

Proyeksi Produksi Padi Kabupaten Pinrang Dengan Metode *Singular Spectrum Analysis*

Irwan

Program Studi Matematika, Universitas Islam Negeri Alauddin Makassar, irwan.msi@uin-alauddin.ac.id

Adnan Sauddin

Program Studi Matematika, Universitas Islam Negeri Alauddin Makassar, adnansauddin@uin-alauddin.ac.id

Anita Kaimuddin

Program Studi Matematika, Universitas Islam Negeri Alauddin Makassar, 60600116046@uin-alauddin.ac.id

ABSTRACT, The increasing population growth in Pinrang Regency every year had an impact on increasing the need for food, especially rice production which was generally a staple food source in Pinrang Regency. so it was necessary to do a forecast to anticipate future food shortages. This study aimed to determine the yield of rice production in Pinrang Regency in 2021 and the level of accuracy of the method used. The results of the study obtained forecast for rice production in Pinrang Regency in 2021 using the Singular Spectrum Analysis (SSA) method, respectively from the first quarter to the third quarter of 33603 tons, 25988 tons, and 43234 tons with the level of forecasting accuracy based on standard MAPE value obtained by 4.97 %. The MAPE value obtained was less than 10 % and close to 0 %, meaning that the SSA method with windows length 9 and 7 groups were very accurate to be used to predict rice production in Pinrang Regency.

Keywords: *Singular Spectrum Analysis, forecasting, Windows Length, MAPE.*

ABSTRAK, meningkatnya kebutuhan akan pangan khususnya produksi padi yang umumnya menjadi sumber makanan pokok di Kabupaten Pinrang, sehingga perlu dilakukan suatu peramalan untuk mengantisipasi kekurangan pangan di masa mendatang. Penelitian ini bertujuan untuk mengetahui hasil produksi padi di Kabupaten Pinrang pada Tahun 2021 serta tingkat akurasi metode yang digunakan. Adapun hasil penelitian diperoleh hasil ramalan produksi padi di Kabupaten Pinrang pada Tahun 2021 dengan metode Singular Spectrum Analysis (SSA) masing – masing dari Kuartal I sampai Kuartal III sebesar 33603 ton, 25988 ton, dan 43234 ton dengan tingkat akurasi peramalan berdasarkan standar nilai MAPE diperoleh sebesar 4.97%. Nilai MAPE yang diperoleh kurang dari 10 % dan mendekati 0 %, artinya metode SSA dengan windows length 9 dan 7 grup sangat akurat digunakan untuk meramalkan produksi padi di Kabupaten Pinrang.

Kata Kunci: *Singular Spectrum Analysis, Peramalan, Windows Length, MAPE.*

1. PENDAHULUAN

Sepanjang sejarah, masyarakat selalu dihadapkan pada masalah produksi padi untuk memenuhi kebutuhan hidupnya yang paling dasar. Dalam rangka memenuhi kebutuhan tersebut, pemerintah perlu melakukan suatu tindakan untuk mengantisipasi kekurangan pangan di masa mendatang. Salah satu strategi yang bisa dilakukan yaitu dengan melakukan suatu peramalan untuk melihat perkembangan produksi padi di masa mendatang.

Ada banyak metode peramalan yang tengah berkembang saat ini. Namun hasil peramalan akan bermanfaat jika menggunakan metode peramalan yang tepat. Setelah dilakukan identifikasi awal, data produksi padi mengandung unsur musiman. Unsur musiman dipengaruhi oleh masa panen yang akan tinggi pada bulan-bulan tertentu. Berdasarkan hal tersebut, maka peramalan dapat dilakukan dengan menggunakan metode *Singular Spectrum Analysis* (SSA).

SSA merupakan metode peramalan yang lebih fleksibel dari metode peramalan lainnya karena menggunakan pendekatan nonparametrik yaitu tidak perlu adanya uji-uji asumsi seperti independensi dan normalitas residual dan cocok digunakan untuk data stationer maupun nonstationer. [1]

Penelitian terkait dengan hal di atas antara lain yaitu Asnafiyah Asrof dkk (2017) yang meneliti tentang penggunaan metode SSA untuk meramalkan produksi cabai merah yang mengandung unsur musiman menunjukkan tingkat akurasi yang baik dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 18,23%. [2] Yogo Aryo Jatmiko dkk (2017)

meneliti terkait metode SSA dalam meramalkan produksi bawang merah dan diperoleh hasil peramalan yang akurat dengan nilai MAPE sebesar 15,63%. [3] Desy Tresnowati Hardi (2019) melakukan penelitian dan diperoleh hasil bahwa metode SSA akurat digunakan dalam meramalkan PDRB Jawa Timur dengan nilai MAPE sebesar 1,59%. [4]

Senang Ukurta Tarigan (2018) melakukan penelitian untuk meramalkan total penggunaan listrik di Yogyakarta dan disimpulkan bahwa metode SSA akurat digunakan untuk data nonstationer dengan nilai MAPE sebesar 0,89%. [5] Yoseph O.S dkk (2017) melakukan penelitian dan mendapatkan hasil bahwa metode SSA akurat digunakan dalam meramalkan Jumlah Wisatawan Mancanegara dengan data mengandung unsur trend berpola musiman dengan nilai MAPE sebesar 12,73%. [6]

Gumgum Darmawan (2016) melakukan penelitian mengenai metode SSA dalam mengidentifikasi pola data curah hujan pada proses grouping dan memperoleh hasil ramalan yang akurat dengan nilai MAPE sebesar 14,45%. [7] Mahdi Kalantari (2021) melakukan penelitian untuk memperkirakan jumlah kasus harian, kematian, dan pemulihan yang disebabkan oleh Covid-19 pada 10 negara antara lain AS, India, Brazil, Rusia, Prancis, Spanyol, Argentina, Kolombia, Inggris, dan Meksiko dengan kriteria pengujian RMSE diperoleh bahwa metode SSA optimal lebih unggul dari metode ARIMA, ARFIMA, ETS, TBATS, dan NNAR. [8]

Kemudian Hector Briceno, dkk juga melakukan penelitian untuk memprediksi beban listrik kota Venezuela dengan membandingkan 3 metode yaitu metode Additive Holt-Winter, ARIMA dan SSA yang menunjukkan metode SSA merupakan metode terbaik dengan nilai MAPE sebesar 1,06%. [9]

Berdasarkan penelitian tersebut dapat dikatakan bahwa metode SSA akurat digunakan sebagai metode peramalan untuk data yang mengandung pola musiman sehingga dalam artikel ini fokus pada penelitian terkait Metode SSA pada proyeksi Produksi padi Kabupaten Pinrang Tahun 2021 dan Tingkat akurasi dari metode yang digunakan.

2. TINJAUAN PUSTAKA

Teori Matriks Untuk Metode SSA

Terdapat beberapa teori matriks yang berkaitan dengan metode SSA diantaranya yaitu matriks bujur sangkar, matriks simetris, matriks diagonal, transpose matriks, invers matriks, orthogonal dan orthonormal, partisi matriks, serta nilai eigen dan vektor eigen. [10]

Analisis Deret Waktu (*Time Series Analysis*)

Analisis deret waktu adalah salah satu prosedur statistika yang diterapkan untuk meramalkan struktur probabilistik keadaan yang akan terjadi di masa yang akan datang dalam rangka pengambilan keputusan. Model deret waktu berupaya untuk meramalkan kondisi masa yang akan datang dengan menggunakan data historis dan mengeksploitasi pola tersebut ke masa depan.

Suatu urutan pengamatan memiliki model deret waktu jika memenuhi hal berikut : [11]

1. Interval waktu antar indeks waktu t dapat dinyatakan dalam satuan waktu yang sama (identik)
2. Adanya ketergantungan antara pengamatan Z_t dengan Z_{t+k} yang dipisahkan oleh jarak berupa waktu kelipatan Δ_t sebanyak k kali (dinyatakan sebagai *lag k*). [12]

Singular Spectrum Analysis

Singular Spectrum Analysis (SSA) adalah sebuah teknik analisis yang digunakan untuk peramalan. SSA mengkombinasikan elemen klasik analisis deret waktu, statistik multivariat, geometri, sistem dinamis dan pemrosesan sinyal. [13] Terdapat dua tahap dalam metode SSA yaitu tahap dekomposisi dan tahap rekonstruksi

Dekomposisi

Pada dekomposisi, terdapat dua tahap yaitu *Embedding* dan *Singular Value Decomposition* (SVD).

Embedding

Embedding diartikan sebagai tahap mengubah data deret waktu awal diubah menjadi matriks lintasan \mathbf{X} , maksudnya mengubah data awal yang berupa data satu dimensi menjadi data berbentuk multidimensi. [9] Matriks lintasan \mathbf{X} berdimensi $L \times K$. Belum ada kriteria pemilihan L (*windows length*) yang tepat, namun rentang pemilihan nilai L adalah $2 < L < \frac{N}{2}$ dengan asumsi nilai L harus besar tapi tidak lebih dari $\frac{N}{2}$ dan $K = N - L + 1$. Data deret waktu sepanjang periode N tidak mengandung data hilang serta vektor \mathbf{x}_i dimana $i = 1, 2, \dots, N$. Matriks lintasan \mathbf{X} yang terbentuk disebut juga matriks hankel dimana semua elemen anti diagonalnya bernilai sama dan dinyatakan dalam bentuk sebagai berikut: [14]

$$\mathbf{X} = (\mathbf{x}_i)_{L \times K} = [x_1, x_2, \dots, x_N] = \begin{bmatrix} x_1 & x_2 & x_3 & \dots & x_K \\ x_2 & x_3 & x_4 & \dots & x_{K+1} \\ x_3 & x_4 & x_5 & \dots & x_{K+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{L+1} & x_{L+2} & x_{L+3} & \dots & x_{LK} \end{bmatrix} \tag{1}$$

Singular Value Decomposition (SVD)

Singular Value Decompositioin (SVD) atau Dekomposisi Nilai Singular bertujuan untuk memperoleh pemisahan komponen dalam dekomposisi dari data deret waktu. SVD dimulai dengan menentukan nilai *eigenvalue* ($\lambda_1, \lambda_2, \dots, \lambda_L$) dari matriks simetriks $\mathbf{S} = \mathbf{X}\mathbf{X}^T$ dimana $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L > 0$, serta *eigenvector* (u_1, u_2, \dots, u_L) dari matriks \mathbf{S} tersebut. [15] Langkah-langkah SVD yaitu :

1. Definisikan matriks $\mathbf{S} = \mathbf{X}\mathbf{X}^T$ yang juga merupakan matriks kovarians.
2. Menentukan *eigenvalue* dengan persamaan : $\det(\mathbf{S} - \lambda I) = 0$ dan *eigenvector* $\mathbf{U}_i = (u_1, u_2, \dots, u_L)$ dari *eigenvalue* yang bersesuaian.
3. Membuat matriks nilai singular

$$\sqrt{\lambda_i} = \begin{bmatrix} \sqrt{\lambda_1} & \dots & 0_L \\ \vdots & \ddots & \vdots \\ 0_L & \dots & \sqrt{\lambda_L} \end{bmatrix} \tag{2}$$

4. Membuat matriks *principal component* yang merupakan transpose dari matriks \mathbf{V}_i berikut :

$$\mathbf{V}_i = \frac{\mathbf{x}^T \mathbf{u}_i}{\sqrt{\lambda_i}} \tag{3}$$

Hasil tranpose matriks \mathbf{V}_i yaitu sbb :

$$\mathbf{V}_i^T = \begin{bmatrix} v_{11} & v_{12} & \dots & v_{1K} \\ v_{21} & v_{22} & \dots & v_{2K} \\ \vdots & \vdots & \ddots & \vdots \\ v_{K1} & v_{K2} & \dots & v_{KK} \end{bmatrix} \tag{4}$$

Setelah diperoleh *singular value* (σ_i), *vector eigen* (\mathbf{U}_i) dan *principal component* (\mathbf{V}_i^T) yang juga disebut sebagai *eigen triple*, maka SVD dari matriks lintasan \mathbf{X} adalah

$$\mathbf{X} = \mathbf{U}_i \sqrt{\lambda_i} \mathbf{V}_i^T \tag{5}$$

Ketiga komponen dalam matrix \mathbf{X}_i dapat dituliskan sebagai berikut :

$$\mathbf{X}_i = \mathbf{X}_1 + \mathbf{X}_2 + \dots + \mathbf{X}_d \tag{6}$$

Rekonstruksi


Pada tahap ini terdiri dari dua langkah yaitu proses *grouping* dan *diagonal averaging*

Grouping


Proses *grouping* dilakukan dengan cara mengelompokkan set-set indeks $i = \{1, 2, \dots, d\}$ ke dalam m subset disjoint I_1, I_2, \dots, I_m dengan $m = d$. Kemudian X_i disesuaikan dengan kelompok $I = \{I_1, I_2, \dots, I_m\}$. Maka, $\mathbf{X}_i = \mathbf{X}_1 + \mathbf{X}_2 + \dots + \mathbf{X}_d$ dapat di ekspansi menjadi

$$\mathbf{X}_I = \mathbf{X}_{I1} + \mathbf{X}_{I2} + \dots + \mathbf{X}_{Im} \tag{7}$$

Tahapan untuk memilih set $I = \{I_1, I_2, \dots, I_m\}$ disebut *eigen triple grouping* yang dilakukan dengan *trial and error*. Penentuan anggota grup adalah dengan diagram pencar dari \mathbf{X}_I , dimana akan dibentuk suatu grup jika diagram pencar dari \mathbf{X}_I memiliki bentuk yang sama artinya komponen-komponen tersebut memiliki karakteristik yang hampir sama. [5]



Gambar 1. Contoh Rekonstruksi Data



Gambar 2. Contoh plot *W-correlation*

Diagonal Averaging

Langkah terakhir dalam SSA adalah mengubah setiap matriks X_I menjadi sebuah runtun waktu baru dengan panjang N . Misalkan matriks Y adalah sebuah matriks sembarang berukuran $L \times K$ dengan unsur y_{ij} untuk $1 \leq i \leq L$ dan $1 \leq j \leq K$, dimana $L \leq K$.

$$Y = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1K} \\ y_{21} & y_{22} & \dots & y_{2K} \\ \vdots & \vdots & \ddots & \vdots \\ y_{L1} & y_{L2} & \dots & y_{LK} \end{bmatrix} \quad (8)$$

Matriks Y diubah ke dalam bentuk deret g_1, g_2, \dots, g_N melalui *diagonal avergaing* dengan cara berikut : [16]

$$g_k = \frac{\sum_{(l,k) \in A_s} y_{lk}}{|A_s|} \quad (9)$$

Berdasarkan persamaan di atas. misalkan pada matriks Y dipilih. Untuk $k = 1$ memberikan $g_1 = y_{11}$, untuk $k = 2$, maka $g_2 = \frac{y_{1,2} + y_{2,1}}{2}$, $g_3 = \frac{y_{1,3} + y_{2,2} + y_{3,1}}{2}$ dan begitu seterusnya. [2]

Keterpisahan

Konsep utama dalam metode SSA adalah keterpisahan yang mencirikan seberapa baik komponen yang berbeda dapat terpisah satu sama lain. Persamaan *W-correlation* merupakan pengukuran alami kemiripan antara dua deret $Y_N^{(i)}$ dan $Y_N^{(j)}$ yang dapat dirumuskan sebagai berikut:

$$\rho_{12}^{(w)} = \frac{(Y_N^{(i)} \cdot Y_N^{(j)})_w}{\sqrt{(Y_N^{(i)} \cdot Y_N^{(i)})_w (Y_N^{(j)} \cdot Y_N^{(j)})_w}} \quad (10)$$

Plot *W-correlation* digunakan untuk melihat besarnya korelasi antar *eigen triple*. Semakin tua warnanya maka semakin tinggi korelasinya. [17]

Noise

Variabel noise (ε) yang terdapat pada persamaan $Y = x + \varepsilon$. Hasil asimtotik berlaku untuk noise apapun menghasilkan distribusi dengan rata-rata nol dan hingga, bukan nol momen keempat. Keberadaan momen keempat diperlukan untuk mengontrol momen keada dari kesalahan kuadrat fungsi biaya.

Definisi 1. Misalkan suatu barisan distribusi F_1, F_2, \dots dengan $\varepsilon_{di} \sim F_d$, $d = 1, 2, \dots, i = 1, 2, \dots, n$ memenuhi properti berikut :

1. $E \varepsilon_{di} = 0$
2. $E \varepsilon_{di}^4 = \rho d$, dan $\forall d, \exists L, U$ s.t $0 < L \leq \rho d \leq U < \infty$.

Kami merujuk urutan di atas sebagai urutan penghasil *noise*, dan fungsi distribusi apapun dalam urutan di atas sebagai distribusi pembangkit *noise*.

Teorema berikut mencantumkan beberapa koneksi yang berguna antara matriks perbedaan biaya dan data *noise*

Teorema 1. Misalkan $Y_d = X_d + \varepsilon_d$ dan biarkan B menjadi matriks perbedaan biaya untuk dua partisi $P, Q \in \mathcal{P}_{nK}, P \neq Q$. Kemudian, untuk $Z_d = Y_d^T B Y_d$, kita memiliki hal berikut:

1. $E \varepsilon_d^T B \varepsilon_d = 0$
2. $E Z_d = X_d^T B X_d$
3. $Var(\varepsilon_d^T B \varepsilon_d) \leq K \rho_d / 2$. [18]

Linear Recurrent Formula (LRF)

Algoritma peramalan dengan *R-forecasting* adalah sebagai berikut :

1. Penaksiran koefisien LRF (r_1, r_2, \dots, r_d) digunakan *eigenvector* yang diperoleh dari langkah SVD, dengan $U = (u_1, u_2, \dots, u_{L-1}, u_L)^T$, $U^{\bar{v}} = (u_1, u_2, \dots, u_{L-1})^T$, dan π_q adalah komponen terakhir dari

eigenvector U atau dapat ditulis $\pi_q = u_L$ maka koefisien LRF dapat dihitung dengan :

$$\mathfrak{R} = (a_{L-1}, a_{L-2}, \dots, a_1)^T = \frac{1}{1-\nu^2} \sum_{q=1}^r \pi_q U^{\nu} \quad (11)$$

2. Dalam metode *R-forecasting* ini, deret waktu yang digunakan adalah deret hasil rekonstruksi yang diperoleh dari hasil *diagonal averaging*, kemudian ditentukan M buah titik baru untuk ramalan. Sehingga akan terbentuk deret hasil peramalan, yaitu $G_{N+M} = (g_1, \dots, g_{N+M})$ berdasarkan rumus di bawah ini :

$$g_i = \begin{cases} \tilde{y}_i & \text{untuk } i = 0, \dots, N \\ \sum_{j=1}^{L-1} a_j g_{i-1} & \text{untuk } i = N + 1, \dots, N + M \end{cases} \quad (12)$$

Dimana g_{N+1}, \dots, g_{N+M} adalah hasil ramalan dari SSA.[3]

Keandalan Peramalan

Untuk menguji tingkat kesalahan suatu peramalan dapat dilakukan dengan metode *Mean Absolute Error* (MAPE) dengan rumus : [4]

$$MAPE = \left(\frac{1}{n} \sum_{i=1}^N \left| \frac{g_i - \hat{g}_i}{g_i} \right| \right) \times 100\% \quad (13)$$

3. METODOLOGI

Jenis data yang digunakan adalah data sekunder yang diperoleh dari Dinas Pertanian dan Hortikultura Kabupaten Pinrang dari Tahun 2012 hingga 2020 yang dibagi menjadi data *in sample* sebanyak 24 data dari Kuartal I 2012 hingga Kuartal III 2019 dan data *out sample* sebanyak 3 data dari Kuartal I 2020 hingga Kuartal III 2020

Prosedur Analisis

Tahapan dalam proses analisis data pada penelitian ini antara lain sebagai berikut :

1. Deskripsi Data
 - a. Data Penelitian
 - b. Plot data
 - c. Struktur Data

2. Melakukan Peramalan dengan Metode *Singular Spectrum Analysis* (SSA) dilakukan dengan dua tahapan sebagai berikut :
 - a. Dekomposisi, tahap ini dibagi menjadi dua langkah yaitu :
 - 1) Embedding, pada langkah ini dibentuk matriks lintasan X berukuran $L \times K$ dari data deret waktu dengan pemilihan *Windows Length* (L) dilakukan secara *trial and error* yang memenuhi $2 < L < \frac{N}{2}$ dan $K = N - L + 1$.
 - 2) *Singular Value Decomposition* (SVD).
 - 3) Pada tahap ini, dihitung nilai *eigenvalue* dari matriks simetris $S = XX^T$
 - b. Rekonstruksi, tahap ini dibagi menjadi dua langkah yaitu :
 - 1) *Grouping*, pada tahap ini dilakukan pengelompokan *eigenvalue* berdasarkan karakteristik setiap komponen
 - 2) *Diagonal Averaging*, pada tahap ini dilakukan rekonstruksi pada masing-masing matriks yang terdapat pada matriks X_I menjadi data deret waktu yang baru dengan panjang N .
3. Menghitung hasil peramalan dari data deret waktu hasil *Diagonal averaging* dengan metode *R-forecasting*
4. Menghitung akurasi peramalan dengan menggunakan nilai *Mean Absolute Percentage Error* (MAPE)

4. PEMBAHASAN

Data penelitian

Data yang dianalisis dalam penelitian ini adalah data produksi padi permusim tanam yang disusun perkuartal yang diperoleh dari Dinas Pertanian dan Hortikultura Kabupaten Pinrang Tahun 2012 sampai Tahun 2020 yang disajikan pada Tabel 1 berikut :

Tabel 1. Data Kuartal Produksi Padi Kabupaten Pinrang

Tahun	Kuartal I	Kuartal II	Kuartal III
2012	38918	14427	38962
2013	42054	12177	42596
2014	46038	11330	39220
2015	44549	36283	23273
2016	43255	24691	38255

2017	46762	20495	39833
2018	43911	18734	43080
2019	45652	26041	33395
2020	32362	27600	48340

Sumber : Dinas Pertanian dan Hortikultura Kabupaten Pinrang

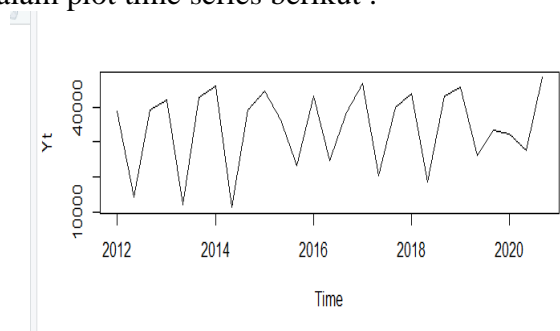
Pada Tabel 1 di atas, data produksi padi disajikan dalam satuan ton dan data tersebut tidak mengandung data hilang (*missing data*). Dari data diatas dilakukan analisis deskriptif yang ditampilkan pada Tabel 2 berikut :

Tabel 2. Deskriptif Data Produksi Padi kabupaten Pinrang

Deskripsi	Kuartal I	Kuartal II	Kuartal III
Minimum	32362	11330	23273
Maximum	46762	36283	48340
Mean	42611,22	21308,67	38550,44
Standar deviasi	4514,89	8179,67	7027,16

Plot data

Data yang akan dianalisis pada penelitian ini adalah data Kuartal produksi padi Kabupaten Pinrang dimulai dari Kuartal I Tahun 2012 sampai Kuartal III Tahun 2020 dengan jumlah observasi sebanyak 27 data yang disajikan dalam plot time series berikut :



Gambar 3. Plot *Time Series* data Produksi padi Kabupaten Pinrang

Selanjutnya untuk mengetahui apakah data stationer dapat diidentifikasi dengan menggunakan uji ADF (*Augmented Dickey-Fuller*)

Tabel 3 Nilai ADF

Statistik Uji	Nilai
Dickey Fuller	-3.9042
<i>p-value</i>	0,02786

Berdasarkan uji ADF yang diperoleh, nilai *p-value* sebesar $0.02786 < 0,05$ sehingga H_0 ditolak artinya data stationer terhadap mean.

Struktur Data

Data dibagi menjadi dua yaitu sebagai berikut :

Tabel 4. Data *in sample*

Tahun	Kuartal I	Kuartal II	Kuartal III
2012	38918	14427	38962
2013	42054	12177	42596
2014	46038	11330	39220
2015	44549	36283	23273
2016	43255	24691	38255
2017	46762	20495	39833
2018	43911	18734	43080
2019	45652	26041	33395

Tabel 5. Data *out sample*

Tahun	Kuartal I	Kuartal II	Kuartal III
2020	32362	27600	48340

Tahapan Peramalan Produksi Padi menggunakan metode *Singular Spectrum Analysis* (SSA)

Peramalan produksi padi dengan menggunakan metode SSA dilakukan dengan menggunakan dua tahapan yaitu dekomposisi dan rekonstruksi.

Dekomposisi

Pada tahap ini dilakukan dekomposisi data dengan dengan 2 langkah yaitu *embedding* dan *Singular Value Decomposition*.

Embedding

Pada tahap ini, data di Tabel 4 diubah menjadi data satu dimensi dengan jumlah data sebanyak 24 dari Kuartal I Tahun 2012 sampai

Kuartal III Tahun 2019 dengan susunan sebagai berikut :

$$\begin{bmatrix} \text{Kuartal I 2012} \\ \text{Kuartal II 2012} \\ \text{Kuartal III 2012} \\ \text{Kuartal I 2013} \\ \text{Kuartal II 2013} \\ \text{Kuartal III 2013} \\ \text{Kuartal I 2014} \\ \vdots \\ \text{Kuartal III 2019} \end{bmatrix} = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \\ x_6 \\ x_7 \\ \vdots \\ x_{24} \end{bmatrix} = \begin{bmatrix} 38918 \\ 14427 \\ 38962 \\ 42054 \\ 12177 \\ 42596 \\ 46038 \\ \vdots \\ 33395 \end{bmatrix}$$

Selanjutnya, data tersebut diubah menjadi data multidimensi yang disebut sebagai matriks lintasan X dengan dimensi $L \times K$. Penentuan nilai L berdasarkan nilai MAPE minimum dimana nilai L yang dianalisis berada di rentang adalah $2 < L < 12$ yang ditampilkan pada Tabel 6 berikut :

Tabel 6. Hasil MAPE berdasarkan Nilai

<i>Windows Length (L)</i>	
L	MAPE
3	0.1219306
4	0.07721753
5	0.1052419
6	0.1012554
7	0.06909059
8	0.0725455
9	0.04966897
10	0.06393601
11	0.08650821

Pada Tabel 6, nilai L yang menghasilkan nilai MAPE minimum berada di $L = 9$. Dari nilai L , diperoleh nilai $K = 16$ berdasarkan persamaan $K = N - L + 1$ dimana nilai $N = 24$ dan $L = 9$. Setelah diperoleh nilai $L = 9$ dan $K = 16$, maka matriks lintasan X dapat dibentuk. Proses pembentukannya adalah nilai x_1 sampai x_9 menjadi komponen kolom pertama, nilai x_2 sampai x_{10} menjadi komponen kolom kedua, nilai x_3 sampai x_{11} menjadi komponen kolom ketiga dan seterusnya hingga nilai x_{16} sampai x_{24} menjadi komponen kolom ke-16 pada matriks lintasan X yang dituliskan sebagai berikut :

$$X = \begin{bmatrix} 38918 & 14427 & 38962 & \dots & 46762 \\ 14427 & 38962 & 42054 & \dots & 20495 \\ 38962 & 42054 & 12177 & \dots & 39833 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 39220 & 44549 & 36383 & \dots & 33395 \end{bmatrix}$$

Singular Value Decomposition

Pada tahap ini dilakukan perhitungan untuk mencari nilai *eigen triple* berdasarkan matriks lintasan $X_{(9 \times 16)}$. Langkah awal yang dilakukan yaitu membentuk matriks simetris $S = XX^T$ sebagai berikut:

$$S = X_{(9 \times 16)} \cdot X_{(16 \times 9)}^T$$

$$S = \begin{bmatrix} 20731570896 & 16694375477 & 17802267051 & \dots & 18586892281 \\ 16694375477 & 19637005197 & 16949282826 & \dots & 18260272383 \\ 17802267051 & 16949282826 & 21015534757 & \dots & 20368714790 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 8586892281 & 18260272383 & 20368714790 & \dots & 21530883395 \end{bmatrix}$$

Setelah diperoleh matriks simetris $S_{(9 \times 9)}$ selanjutnya dihitung nilai-nilai *eigen triple* :

Singular Value ($\sqrt{\lambda_i}$)

Dari matriks simetris $S_{(9 \times 9)}$ tersebut dihitung nilai *eigenvalue* dan selanjutnya dari nilai *eigenvalue* dihitung nilai *singular value* yang hasilnya ditampilkan pada Tabel 7 berikut:

Tabel 7. Nilai *Eigenvalues* dan *Singular Values*

No	<i>Eigenvalues</i>	<i>Singular values</i>
1	170026782005	412343.039
2	7802003224	88328.949
3	6460090155	80374.686
4	1320236739	36335.062
⋮	⋮	⋮
9	61756631	7858.539

Eigenvector (U_i)

Setelah mendapatkan nilai *singular value* maka selanjutnya dihitung nilai *eigenvector* yang hasilnya disajikan pada Tabel 8 berikut :

Tabel 8 Nilai *Eigenvectors*

No	U_1	U_2	...	U_9
1	-0.3306301	-0.358027981	...	0.201478915
2	-0.3184183	0.470469031	...	0.393777554
3	-0.3323872	-0.078945938	...	0.477150748
⋮	⋮	⋮	⋮	⋮
9	-0.3439137	-0.005670194	...	-0.212892235

Principal Component (V_i)

Selanjutnya dihitung nilai *principal component* yang hasilnya disajikan sebagai berikut :

Tabel 9 Nilai *Principal component*


No	V_1	V_2	...	V_9
1	-0.2328786	-0.41197213	...	-0.073596044
2	-0.2348768	0.36474686	...	-0.061733382
3	-0.2523570	0.12898307	...	-0.401562108
⋮	⋮	⋮	⋮	⋮
16	-0.2582387	-0.32171529	...	-0.025939080

Rekonstruksi

Pada tahap ini dilakukan rekonstruksi data hasil SVD dengan 2 langkah yaitu *grouping* dan *diagonal averaging* yaitu sebagai berikut :

Grouping

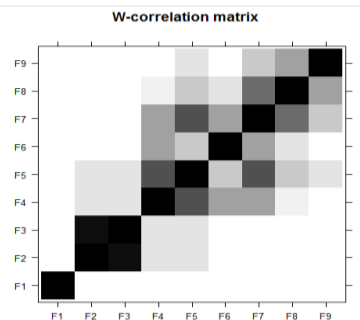
Pada tahap ini dilakukan pengelompokan *eigen triple* hasil SVD berdasarkan karakteristik setiap komponen yang dimiliki. Untuk menentukan anggota-anggota dari grup dilakukan dengan melihat plot dari *eigenvector*. Berikut ditampilkan plot dari *eigenvector* dengan nilai = 1,2, ...,9 :



Gambar 4. Plot *Eigenvector* Data

Dari Gambar 4 dapat dilihat bahwa komponen pertama adalah *trend* dan komponen lainnya mengandung pola musiman dan *noise*. *Grouping* yang dilakukan dengan menggunakan

plot *eigenvector* bersifat subjektif. Terdapat beberapa plot yang memiliki pola yang sama dan sulit membedakan karakteristiknya. Untuk melihat kesamaan karakteristik antar komponen dengan lebih jelas dapat dilihat dari plot *W-correlation*. Plot *W-correlation* ditampilkan sebagai berikut :



Gambar 5. Plot *W-correlation*

Dari Gambar 5 dilihat bahwa dari 9 komponen yang dimiliki dapat dikelompokkan menjadi 7 grup berdasarkan tinggi rendahnya korelasi setiap grup. Tinggi rendahnya korelasi dapat dilihat dari gelap terangnya irisan antar komponen F1 sampai F9. Dari plot *eigenvector* dan plot *W-correlation* di atas, maka grup yang dapat dibentuk adalah sebagai berikut :

Tabel 10. Hasil *Grouping*

Komponen	Grup
1	1
2,3	2
4	3
6	4
5,7	5
8	6
9	7

Dari Tabel 10 diperoleh 7 matriks dari 9 komponen yang berbeda. 7 grup tersebut merupakan matriks ($X_{11}, X_{12}, \dots, X_{17}$) yang masing-masing berukuran 9×16 yaitu sebagai berikut :

$$X_{11} = \begin{bmatrix} 31749.05 & 32021.46 & 34404.60 & \dots & 35206.46 \\ 30576.40 & 30838.75 & 33133.86 & \dots & 33906.11 \\ 31917.77 & 32191.63 & 34587.43 & \dots & 35393.56 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 33024.62 & 33307.98 & 35786.86 & \dots & 36620.94 \end{bmatrix}$$

$$X_{12} = \begin{bmatrix} 9092.686 & -20165.619 & 6429.144 & \dots & 9135.317 \\ -19199.842 & 10596.199 & 10913.413 & \dots & -13918.140 \\ 9450.133 & 11880.651 & -18461.048 & \dots & 3979.278 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 4796.558 & 9883.647 & -12320.542 & \dots & 1372.574 \end{bmatrix}$$

$$X_{17} = \begin{bmatrix} -116.526814 & 97.744308 & 635.80528 & \dots & 41.070120 \\ 227.744148 & 191.034949 & 1242.64044 & \dots & 80.268902 \\ 275.963648 & 231.482135 & 1505.74051 & \dots & 97.263966 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 123.127792 & 103.281299 & 671.82219 & \dots & 43.396648 \end{bmatrix}$$

Diagonal Averaging

Dari langkah sebelumnya, diperoleh 7 matriks yang mewakili karakteristik setiap komponen. Setiap matriks tersebut akan diubah menjadi data deret waktu yang baru menurut masing-masing karakteristik yang dimiliki. Hasil *diagonal averaging* dari 7 matriks tersebut adalah sebagai berikut:

Tabel 11 Hasil *diagonal averaging*

No	Grup 1	Grup 2	Grup 3	...	Grup 7
1	31798.30	9549.9322	-3236.7268	...	-347.771928
2	31425.44	20099.8619	3023.6333	...	-489.314766
3	32513.90	8960.9442	-1203.3222	...	-768.433270
⋮	⋮	⋮	⋮	⋮	⋮
27	36842.56	3678.3002	-798.5534	...	-803.564953

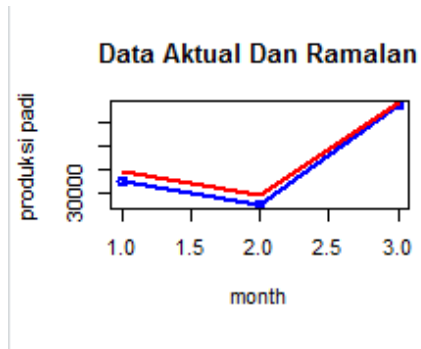
Menghitung Hasil Peramalan dari Data Deret Waktu Hasil *Diagonal averaging* dengan metode *R-forecasting*

Setelah diperoleh 7 grup hasil *diagonal averaging*, maka langkah selanjutnya adalah melakukan peramalan pada data *out sample* dengan menggunakan metode *R-forecasting*. Berikut ditampilkan hasil ramalan data *out sample*:

Tabel 12. Hasil peramalan pada data *out sample*

Tahun	Kuartal	Data Aktual	Data Ramalan	Selisih
2020	kuartal I	32362	34539	2177
	kuartal II	27600	29536	1936
	kuartal III	48340	48901	561

Dari Tabel 12 terlihat selisih antara data aktual dengan data ramalan cukup kecil. Untuk melihat perbandingan antara keduanya juga dapat disajikan dalam bentuk plot yaitu sebagai berikut :



Gambar 6. Plot Data Aktual dan Ramalan

Pada Gambar 6, terlihat bahwa hasil plot data aktual dan ramalan memiliki pola perulangan yang hampir sama, dimana data ramalan mendekati data aktual.

Akurasi Peramalan

Akurasi peramalan metode SSA pada penelitian ini menggunakan metode *Mean Absolute Percentage error* (MAPE) untuk data *out sample* yang disajikan dalam Tabel 13 berikut :

Tabel 13. Nilai MAPE pada Hasil Peramalan Data *Out Sample*

Tahun	Kuartal	Data Aktual	Data Ramalan	Error
2020	kuartal I	32362	31953,539	0.06725588
	kuartal II	27600	27170,992	0.07013644
	kuartal III	48340	48241,031	0.01161457
Total Error				0.14900689
<i>Mean Absolute Percentage Error (MAPE)</i>				0.04966897

Dari Tabel 13 terlihat nilai error antara data aktual dengan data ramalan cukup kecil. Dilihat dari nilai MAPE yang diperoleh sebesar 0.0497 atau 4.97 %. Sebagaimana dikemukakan oleh Desy Tresnowati Hardi bahwa peramalan dikatakan akurat jika Nilai MAPE kurang dari 10 % dan mendekati 0 %. Maka hal tersebut menunjukkan bahwa hasil peramalan dengan metode SSA dengan *windows length* 9 sangat akurat untuk meramalkan produksi padi Kabupaten Pinrang. Oleh karena itu, dengan *windows length* 9 dilakukan peramalan pada produksi padi tahun 2021. Hasil peramalannya adalah sebagai berikut:

Tabel 14 . Hasil ramalan produksi padi tahun 2021

Kuartal	Hasil Ramalan
Kuartal I	33603
Kuartal II	25988
Kuartal III	43234

5. KESIMPULAN

Berdasarkan hasil dari penelitian maka dapat disimpulkan bahwa hasil peramalan produksi padi Kabupaten Pinrang pada Tahun 2021 dengan metode *Singular Spectrum Analysis* (SSA) masing –masing dari Kuartal I sampai Kuartal III sebesar 33603 ton, 25988 ton, dan 43234 ton dengan tingkat akurasi peramalan berdasarkan standar nilai MAPE diperoleh sebesar 4.97 %.

6. DAFTAR PUSTAKA

- [1] Lubiz, Deltha A. (2017). *Peramalan Indeks Harga konsumen dengan Metode Singular Spectrum Analysis (SSA) dan Seasonal Autoregressive Integrated Moving Average (SARIMA)*. (Jurnal Matematika MANTIK, Vol 03 No.02)
- [2] Asrof, Asnafiyah dkk. (2017). *Peramalan Produksi Cabai Merah di Jawa Barat Menggunakan Metode Singular Spectrum Analysis (SSA)*.(Jurnal Statistika Vol.17 No.2)
- [3] Jatmiko, yogo Aryo, dkk (2017), *Perbandingan Keakuratan Hasil Peramalan Produksi Bawang Merah Metode Holt Winter dengan Singular Spectrum Analysis*. (Jurnal Matematika “MANTIK” Vol 03, No.01)
- [4] Hardi, Desy Tresnowati. (2019). *Peramalan Produk Domestik Bruto (PDB) Sektor Pertanian, Kehutanan, dan Perikanan Menggunakan Singular Spectrum Analysis (SSA)*. (Jurnal Gaussian, Volume 8, Nomor 1)
- [5] Tarigan, Senang ukurta. (2018). *Peramalan Data Menggunakan Singular Spectrum Analysis dengan Metode Peramalan Linear Recurrent Formula*. (Yogyakarta : Program Studi Statistika UGM)
- [6] Sitohang, Yoseph O., & Darmawan, Gumgum.(2017). *Perbandingan Akurasi Recurrent Forecasting dan Vector Forecasting pada Metode Peramalan Jumlah Wisatawan Mancanegara yang Masuk Melalui bandara Ngurah Rai Bali Tahun 2017*. (Jurnal Euclid Vol. 5 No. 1)
- [7] Darmawan, Gumgum (2016). *Identifikasi Pola Data Curah Hujan pada Proses Grouping dalam Metode Singular Spectrum Analysis*. (Seminar Nasional Pendidikan Matematika)
- [8] Briceno, Hector., dkk. (2013). *Singular Spectrum Analysis for Forecasting of Electric Load Demand*. (Jurnal Chemical Engineering Transaction, Vol.33)
- [9] Kalantari, Mahdi. (2021). *Forecasting COVID-19 Pandemic Using Optimal Singular Spectrum Analysis*. (Jurnal Chaos, Solition and Fractals : Nonlinear Science, and Nonequilibrium and Complex Phenomena)
- [10] Leon, Steven J. (1998). *Linear Algebra with Aplication Fifith Edition*. (Prenticehall, United States)
- [11] Aswi dan Sukarna, (2006). *Analisis Deret Waktu*. (Makassar:Andira Publisher).
- [12] George E.P, Box dkk. (2008). *Time Series Analysis Forecasting and Control*. (Canada: John Wiley & Sons)
- [13] Sainah, Awit Marwati. (2018). *Akurasi Peramalan Long Horizon dengan Singular Spectrum Analysis* (eJurnal of Sunan gunung Jati State Islmaic University (UIN) Vol. 3 No.2)
- [14] Khaeri, Hirlan, dkk. (2017). *Penerapan Metode Singular Spectrum Analysis (SSA) pada Peramalan Jumlah Kereta Api di Indonesia Tahun 2017*. (jurnal Euclid, Vol. 5 No. 1)
- [15] Ariyanti, Gregoria. (2010). *Dekomposisi Nilai Singular dan Aplikasinya*. (Yogyakarta : Seminar Nasional Matematika dan Pendidikan Matematika)
- [16] Golyandina dan Zhigljavsky. (2013). *Singular Spectrum Analysis for Time Series*. STAT ME.
- [17] Andika, Gilang Bimasakti (2010). *Peramalan Nilai Tukar Petani menggunakan meode Singular Spectrum Analysis*, (Denpasar : Program Studi Matematika Udayana)
- [18] Koepke, H.A., & Clarke, B.S. (2010). *On the limits of Clustering in High Dimension Via Cost Function*. (Jurnal Staistical and Data Mining,4)