

PERAMALAN NILAI TUKAR PETANI MENGGUNAKAN METODE SINGULAR SPECTRUM ANALYSIS

Gilang Bimasakti Andhika^{1§}, I Wayan Sumarjaya², I Gusti Ayu Made Srinadi³

¹Program Studi Matematika, Fakultas MIPA – Universitas Udayana [Email: gilang.1316@gmail.com]

²Program Studi Matematika, Fakultas MIPA – Universitas Udayana [Email: sumarjaya@unud.ac.id]

³Program Studi Matematika, Fakultas MIPA – Universitas Udayana [Email: srinadi@unud.ac.id]

[§]Corresponding Author

ABSTRACT

Singular spectrum analysis (SSA) is a new method in time series analysis that uses a nonparametric approach. The purpose of this study is to determine the model and forecast the farmer exchange rate in the Province of Bali using SSA. Vector singular spectrum analysis (VSSA) forecasting method is used to calculate the accuracy of forecasting. The best SSA model is obtained with a window length (L) value of 57 and produces a MAPE value of 0.49%. In conclusion, SSA method can predict farmer exchange rate in the Province of Bali very accurate.

Keywords: farmer exchange rate, singular spectrum analysis, VSSA

1. PENDAHULUAN

Indonesia dikenal sebagai negara agraris yang sebagian besar penduduknya bekerja pada sektor pertanian. Kebutuhan pangan yang diperoleh dari sektor pertanian sangatlah penting bagi kelangsungan hidup penduduk, sehingga kesejahteraan para petani perlu diperhatikan.

Nilai tukar petani (NTP) adalah salah satu indikator untuk mengukur tingkat kesejahteraan petani. NTP merupakan perbandingan antara indeks harga yang diterima petani (I_t) dan indeks harga yang dibayar petani (I_b) (BPS Bali, 2018). Dalam mengukur kesejahteraan petani, diharapkan I_t meningkat sedangkan I_b menurun. Sehingga peramalan diperlukan untuk mengetahui potensi sektor pertanian ke depannya.

Terdapat banyak metode untuk meramal yang telah berkembang dalam metode deret waktu, salah satunya adalah metode *singular spectrum analysis* (SSA). SSA adalah metode baru dalam analisis deret waktu yang menggabungkan elemen analisis deret waktu klasik, statistika multivariat, geometri multivariat, sistem dinamik, dan pemrosesan sinyal. Tujuan SSA adalah mendekomposisi data asli menjadi sejumlah kecil komponen independen sehingga dapat lebih mudah untuk diinterpretasi (Hassani, 2007).

Penelitian terdahulu tentang SSA telah dilakukan antara lain oleh peneliti-peneliti berikut. Sakinah (2018) meneliti akurasi peramalan *long horizon* dengan *recurrent SSA* (RSSA) dan *vector SSA* (VSSA) yang menghasilkan *mean absolute percentage error* (MAPE) secara berturut-turut 5,0029 dan 4,0067. Sari dkk. (2019) meramalkan jumlah kunjungan wisatawan mancanegara ke Bali dan menghasilkan model SSA terbaik dengan *window length (L)* 94 dan MAPE sebesar 7,65%.

Pada penelitian ini penulis menggunakan metode SSA untuk memodelkan dan mengetahui hasil peramalan NTP di Provinsi Bali.

2. METODE PENELITIAN

2.1 Jenis dan Sumber Data

Jenis data yang digunakan adalah data sekunder yang diperoleh dari Badan Pusat Statistik Provinsi Bali. Data yang digunakan adalah data bulanan dari periode Januari 2008 hingga Desember 2019 yang dibagi menjadi dua yaitu data *in-sample* sebanyak 132 data yaitu periode Januari 2008 hingga Desember 2018 dan data *out-sample* sebanyak 12 data yaitu periode Januari 2019 hingga Desember 2019.

2.2 Metode Analisis Data

Langkah-langkah yang digunakan untuk menganalisis dengan bantuan program R 3.6.2 adalah sebagai berikut:

1. Mempersiapkan data *in-sample* nilai tukar petani di Provinsi Bali.
2. Menyusun data menjadi bentuk data deret waktu.
3. Melakukan plot data untuk mengetahui pola data.
4. Tahap dekomposisi. Tahap ini dibagi menjadi dua langkah yaitu:

a. *Embedding*

Pada langkah ini, dibentuk matriks lintasan \mathbf{X} berukuran $L \times K$ dari data deret waktu. Pemilihan *Window length* (L) dilakukan secara coba-coba (*trial and error*) yang memenuhi $2 \leq L \leq \frac{N}{2}$ dengan $N = 132$ dan $K = N - L + 1$.

b. *Singular value decomposition* (SVD)

Langkah ini mendekomposisi matriks lintasan \mathbf{X} sebanyak d matriks dengan $d = \max\{i, \lambda_i > 0\}$. Masing-masing matriks hasil dekomposisi ($\mathbf{X}_1, \dots, \mathbf{X}_d$) dapat dinyatakan sebagai $\mathbf{X}_i = \sqrt{\lambda_i} U_i V_i^T$. Kumpulan $(\sqrt{\lambda_i}, U_i, V_i^T)$ merupakan *eigen triple* matriks \mathbf{X}_i .

5. Tahap rekonstruksi. Tahap ini dibagi menjadi dua langkah yaitu:

a. *Grouping*

Pada langkah ini, dikelompokkan matriks hasil dekomposisi yang telah dipartisi, kemudian menjumlahkan setiap kelompok matriks yang dinyatakan $\mathbf{X} = \mathbf{X}_{I_1} + \dots + \mathbf{X}_{I_m}$. Selanjutnya mengelompokkan komponen tren, musiman, dan *noise* menggunakan plot nilai *singular*. Dari plot nilai *singular* diperoleh r yang digunakan untuk membatasi jumlah *eigen triple*. *Eigen triple* digunakan untuk mengidentifikasi komponen tren dan musiman. Komponen tren dapat dilihat dari *eigen triple* yang bervariasi lambat, sedangkan komponen musiman dilihat berdasarkan kemiripan dari dua *eigen triple* yang berurutan. Melakukan ESPRIT pada setiap dua *eigen triple* berurutan yang terpilih. Dari hasil ESPRIT dipilih pasangan *eigen triple* yang memiliki periode musiman sebesar 12, 6, 4, 3, 2 untuk dikelompokkan ke dalam komponen musiman.

b. *Diagonal Averaging*

Pada langkah akhir ini, dibentuk deret baru dengan panjang N menjadi deret yang sesuai terhadap masing-masing hasil *grouping* komponen tren dan musiman.

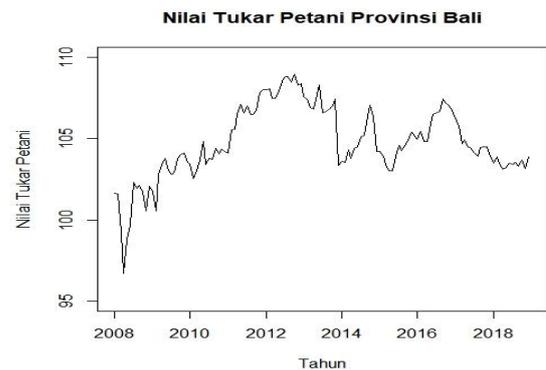
6. Membentuk model SSA dengan mencari koefisien tren dan koefisien musiman dari hasil *diagonal averaging* menggunakan

$$= \begin{cases} Z_i & \\ \tilde{X}_i, & i = 1, \dots, K. \\ \theta^{(v)} Z_{i-1}, & i = K + 1, \dots, K + h + L - 1. \end{cases}$$

7. Melakukan peramalan menggunakan VSSA.
8. Menghitung tingkat *error* peramalan menggunakan MAPE.
9. Menginterpretasi hasil peramalan dan menarik kesimpulan.

3. HASIL DAN PEMBAHASAN

Bagian ini membahas penerapan metode SSA untuk meramalkan NTP di Provinsi Bali. Berikut hasil plot data NTP di Provinsi Bali.



Gambar 1. Plot Data Nilai Tukar Petani di Provinsi Bali periode Januari 2008 hingga Desember 2019

Gambar 1 memperlihatkan bahwa pada tiga tahun awal terdapat pola tren naik. Pada tahun selanjutnya terlihat pola tren cenderung menurun, hal ini disebabkan harga konsumsi dan biaya produksi lebih besar dibandingkan dengan harga produksi. Selain itu, terdapat pola berulang yang mengindikasikan adanya pola musiman pada data.

3.1 Dekomposisi

Langkah awal dalam tahap dekomposisi adalah *embedding*. Pertama dilakukan pemilihan nilai *window length* (L) secara coba-coba (*trial and error*). Pada penelitian ini banyak data yang digunakan sebanyak 132

data. Oleh karena itu nilai L yang memenuhi adalah $2 < L < 66$. Dilakukan coba-coba nilai $L = 55, 56, 57, 58, 59$ kemudian diperoleh nilai MAPE berturut-turut 0,501%, 0,502%, 0,49%, 0,504%, 0,51%.

Nilai L yang dipilih setelah dilakukan proses coba-coba yaitu $L = 57$ dan $K = 76$. Pemilihan nilai L didasarkan pada nilai MAPE minimum yaitu sebesar 0,49%. Dengan demikian, matriks lintasan \mathbf{X} dapat disusun sebagai berikut:

$$\mathbf{X} = [X_1: \dots : X_{76}] = (x_{ij})_{i,j=1}^{57,76} = \begin{pmatrix} 101,63 & 101,57 & \dots & 103,8 \\ 101,57 & 99,24 & \dots & 104,4 \\ \vdots & \vdots & \ddots & \vdots \\ 108,46 & 108,93 & \dots & 103,87 \end{pmatrix}$$

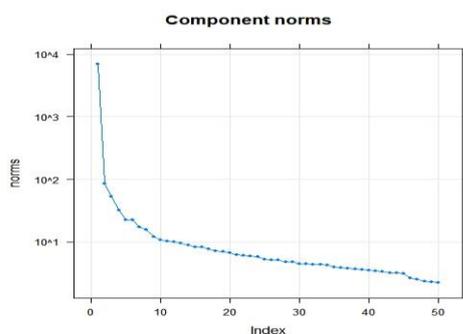
Langkah selanjutnya yaitu SVD dengan mendekomposisi matriks lintasan \mathbf{X} menjadi 50 *eigen triple* yang terdiri dari 50 nilai eigen dan 50 vektor eigen.

3.2 Rekonstruksi

Terdapat dua langkah dalam tahap rekonstruksi yaitu *grouping* dan *diagonal averaging*.

3.2.1 Pengelompokan Komponen Noise

Langkah awal dalam tahap rekonstruksi adalah mengelompokkan *eigen triple* menjadi komponen tren, musiman, dan *noise*. *Grouping effects* (r) merupakan parameter dalam langkah *grouping* yang berguna untuk membatasi jumlah *eigen triple* yang akan digunakan saat mengidentifikasi komponen tren dan musiman. Nilai r ditentukan berdasarkan jumlah *eigen triple* yang tidak mencerminkan *noise* pada plot nilai *singular*.



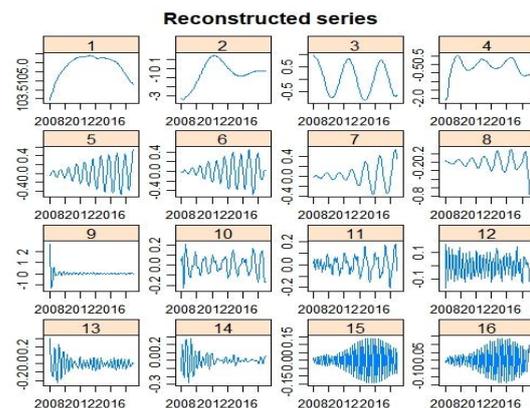
Gambar 2. Plot Nilai Singular

Gambar 2 menunjukkan plot nilai *singular* dari 50 *eigen triple*. Terlihat nilai *singular* mulai menurun secara lambat dari *eigen triple* 17. Hal ini menyebabkan *eigen triple* 17 hingga

eigen triple 50 diidentifikasi sebagai komponen *noise*, sehingga nilai r adalah 16. Dengan demikian, banyak *eigen triple* yang akan digunakan untuk mengidentifikasi komponen tren dan musiman adalah enam belas *eigen triple*. Dari enam belas *eigen triple* terdapat kemungkinan ada *eigen triple* yang mencerminkan komponen *noise*, hal ini dapat diketahui dari sisa *eigen triple* yang tidak mencerminkan komponen tren dan musiman.

3.2.2 Pengelompokan Komponen Tren dan Musiman

Eigen triple yang akan digunakan untuk mengidentifikasi komponen tren dan musiman adalah sebanyak enam belas *eigen triple*. Enam belas *eigen triple* yang digunakan untuk mengidentifikasi komponen tren dan musiman terdiri dari *eigen triple* 1,2,3,...,16. Dalam mengidentifikasi *eigen triple* yang berhubungan dengan tren dan musiman dapat menggunakan plot deret yang direkonstruksi.

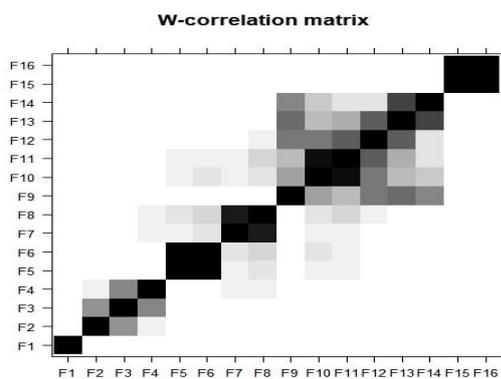


Gambar 3. Plot Deret yang Direkonstruksi

Gambar 3 memperlihatkan bahwa deret yang direkonstruksi oleh *eigen triple* 1 dan *eigen triple* 2 memuat komponen yang bervariasi lambat. Oleh karena itu, *eigen triple* 1 dan *eigen triple* 2 dikelompokkan ke dalam komponen tren. Selanjutnya dilakukan pengelompokan *eigen triple* ke dalam komponen musiman yang dilakukan berdasarkan kemiripan *eigen triple* yang berurutan. Pada plot deret yang direkonstruksi, kemiripan *eigen triple* mengakibatkan deret yang direkonstruksi memiliki pola dan periode musiman yang sama.

Pada Gambar 3 terlihat beberapa pasang *eigen triple* berurutan yang memiliki kemiripan pola yaitu *eigen triple* 5 dan 6, *eigen triple* 7 dan 8, *eigen triple* 10 dan 11, serta *eigen triple*

15 dan 16. Dengan ESPRIT diperoleh deret yang direkonstruksi *eigentriple* 15 dan 16 memiliki periode musiman yang sama yakni empat sehingga dikelompokkan ke dalam komponen musiman. Selanjutnya, deret yang direkonstruksi *eigentriple* 5 dan 6 memiliki periode musiman yang sama yakni tiga belas. Meskipun deret yang direkonstruksi oleh *eigentriple* 5 dan 6 memiliki periode musiman yang sama, tetapi kedua *eigentriple* tersebut tidak dapat dikelompokkan ke dalam komponen musiman. Hal ini dikarenakan periode musiman kedua deret tersebut tidak dapat diinterpretasikan untuk data bulanan.



Gambar 4. Plot Keterpisahan (*W-correlation*)

Selain melihat plot deret yang direkonstruksi, proses identifikasi *eigentriple* yang mencerminkan komponen tren dan musiman dapat dilihat pada plot keterpisahan (*w-correlation*). Plot keterpisahan (*w-correlation*) ini digunakan untuk melihat besarnya korelasi antar *eigentriple*. Semakin tua warnanya maka semakin tinggi korelasinya. Plot keterpisahan (*w-correlation*) dari enam belas *eigentriple* ditunjukkan pada Gambar 4.

Gambar 4 memperlihatkan pasangan *eigentriple* 5 dan 6, *eigentriple* 7 dan 8, *eigentriple* 10 dan 11, serta *eigentriple* 15 dan 16 memiliki korelasi yang kuat. Akan tetapi, untuk mengidentifikasi komponen musiman tidak dapat ditentukan hanya dengan melihat plot. Sehingga digunakan ESPRIT untuk mencari periode musiman dari deret yang direkonstruksi dari dua *eigentriple*. Tabel 1 menyajikan secara lengkap pasangan *eigentriple* beserta periode musimannya.

Tabel 1 *Eigentriple* dan Periode Musiman

| <i>Eigentriple</i> | Periode | <i>Eigentriple</i> | Periode |
|--------------------|---------|--------------------|---------|
| 5 | 13 | 10 | 47 |
| 6 | 13 | 11 | 47 |
| 7 | 21 | 15 | 4 |
| 8 | 21 | 16 | 4 |

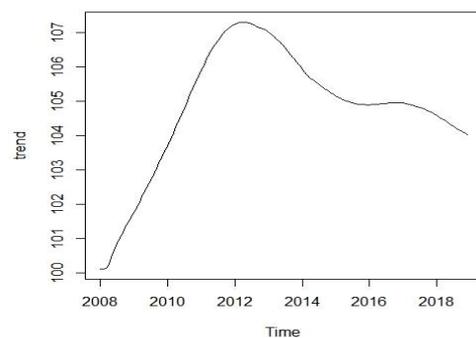
Sumber: *Data diolah, 2020*

Pasangan *eigentriple* yang memiliki periode musiman yang sama dapat diinterpretasikan untuk data bulanan berdasarkan Tabel 1 adalah *eigentriple* 15, dan 16. Sehingga, *eigentriple* 15, dan 16 dapat dikelompokkan ke dalam kelompok komponen musiman.

Eigentriple yang dikelompokkan ke dalam kelompok komponen tren adalah *eigentriple* 1 dan 2. Selanjutnya *eigentriple* yang dikelompokkan ke dalam kelompok komponen musiman adalah *eigentriple* 15, dan 16. Terakhir, *eigentriple* yang tidak dikelompokkan ke dalam kelompok komponen tren dan musiman merupakan kelompok komponen *noise*.

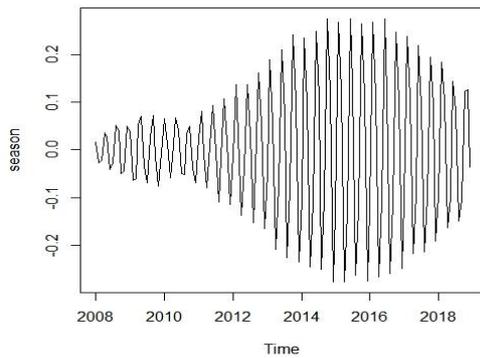
3.2.3 *Diagonal Averaging*

Langkah selanjutnya yaitu *diagonal averaging*. Masing-masing komponen direkonstruksi menggunakan *eigentriple* yang terkait. Pada penelitian ini, komponen tren direkonstruksi oleh *eigentriple* 1 dan 2. Plot hasil dari komponen tren yang direkonstruksi adalah sebagai berikut.



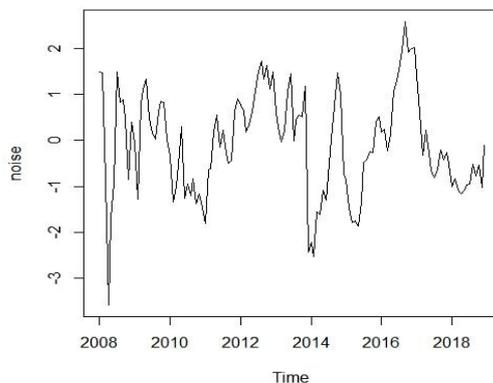
Gambar 5. Komponen Tren yang Direkonstruksi

Selanjutnya komponen musiman direkonstruksi oleh *eigentriple* 15, dan 16. Plot hasil dari komponen musiman yang direkonstruksi dapat dilihat pada Gambar 6.



Gambar 6. Komponen Musiman yang Direkonstruksi

Sedangkan plot hasil dari komponen *noise* yang direkonstruksi dapat dilihat pada Gambar 7.



Gambar 7. Komponen *Noise* yang Direkonstruksi

3.3 Peramalan

Saat seluruh komponen berhasil dipisahkan, maka langkah selanjutnya adalah melakukan peramalan terhadap komponen tren dan musiman. Metode yang digunakan untuk meramalkan komponen tren dan musiman adalah *vector singular spectrum analysis* (VSSA). Data *in-sample* sebanyak $N = 132$, sehingga peramalan dengan data *out-sample* pada selang $h = 12$ yakni $\tilde{X}_{133}, \dots, \tilde{X}_{144}$ diperoleh rumus *vector* sebagai berikut:

$$Z_i = \begin{cases} \tilde{X}_i, & i = 1, \dots, 76. \\ \theta^{(v)} Z_{i-1}, & i = 77, \dots, 144. \end{cases}$$

dengan Z_1, \dots, Z_{144} merupakan nilai-nilai dari deret rekonstruksi dan $\theta^{(v)}$ merupakan koefisien dari VSSA.

Model SSA untuk meramalkan komponen tren dapat ditulis sebagai berikut:

$$Z_i^T = 101,69Z_1^T + 101,75Z_2^T + \dots + 104,2Z_{63}^T.$$

Selanjutnya, model SSA untuk meramalkan komponen musiman dapat ditulis sebagai berikut:

$$Z_i^S = 0,024Z_1^S - 0,022Z_2^S + \dots - 0,1Z_{63}^S.$$

Nilai ramalan data *out-sample* secara keseluruhan diperoleh dari penjumlahan nilai ramalan data *out-sample* dari komponen tren dan komponen musiman. Secara matematis, model SSA untuk memperoleh nilai ramalan data *out-sample* secara keseluruhan dapat ditulis sebagai berikut:

$$Z_i = Z_i^T + Z_i^S, \text{ untuk } i = 132, \dots, 144.$$

Setelah diperoleh model SSA yang digunakan untuk melakukan peramalan, maka langkah selanjutnya melakukan peramalan pada data *out-sample* berdasarkan model yang diperoleh. Akurasi hasil peramalan pada data *out-sample* diukur dengan nilai MAPE yang merupakan nilai rata-rata persentase kesalahan dari beberapa periode. Tabel 2 menyajikan hasil peramalan data *out-sample* dari komponen tren dan musiman untuk dua belas bulan ke depan.

Tabel 2. Hasil Peramalan Data *Out-Sample* dari Komponen Tren dan Musiman

| Bulan | Hasil Ramalan | Data Aktual | Persentase Kesalahan |
|----------------------------|---------------|-------------|----------------------|
| Januari | 104,13 | 103,65 | 0,00458 |
| Februari | 104,18 | 103,98 | 0,00190 |
| Maret | 104,25 | 104,10 | 0,00143 |
| April | 104,14 | 103,40 | 0,00711 |
| Mei | 103,99 | 103,30 | 0,00667 |
| Juni | 104,02 | 103,50 | 0,00499 |
| Juli | 104,09 | 104,80 | 0,00679 |
| Agustus | 103,99 | 104,65 | 0,00625 |
| September | 103,85 | 104,14 | 0,00281 |
| Oktober | 103,85 | 103,66 | 0,00183 |
| November | 103,92 | 104,35 | 0,00413 |
| Desember | 103,85 | 104,93 | 0,01033 |
| Total Persentase Kesalahan | | | 0,05885 |
| MAPE | | | 0,00490 |

Sumber: *Data diolah, 2020*

Menurut Zhang dkk. (2015) nilai MAPE yang kurang dari 10% menunjukkan bahwa peramalan sangat akurat. Berdasarkan Tabel 2, diperoleh nilai MAPE pada data *out-sample* sebesar 0,0049 atau 0,49%. Dengan demikian, dapat disimpulkan bahwa metode SSA dengan $L = 57$ dapat meramalkan nilai tukar petani di Provinsi Bali dengan sangat akurat.

4. SIMPULAN DAN SARAN

Berdasarkan hasil dan pembahasan, diperoleh model SSA yang digunakan untuk meramalkan komponen tren dua belas bulan ke depan yaitu sebagai berikut:

$$Z_i^T = 101,69Z_1^T + 101,75Z_2^T + \dots + 104,2Z_{63}^T.$$

Kemudian model SSA yang digunakan untuk meramalkan komponen musiman dua belas bulan ke depan dapat ditulis sebagai berikut:

$$Z_i^S = 0,024Z_1^S - 0,022Z_2^S + \dots - 0,1Z_{63}^S.$$

Model tersebut merupakan model SSA terbaik dengan nilai *window length* $L = 57$ serta nilai MAPE sebesar 0,49%. Hal ini menunjukkan bahwa metode SSA dapat meramalkan nilai tukar petani di Provinsi Bali dengan sangat akurat.

Saran untuk penelitian selanjutnya yaitu pada proses pengelompokan komponen tren dan musiman dapat menambahkan atau menggunakan cara lain seperti analisis periodogram dan *pairwise scatterplot*.

DAFTAR PUSTAKA

- Badan Pusat Statistik Provinsi Bali. 2018. *Indeks Nilai Tukar Petani Provinsi Bali 2018*. Badan Pusat Statistik Provinsi Bali. Denpasar: BPS Provinsi Bali.
- Hassani, Hossein. 2007. "Singular Spectrum Analysis: Methodology and Comparison." *Journal of Data Science* 5: 239–257.
- Sakinah, Awit Marwati. 2018. "Akurasi Peramalan Long Horizon Dengan Singular Spectrum Analysis." *Kubik* 3(2): 93–99.
- Sari, Mira Ayu Novita, I Wayan Sumarjaya, and Made Susilawati. 2019. "Peramalan Jumlah Kunjungan Wusatawan Mancanegara Ke Bali Menggunakan Metode Singular Spectrum Analysis." *E-Jurnal Matematika* 8(4): 303–308.
- Zhang, Tailei, Kai Wang, and Xueliang Zhang. 2015. "Modeling and Analyzing the Transmission Dynamics of HBV Epidemic in Xinjiang, China." *PLoS ONE* 10(9): 1–14.