$

Selanjutnya menghitung nilai *principal component* menggunakan persamaan berikut:

$$V_i = \frac{X^T U_i}{\sqrt{\lambda_i}}$$

SVD dari matriks lintasan dapat dituliskan sebagai berikut:

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

Pada rekonstruksi terdapat dua tahap yaitu *Grouping* dan *Diagonal Averaging*. Parameter yang memiliki peran penting dalam rekonstruksi adalah *grouping effect* (r). *Grouping* merupakan tahap pengelompokan *eigentriple* berdasarkan karakteristik tertentu yang dimiliki oleh setiap komponen. Pada langkah ini, matriks lintasan berukuran $L \times K$ diuraikan menjadi beberapa kelompok yaitu pola *trend*, *seasonal*, dan *noise*. *Grouping*. Tahapan untuk memilih set $I = \{I_1, I_2, \dots, I_m\}$ disebut *eigentriple grouping* yang dilakukan dengan *trial and error*. Penentuan anggota grup adalah dengan diagram pencar dari X_i , dengan dibentuk suatu grup jika diagram pencar dari X_i memiliki bentuk yang sama artinya komponen-komponen tersebut memiliki karakteristik yang hampir sama. (Golyandina, et.al., 2015).

Selanjutnya diagonal averaging Pada tahap ini akan dilakukan transformasi dari hasil pengelompokan matriks X_{I_i} ke dalam seri baru dengan panjang N . Tujuan dari tahap ini adalah mendapatkan *singular value* dari komponen-komponen yang telah dipisahkan, kemudian akan digunakan dalam peramalan. Hasil pada tahap ini merupakan matriks F sebagai berikut (Darmawan, et.al., 2015).

$$X_{LK} = \begin{bmatrix} f_{11} & f_{12} & \dots & f_K \\ f_{21} & f_{22} & \dots & f_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ f_L & f_{L+1} & \dots & f_N \end{bmatrix} ..$$

Untuk mencari rata-rata diagonal matriks dapat digunakan persamaan sebagai berikut.

$$\begin{aligned}
 &\left\{ \frac{1}{K} \sum_{m=1}^k f^{*m, k-m+1} \text{ Untuk } 1 \leq K \leq L \quad \frac{1}{L^* - 1} \sum_{m=1}^{L-1} f^{*m, k-m+1} \text{ Untuk } L^* \leq k \right. \\
 &< K \leq K^* \quad \frac{1}{N - K + 1} \sum_{m=k-K^*+1}^{N-K^*+1} f^{*m, k-m+1} \quad \text{Untuk } K' \leq 1 < k \\
 &< N
 \end{aligned}$$

Dimana $L^* = \min(L, K)$ dan $K^* = \max(L, K)$. Persamaan (2.7) jika diaplikasikan ke dalam matriks resultan X_{im} akan berbentuk deret $\tilde{Y}^{(k)} = (\tilde{y}_1^{(k)}, \dots, \tilde{y}_1^{(k)})$. Oleh karena itu, deret asli akan didekomposisi menjadi jumlah deret m deret:

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

Akurasi Peramalan

Ada beberapa metode yang dapat digunakan untuk melakukan peramalan dalam SSA diantaranya metode vektor dan metode *Linear Recurrent Formula* (LRF). Misalkan adalah vektor komponen pertama L-1 dari vektor eigen $U^{\bar{v}}$ dan π_j adalah komponen terakhir dari U_j ($j = 1, 2, \dots, r$) dimana r adalah koefisien LRF, didefinisikan vektor koefisien LRF yaitu r sebagai berikut:

$$r = \frac{1}{1 - v^2} \sum_{j=1}^r \pi_j U^{\bar{v}} \quad ; \text{, dimana} \quad v^2 = \sum_{j=1}^r \pi_j^2$$

$$y_i = \begin{cases} y_i, & i = 1, \dots, T \\ R^T Z_i, & i = T + 1, \dots, T + M \end{cases}$$

dimana $Z_i = [y_{i-L+1}, \dots, y_{i-1}]^T$ dan y_1, y_2, \dots, y_T diperoleh dari diagonal averaging (Khaeri., et al, 2017)

Salah satu tingkat akurasi peramalan dapat diukur dari nilai *Mean Absolute Percentage Error* (MAPE) yaitu rata-rata persentase kesalahan pertama dari beberapa periode. Tingkat keakuratan dapat dijelaskan dengan membandingkan nilai yang diproyeksikan dengan nilai aktual. Untuk melakukan peramalan maka nilai akurasinya harus semakin kecil (Hardi. D. T., et al., 2019).

Menurut Tsaur (2012) menggunakan metode *Mean Absolute Percentage Error* (MAPE) untuk mengetahui besarnya penyimpangan yang terjadi pada data hasil peramalan terhadap data aktual. MAPE yang digunakan untuk ukuran keakuratan adalah sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100\%$$

Dimana y_t^i merupakan data aktual pada periode ke- t , \hat{y}_t^i merupakan data ramalan periode ke- t , dan n menyatakan banyaknya data aktual.

Kriteria keakuratan dengan menggunakan nilai MAPE dapat dilihat pada Tabel 2.1 (Maricar, 2019).

Tabel 1. Kriteria Tingkat Akurasi Nilai MAPE

Nilai MAPE	Kriteria Tingkat Keakuratan
<10%	Sangat baik
10% – 20%	Baik
20% – 50%	Cukup
>50%	Buruk

III. METODE PENELITIAN

Materi Penelitian

Bahan dari penelitian ini adalah data sekunder dari hasil produksi ikan cakalang di Provinsi Sulawesi Tenggara dari bulan Januari 2019 sampai bulan Desember 2022 yang

bersumber dari Dinas Kelautan dan perikanan Sulawesi Tenggara. Variabel Penelitian yang digunakan hanya satu yaitu jumlah produksi perikanan tangkap di Sulawesi Tenggara. Data tersebut dibagi menjadi dua yaitu data *training* (sebanyak 36 data yaitu data pada bulan Januari 2019 sampai bulan Desember 2021) dan data *testing* (sebanyak 12 data yaitu data pada bulan Januari sampai bulan Desember 2022).

Prosedur Penelitian

Adapun langkah-langkah yang dilakukan pada penelitian ini adalah sebagai berikut:

1. Mempersiapkan data dan membagi data menjadi data *training* dan *testing* Produksi Ikan Cakalang.
2. Membuat plot *time series* dari data untuk mengetahui pola data.
3. Melakukan analisis data tahap pertama yaitu tahap dekomposisi. Tahap ini dibagi menjadi dua langkah yaitu *embedding* dan *singular value decomposition* (SVD).
4. Melakukan analisis data tahap kedua yaitu rekonstruksi. Tahap ini juga dibagi menjadi dua langkah yaitu *grouping* dan *diagonal averaging*. Membentuk model *Singular Spectrum Analysis*
5. Menghitung tingkat *error* peramalan menggunakan *Mean Absolute Percentage Error* (MAPE).
6. Melakukan peramalan dengan metode *Singular Spectrum Analysis* dengan menggunakan model yang telah didapatkan sebelumnya.
7. Menginterpretasi hasil peramalan yang didapatkan.
8. Menarik kesimpulan

IV. HASIL, ANALISIS, DAN PEMBAHASAN

Identifikasi Data

Data analisis pada penelitian ini adalah data produksi ikan cakalang di Provinsi Sulawesi Tenggara dari bulan Januari 2019 sampai bulan Desember 2022 yang bersumber dari Dinas Kelautan dan perikanan Sulawesi Tenggara. Plot produksi ikan cakalang di Provinsi Sulawesi Tenggara ditunjukkan pada Gambar 1



Gambar 1. Plot *Time Series* Produksi Ikan Cakalang

Berdasarkan Gambar 1, data produksi ikan cakalang disajikan dalam satuan ton dan data tersebut tidak mengandung data hilang (*missing data*). Data produksi ikan cakalang pada Gambar 1, menunjukkan pola musiman dengan periode musiman 4. Hal ini dapat dilihat dari plot *time series* yang memiliki pola pergerakan yang sama setiap periode 4 yaitu mengalami penurunan lalu mengalami kenaikan kembali secara berulang.

Analisis Data

Langkah awal pada tahap dekomposisi yaitu proses *embedding*, di mana data diubah menjadi data satu dimensi, dengan jumlah sebanyak 27 data dari bulan Januari 2019 hingga Desember 2021 dengan susunan sebagai berikut :

$$\begin{bmatrix} \text{Januari}(2019) \\ \text{Februari}(2019) \\ \vdots \\ \text{Maret}(2021) \end{bmatrix} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_{27} \end{bmatrix} = \begin{bmatrix} 975.416 \\ 992.312 \\ \vdots \\ 633.484 \end{bmatrix}$$

selanjutnya data satu dimensi di ubah menjadi data multidimensi yang disebut sebuah matriks lintasan X dengan dimensi $L \times K$. Penentuan nilai L berdasarkan nilai MAPE minimum dimana L yang di analisis berada di rentang adalah $2 < L < 18$. Nilai L yang menghasilkan nilai MAPE minimum berada di $L=10$. Dari nilai L , diperoleh nilai $K=27$ berdasarkan persamaan $K = N - L + 1$ dimana nilai $N = 36$ dan $L = 10$. Setelah diperoleh nilai $L = 10$ dan $K = 27$. Maka matriks lintasan X dapat dibentuk. Dengan demikian matriks lintasan X yang dibangun dari deret F dapat digambarkan sebagai berikut:

$$X_{10 \times 27} = \begin{bmatrix} 975.416 & 992.312 & 819.866 & \dots & 633.484 \\ 992.312 & 819.866 & 638.109 & \dots & 421.295 \\ 819.866 & 638.109 & 729.202 & \dots & 572.480 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 938.146 & 874.909 & 781.659 & \dots & 573.353 \end{bmatrix}$$

Langkah berikutnya yang dilakukan dalam tahap dekomposisi adalah *singular value decomposition* (SVD). Pada langkah ini, matriks lintasan X didekomposisi menjadi 10 *eigen triple*, yang terdiri dari 10 nilai eigen, 10 vektor eigen, dan 0 vektor faktor. Selanjutnya, pada tahap ini dilakukan perhitungan untuk mencari nilai *eigen triple* berdasarkan matriks lintasan $X_{(10 \times 27)}$. Langkah awal yang dilakukan yaitu membentuk matriks simetris $S = XX^T$ sebagai berikut:

$$S = X_{(10 \times 27)} \times X_{(27 \times 10)}^T$$

$$s = \begin{bmatrix} 14785207 & 14022294 & 13456356 & \dots & 12023663 \\ 14022294 & 14011260 & 13295560 & \dots & 11533319 \\ 13456356 & 13295560 & 13354311 & \dots & 11070275 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 12023663 & 11533319 & 11070275 & \dots & 11571035 \end{bmatrix}$$

Setelah diperoleh matriks simetris $S_{(10 \times 10)}$ langkah selanjutnya menghitung nilai-nilai *eigen triple*. Dari matriks tersebut dihitung nilai *eigenvalue* (λ_i) dengan persamaan berikut:

$$\det(S - \lambda I) = 0$$


Kemudian dari nilai *eigenvalue* dihitung nilai *singular value* $\sqrt{(\lambda_i)}$ yang disajikan pada Tabel 2 sebagai berikut:

Tabel 2. *Eigenvalues dan Singular Value*

No	<i>Eigenvalues</i>	<i>Singular Values</i>
1	120378058.2	10971.6935
2	3737080.1	1933.1529
⋮	⋮	⋮
10	135588.8	368.2239


Selanjutnya tahap rekonstruksi, pada tahap ini terdapat dua langkah yang digunakan untuk mendapatkan komponen *trend*, komponen *seasonality*, dan komponen *noise*, yaitu pengelompokan dan *diagonal averaging*. Langkah pertama dalam tahap ini adalah melakukan pengelompokan terhadap *eigen triple* yang berhubungan dengan *trend*, *seasonality*, dan *noise*. *Eigen triple* ialah komponen yang terbentuk dari nilai *singular*, *eigenvalue* dan *Principal component*. Dimana *noise* adalah *eigen triple* yang tidak masuk pada kategori *trend* ataupun *seasonality*. Adapun parameter yang digunakan pada tahap pengelompokan adalah *Effect grouping (r)*. *Effect grouping (r)* digunakan untuk membatasi jumlah *eigen triple* yang akan digunakan untuk mengidentifikasi komponen *trend* dan *seasonality*. Nilai parameter *effect grouping (r)* ditentukan berdasarkan jumlah *eigen triple* yang tidak mencerminkan *noise*

pada plot dari nilai *singular*. Berikut plot singular dari data Produksi Ikan Cakalang di Provinsi Sulawesi Tenggara.



Gambar 2 Plot Singular Produksi Ikan cakalang

Berdasarkan Gambar 2, diketahui bahwa nilai *singular* mulai menurun secara lambat pada *eigenvalue* 6 sampai *eigenvalue* 10 sehingga *eigenvalue* 6 sampai *eigenvalue* 10 diidentifikasi sebagai komponen *noise*. Dengan demikian nilai parameter *effect grouping*(r) adalah $r = 5$ karena jumlah *eigenvalue* yang tidak mencerminkan *noise* pada plot dari nilai singular adalah 5. Berikut Gambar 4.3 yaitu Plot dari deret yang direkonstruksi untuk mengidentifikasi *eigenvalue* yang berhubungan dengan *trend* dan *seasonality*.



Gambar 3 Plot deret Rekonstruksi


Dari hasil rekonstruksi maka didapatkan pengelompokan komponen sebagai berikut:

Tabel 3 *Eigenvalue* Komponen


Jenis Komponen	<i>Eigenvalue</i>
<i>Seasonal</i>	2 dan 3, 5 dan 6
<i>Trend</i>	1
<i>Noise</i>	4,7,8,9,10

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


terlihat pada Gambar 5. Komponen *noise* direkonstruksi menggunakan *eigen triple* 4, dan *eigen triple* 7 hingga 10.



Gambar 4 Plot *Trend* Rekontruksi



Gambar 5 Plot *Seasonality* Rekontruksi



Gambar 6 Plot *Noise* Rekontruksi

Peramalan

Setelah berhasil memisahkan komponen *trend*, *seasonality*, dan *noise*, langkah selanjutnya adalah melakukan peramalan pada masing-masing komponen *trend* dan komponen *seasonality*. Setelah masing-masing komponen didapatkan hasil peramalannya,

nilai ramalan untuk seluruh data *training* dan data *testing* diperoleh dari hasil penjumlahan nilai ramalan dari komponen *trend* dan komponen *seasonality*. Algoritma pada peramalan *R-forecasting* yang berkaitan dengan penaksiran koefisien *Linear Recurrent Formula* (FRL). Adapun model persamaan yang digunakan untuk meramalkan Produksi Ikan Cakalang adalah sebagai berikut:


$$Y_i = 0.238742400_{i-1} - 0.196532145_{i-2} + \dots + 0.601112845_{i-9}$$

Model persamaan yang diperoleh kemudian divalidasi menggunakan sejumlah indikator. Salah satu indikator yaitu menggunakan MAPE. Perhitungan akurasi peramalan dilakukan dengan membandingkan data aktual dan data ramalan untuk melihat apakah model tersebut layak atau tidak untuk meramalkan produksi ikan cakalang di pelabuhan Provinsi Sulawesi Tenggara. Berikut ditampilkan hasil peramalan berulang *Singular Spectrum Analysis* untuk data *testing* dari komponen *trend* dan *seasonal* untuk 12 bulan ke depan.

Tabel 4.4 Hasil peramalan dengan komponen *trend* dan *seasonal*

Bulan	<i>Trend</i>	<i>Seasonality</i>	Ramalan	Aktual
Januari	631.382	-61.887	569.494	719.565
Februari	638.268	-137.314	500.953	636.054
Maret	644.705	-251.705	393.000	531.241
April	650.119	-207.013	443.106	311.033
Mei	654.057	-139.855	514.202	529.719
Juni	656.001	-68.710	587.290	544.522
Juli	655.983	105.727	761.710	708.029
Agustus	654.715	204.950	859.666	872.873
September	652.891	238.880	891.771	811.239
Oktober	650.918	264.695	915.614	844.889
November	653.094	162.317	815.411	815.351
Desember	654.761	17.407	672.168	700.862

Gambar 7 menampilkan hasil peramalan jumlah ikan cakalang menggunakan metode SSA data aktual dan data ramalan secara visual sebagai berikut:



Gambar 7 Plot Perbandingan data aktual dan ramalan produksi ikan cakalang

Berdasarkan gambar 7, menunjukkan bahwa hasil peramalan produksi ikan cakalang mendekati nilai aktualnya. Untuk menentukan nilai *window length* (L) yang baik, digunakan perhitungan akurasi yang memberikan informasi persentase kesalahan hasil pendugaan atau peramalan terhadap hasil aktual selama periode tertentu. Akurasi peramalan metode SSA pada penelitian ini menggunakan metode *Mean Absolute Percentage Error* (MAPE). Secara matematis dituliskan sebagai berikut:

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

$$MAPE = \frac{1}{12} \left(\left(\frac{719.565 - 569.494}{719.565} \right) + \left(\frac{636.054 - 500.953}{636.054} \right) + \dots + \left(\frac{700.862 - 672.168}{700.862} \right) \right) \times 100\%$$

$$MAPE = 12,73\%$$

Berdasarkan perhitungan sebelumnya, data produksi ikan cakalang di Provinsi Sulawesi Tenggara dengan *window length* (L) sebesar 10 yang didapatkan dengan proses *trial and error* memperoleh nilai MAPE sebesar 12,73%. Berdasarkan hal tersebut dapat disimpulkan bahwa metode *Singular Spectrum Analysis* (SSA) dengan *window length* = 10 dapat dikatakan memiliki keakuratan peramalan yang baik dalam meramalkan produksi ikan cakalang. Hasil penelitian ini menunjukkan bahwa metode SSA menghasilkan MAPE sebesar 12,73%, sedangkan penelitian sebelumnya yang dilakukan oleh Ega *et al*, (2024) dalam meramalkan produksi padi di Provinsi Sulawesi Tenggara dimana peneliti tersebut menggunakan L=24 dan metode yang sama mendapatkan nilai MAPE sebesar 23%. Artinya MAPE pada penelitian ini mendapatkan MAPE yang lebih rendah jika dibandingkan dengan penelitian sebelumnya, hal ini dapat disebabkan oleh perbedaan dalam kondisi data, model ataupun parameter yang digunakan.

V. KESIMPULAN DAN SARAN

KESIMPULAN

Berdasarkan hasil dan pembahasan diatas, dapat ditarik kesimpulan dalam penelitian ini, diantaranya sebagai berikut:

1. Model *Singular Spectrum Analysis* (SSA) yang digunakan untuk meramalkan hasil produksi ikan cakalang di Provinsi Sulawesi Tenggara selama dua belas bulan ke depan yaitu sebagai berikut:

$$Y_i = 0.238742400_{i-1} - 0.196532145_{i-2} + \dots + 0.601112845_{i-9}$$

Model tersebut merupakan model SSA terbaik pada penelitian ini dengan nilai *window length* $L=10$ serta nilai MAPE sebesar 12,73 %. Hal ini menunjukkan bahwa metode SSA dapat meramalkan produksi ikan cakalang di Provinsi Sulawesi Tenggara dengan akurat dan masuk dalam kategori baik.

2. Keakuratan hasil peramalan hasil produksi ikan cakalang di Provinsi Sulawesi Tenggara menunjukkan bahwa kinerja peramalan dengan metode SSA akurat dengan nilai MAPE 12,73% dimana kategori tersebut masuk pada kategori baik. Berdasarkan hal tersebut, metode SSA lebih cocok digunakan untuk peramalan hasil produksi ikan cakalang Provinsi Sulawesi Tenggara.

SARAN

Dari kesimpulan yang telah diambil, berikut dapat diberikan saran dari peneliti dimana untuk menindaklanjuti hasil penelitian ini alangkah baiknya Menggunakan metode peramalan yang berbeda untuk memperoleh tingkat keakuratan yang lebih baik.

DAFTAR PUSTAKA

- Asrof, A., Rabbani, I., dan Gumgum, D. 2017. Peramalan Produksi Cabai Merah di Jawa Barat Menggunakan Metode *Singular Spectrum Analysis* (SSA). *Jurnal Statistika*.**17**(2),77-87.
- Darmawan, G., Triyani, H., Restu, A. 2015. *Model Auto Singular Spectrum Analysis untuk Meramalkan Kejadian Banjir di Bandung dan Sekitarnya*. *Seminar Matematika dan Pendidikan Matematika UNY*. Jurusan Statistika Universitas Padjadjaran. Bandung.
- Ega Sarmita. 2024. Aplikasi Metode Singular Spectrum Analysis (SSA) dalam Peramalan Produksi Padi di Provinsi Sulawesi Tenggara. *Jurnal Pustaka Nusantara Multidisplin*
- Golyandina, N., dan Shlemov, A. (2013). *Variations of singular spectrum analysis for separability improvement: non-orthogonal decompositions of time series*. *Journal Statistics and Its Interface*, 2015,,8(3), P.277-294
- Gumgum, D., Triyani, H., dan Restu, A. 2015. *Model Auto Singular Spectrum Analysis untuk Meramalkan Kejadian Banjir di Bandung dan Sekitarnya*. *Seminar Matematika dan Pendidikan Matematika UNY*. Jurusan Statistika Universitas Padjadjaran: Bandung.

- Hardi, Desy Tresnowati. (2019). Peramalan Produk Domestik Bruto (PDB) Sektor Pertanian, Kehutanan, dan Perikanan *Menggunakan Singular Spectrum Analysis (SSA)*. *Jurnal Gaussian*, **8(1)**, ISSN: 2339-2541.
- Khaeri, H., Eko, Y., Gungum, D. 2017. Penerapan Metode *Singular Spectrum Analysis (SSA)* pada Peramalan Jumlah Penumpang Kereta Api di Indonesia Tahun 2017. *Jurnal Euclid*. **5(1)**,8.
- Robial, Siti Muawanah. 2018. Perbandingan Model Statistika pada Analisis Metode Peramalan TimeSeries (Studi Kasus : PT. Telekomunikasi Indonesia, TBK Kandatel Sukabumi). *Jurnal Ilmiah Santika*. **8(2)**, ISSN : 2088-5407.
- Siregar, R.S.K., Dina, P., dan Gungum, D. 2017. Aplikasi Metode *Singular Spectrum Analysis (SSA)* dalam Peramalan Pertumbuhan Ekonomi Indonesia Tahun 2017. *Jurnal Matematika Mantik*. **3(1)**, E-ISSN: 2527
- Wei, W. W. (2006). *Time Series Analysis Univariate and Multivariate Methods* (2nd ed.). United States of America: Pearson Education, Inc.

LAMPIRAN

A. Data Jumlah Produksi Ikan Cakalang Di Provinsi Sulawesi Tenggara (Ton)

Bulan	Tahun			
	2019	2020	2021	2022
Januari	975.416	909.424	671.673	719.565
Februari	992.312	505.021	680.810	636.054
Maret	819.866	723.004	633.484	531.241
April	638.109	525.534	421295	311.033
jrMei	729.202	339.021	572.480	529.719
Juni	496.577	375.070	589.761	544.522
Juli	530.180	520.845	518.243	708.029
Agustus	688.112	565.366	313.715	872.873
September	804.305	848.689	460.868	811.239
Oktober	938.146	907.591	378.206	844.889
November	847.909	912.222	277.352	815.351
Desember	781.659	979.900	573.353	700.862

B. Syntax Program R untuk Metode SSA pada data Produksi Ikan Cakalang di Provinsi Sulawesi Tenggara

```
#remove variables
rm(list=ls())

#close figures
graphics.off()

#panggil data
data<-read.csv("D://Intan/Cakalangneww.csv",header = TRUE, sep=";")
data
data1<- data[1:48,2]
data1
Produksi Ikan Cakalang<- ts(data1, start=c(2019, 1), frequency = 12)
Produksi Ikan Cakalang
ts.plot(Yt,main=paste("Plot Produksi Ikan Cakalang TimeSeries"),col=c("red"))

library(Rssa)
insample<- data[1:36,2]
insample
outsample<- data[37:48,2]
outsample
```

```
#parameter windowlength
n=length(data[1:36,2])
p=12

insample=data[1:(n-p),2]
n1=length(insample)
n1

L=10
K=36-L+1

#dekomposisi
##1.embedding
z=as.matrix(insample)
z
x=embed(z,L)
id=1:L
y=rbind(id,x)
y
w=as.matrix(y)
sort=w[,order(-w[1,])]
thankel=as.matrix(sort[-1,(1:L)])
hankel=t(thankel)
hankel

#2.svd
trajectory=hankel%*%t(hankel)
dim(trajectory)

#eigen value
e.value=eigen(trajectory)$values
e.value
total=sum(e.value)
propv=e.value/total

#Singular Value
s.value=sqrt(e.value)
```

```
#eigen vector
e.vector=eigen(trajjectory)$vectors
e.vector
#principal component
pca1=(hankel*e.value)/s.value
pca1
#plot singularvalue
s=ssa(insample, L=10, kind="1d-ssa")
s
#plot tree
plot(s)

#Rekontruksi
plot(s, col = c("red"))
plot(s, type = "series",col = c("red"), groups = as.list (1:10))
#1.grouping
Produksi_Ikan_Cakalang<- ts(data1, start=c(2019, 1), frequency = 12)
Produksi_Ikan_Cakalang
plot(Produksi_Ikan_Cakalang , col = c("red"))
plot(Produksi_Ikan_Cakalang, type = "series",col = c("red"), groups = as.list (1:10))
r=reconstruct(s,groups=list(trend=c(1),seasonal1=c(2:3,5:6)),len=12)
r
7trend<- r$Trend
trend
plot(trend,col = c("red"))
seasonality<- r$Seasonality
seasonality
plot(seasonality,col = c("red"))
noise<-residuals(r)
noise
plot(noise,col = c("red"))
#2.diagonal avaraging
komponen=cbind(r$trend,r$season1)
diagonal.averaging=rowSums(komponen)
diagonal.averaging
```

```
#Recurrent forecasting
forecast=rforecast(s,groups=list(trend=c(1),season1=c(2:3,5:6)),len=12)

forecast

hasil.forecast=as.matrix(forecast$trend+forecast$season1)

hasil.forecast

#akurasi peramalan

hasil.forecast1=forecast$trend+forecast$season1

accuracy(hasil.forecast1,outsample)

f2<-rforecast(s,groups=list((1:3)),only.new=TRUE,len=12)
```

C. *Eigenvalues dan Singular Values*

No	<i>Eigenvalues</i>	<i>SingularValues</i>
1	120378058.2	10971.6935
2	3737080.1	1933.1529
3	2557805.7	1599.3141
4	508326.1	712.9699
5	401271.4	633.4598
6	359184.3	599.3199
7	261955.0	511.8154
8	213488.6	462.0483
9	147190.8	383.6545
10	135588.8	368.2239

D. Hasil Rekontruksi Komponen

No	<i>Trend</i>	<i>Seasonal</i>	<i>Noise</i>	<i>Diagonal Averaging</i>
1	812.535	220434	-57553	975.416
2	796.102	179431	16778	992.311
3	777.621	36067	6176	819.864
4	768.595	-95123	-35362	638.110
5	760.105	-138492	107589	729.202
6	751.750	-215391	-39781	496.578
7	746.535	-153398	-62956	530.181
8	739.740	-55204	3575	688.111
9	729.123	47322	27859	804.304
10	716.260	183253	38632	938.145
11	701.099	151822	-5013	847.908
12	687.196	168717	-74254	781.659

13	676.641	157563	75219	909.423
14	665.182	-41148	-119013	505.021
15	659.830	-45194	108368	723.004
16	653.996	-130330	1867	525.533
17	649.448	-307042	-3385	339.021
18	649.789	-219696	-55023	375.070
19	653.757	-154659	21747	520.845
20	661.085	-75995	-19723	565.367
21	672.396	159059	17232	848.687
22	680.373	212965	14252	907.590
23	681.134	231763	-675	912.222
24	677.348	257758	44792	979.898
25	662.759	68085	-59171	671.673
26	644.752	3536	32521	680.809
27	624.124	4107	5251	633.482
28	611.269	-117290	-72683	421.296
29	595.835	-76870	53515	572.480
30	576.754	-10125	23131	589.760
31	552.009	-102110	68343	518.242
32	524.540	-90078	-120746	313.716
33	500.010	-41709	2566	460.867
34	474.480	-122618	26344	378.206
35	455.137	-93592	-84192	277.353
36	444.558	21326	107468	573.352

E. Nilai *Linear Recurrent Formula* (LFR)

No	LFR
1	0.238742400
2	-0.196532145
3	0.042750469
4	0.023658089
5	-0.403373954
6	-0.061123430
7	0.083511024
8	0.007868696
9	0.601112845