

PREDIKSI *OUTFLOW* UANG KARTAL DI KALIMANTAN BARAT DENGAN METODE *SINGULAR SPECTRUM ANALYSIS (SSA)*

Ageng Wicaksono, Helmi, Yundari

INTISARI

Uang merupakan komponen penting dalam perekonomian yang digunakan sebagai alat pembayaran dalam melakukan transaksi jual dan beli. Banyaknya uang yang beredar di masyarakat berpengaruh pada kondisi perekonomian suatu negara. Dalam kewenangan untuk mengatur transaksi arus keluar/masuk uang kartal, diperlukan Rencana Kebutuhan Uang (RKU). Banyak aspek yang menjadi dasar pembuatan RKU, salah satunya data historis aliran uang masuk (inflow) dan aliran uang keluar (outflow). Agar perencanaan tersebut tepat maka peramalan outflow sangat diperlukan. Data outflow pada umumnya memuat pola musiman dan trend sehingga dapat dimodelkan dengan analisis deret waktu. Metode SSA merupakan metode yang menggunakan pendekatan nonparametrik. Artinya dalam pengaplikasiannya, metode ini tidak membutuhkan uji asumsi-asumsi parametrik. Metode SSA menguraikan data deret waktu ke dalam komponen-komponen, yaitu trend, musiman, siklis dan noise. Pada penelitian ini metode SSA yang digunakan adalah metode recurrent (R-forecasting). Penelitian ini dilakukan dengan mengelompokkan data sebanyak 3 kelompok yang menggambarkan fluktuasi data untuk 9 periode peramalan. Tingkat akurasi peramalan diukur menggunakan kriteria Mean Absolute Percentage Error (MAPE) dan Tracking Signal. MAPE dan Tracking Signal pada peramalan SSA terhadap data aktual sebesar 18,63% dan 0,6377. Hal ini mengakibatkan metode SSA dapat dikatakan baik dan valid untuk meramalkan outflow uang kartal di Kalimantan Barat periode November 2018 sampai Juli 2019.

Kata Kunci: *singular spectrum analysis, R-forecasting, MAPE, tracking signal*

PENDAHULUAN

Uang merupakan komponen penting dalam perekonomian yang digunakan sebagai alat pembayaran dalam melakukan transaksi jual beli, baik dalam pertukaran barang ataupun jasa. Banyaknya uang yang beredar di masyarakat akan berpengaruh pada kondisi perekonomian suatu negara [1].

Bank Indonesia (BI) merupakan satu-satunya lembaga yang berwenang mengeluarkan, mengedarkan, mencabut, menarik dan memusnahkan uang Rupiah [2]. Sebagai bank sentral, BI memiliki wewenang untuk mengeluarkan dan mengedarkan uang kartal yang terdiri dari uang kertas dan uang logam [3]. Keberadaan uang kartal ini sangatlah penting bagi masyarakat, karena uang kartal inilah yang secara fungsi dipakai sebagai alat pembayaran yang sah menggantikan sistem barter, sebagai alat penyimpan nilai dan satuan penghitung [4]. Dalam kewenangan BI untuk mengatur transaksi arus keluar atau masuk uang kartal, BI membuat Rencana Kebutuhan Uang (RKU). Banyak aspek yang menjadi dasar pembuatan RKU, salah satunya data historis aliran uang masuk (*inflow*) dan aliran uang keluar (*outflow*).

Peramalan *inflow* dan *outflow* ini menjadi penting karena berhubungan dengan likuiditas perbankan yang berdampak pada kebijakan-kebijakan moneter yang harus dijalankan. Jika nilai aspek tersebut tinggi maka likuiditas bank akan naik, sedangkan jika terlalu rendah maka likuiditas bank akan turun dan terjadi inflasi. Selain itu peramalan *inflow* dan *outflow* menjadi penting karena berhubungan dengan ekonomi suatu daerah. Jika pada suatu daerah terjadi kekurangan uang maka dikhawatirkan perekonomian daerah tersebut akan kolaps atau jatuh. Sebaliknya jika jumlah uang di suatu daerah berlebih maka dikhawatirkan nilai uang tersebut akan berkurang dan terjadi inflasi [4].

Salah satu hal penting yang harus diramalkan dalam uraian tersebut adalah *outflow*. Pada umumnya data *outflow* memuat pola musiman dan *trend* sehingga dapat dimodelkan dengan analisis deret waktu. Metode SSA merupakan metode yang menggunakan pendekatan nonparametrik. Artinya dalam pengaplikasiannya, metode ini tidak membutuhkan uji asumsi-asumsi parametrik. SSA mendekomposisi data deret waktu asli menjadi suatu penjumlahan dari sejumlah kecil komponen independen seperti komponen *trend*, musiman, dan *noise* [5]. Hal ini mengakibatkan pada penelitian ini digunakan metode SSA.

SSA merupakan sebuah teknik analisis deret waktu dan peramalan. SSA mengkombinasikan elemen klasik analisis deret waktu, statistika multivariat, geometri multivariat, sistem dinamik dan pemrosesan sinyal. SSA memiliki tujuan untuk mendekomposisi sebuah rangkaian data menjadi jumlahan komponen-komponen kecil yang dapat diinterpretasikan [6]. Metode SSA yang digunakan dalam penelitian ini adalah metode *recurrent (R-forecasting)*.

Penelitian ini diawali dengan identifikasi pola data, untuk melihat apakah pola datanya terdapat musiman atau tidak. Selanjutnya terdapat dua tahapan yang saling melengkapi dalam algoritma SSA yaitu tahap dekomposisi dan tahap rekonstruksi. Pada tahap dekomposisi, dua langkah utama yang harus dilakukan untuk memperoleh *eigentriple*, yaitu *embedding* dan *singular value decomposition*. Pada tahap rekonstruksi, dua langkah yang harus dilakukan untuk memperoleh deret yang direkonstruksi, yaitu pengelompokan dan *diagonal averaging*.

Selanjutnya dilakukan pembentukan model SSA berdasarkan nilai koefisien *recurrent*. Setelah diperoleh model SSA langkah selanjutnya adalah meramalkan dan menyimpulkan hasil analisis model SSA.

DEKOMPOSISI

Pada dekomposisi terdapat dua tahap yaitu *Embedding* dan *Singular Value Decomposition (SVD)*. Parameter yang memiliki peran penting dalam dekomposisi adalah *Window Length (L)*.

Embedding adalah tahapan di mana data deret waktu awal diubah menjadi matriks *trajectory*, maksudnya mengubah data awal yang berupa data satu dimensi menjadi data berbentuk multidimensi. Matriks *trajectory* memiliki dimensi $L \times K$, di mana L merupakan *window length*, sedangkan $K = N - L + 1$. Rentang pemilihan nilai L adalah $2 < L < \frac{N}{2}$, dengan asumsi bahwa data deret waktu X sepanjang periode N tidak memuat data hilang, dengan $X = \{x_i\}; i = 1, 2, \dots, N$ [5].

Matriks *trajectory* (\mathbf{T}_x) yang terbentuk merupakan matriks *Hankel*. Matriks *Hankel* adalah matriks yang semua elemen di sepanjang diagonal $i + j$ konstan artinya setiap kemiringan diagonal dari kiri ke kanan adalah konstan. Matriks *trajectory* dapat ditulis sebagai berikut.

$$\mathbf{T}_x = (\mathbf{T}_{i,j})_{L \times K} = \begin{bmatrix} x_1 & x_2 & \cdots & x_K \\ x_2 & x_3 & \cdots & x_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & \cdots & x_N \end{bmatrix}. \quad (1)$$

Tahapan selanjutnya dalam dekomposisi adalah *Singular Value Decomposition (SVD)* yang bertujuan untuk memperoleh pemisahan komponen dalam dekomposisi dari data deret waktu. SVD pada penerapannya memiliki kesamaan dengan analisis komponen utama (*principal component analysis*) yaitu bersifat untuk mereduksi komponen dari data awal serta mengurangi dimensi.

Hasil dari langkah SVD adalah *singular value*, *eigenvector*, dan *principal component* dari matriks lintasan. Matriks ini dalam setiap barisannya mengandung *singular value* yang merupakan akar dari *eigenvalue*, *eigenvector*, dan *principal component*. SVD dimulai dengan menentukan nilai *eigenvalue* ($\lambda_1, \lambda_2, \dots, \lambda_L$) dari matriks \mathbf{S} .

$$\mathbf{S} = \mathbf{T}_x \mathbf{T}_x^T, \quad (2)$$

di mana $\lambda_1 \geq \dots \geq \lambda_L > 0$, serta *eigenvector* (U_1, U_2, \dots, U_L) dari matriks \mathbf{S} tersebut. Sedangkan *principal component* dinotasikan dengan

$$\mathbf{V} = \frac{\mathbf{T}_x^T \mathbf{U}_p}{\sqrt{\lambda_p}}, \quad (3)$$

dengan $p = 1, 2, \dots, d$

SVD dari matriks lintasan dituliskan sebagai $\mathbf{T}_{xp} = T_{x1} + T_{x2} + \dots + T_{xd}$, dimana $\mathbf{T}_{x1} = \sqrt{\lambda_1} \mathbf{U}_1 \mathbf{V}_1^T$. Matriks \mathbf{T}_{xp} mempunyai rank 1, karena merupakan matriks elementer. Kumpulan dari $(\sqrt{\lambda_p}, \mathbf{U}_p, \mathbf{V}_p^T)$ disebut *eigen triple* ke p dari SVD [5]. SVD dari matriks lintasan dapat ditulis dengan persamaan berikut.

$$\begin{aligned} \mathbf{T}_{xp} &= T_{x1} + T_{x2} + \dots + T_{xd}, \\ \mathbf{T}_{xp} &= \sqrt{\lambda_1} \mathbf{U}_1 \mathbf{V}_1^T + \sqrt{\lambda_2} \mathbf{U}_2 \mathbf{V}_2^T + \dots + \sqrt{\lambda_d} \mathbf{U}_d \mathbf{V}_d^T, \\ \mathbf{T}_{xp} &= \sum_{i=1}^d \sqrt{\lambda_p} \mathbf{U}_p \mathbf{V}_p^T, \end{aligned}$$

dengan $p = 1, 2, \dots, d$ dan $d = \max\{p\}; \lambda_p > 0$.

GROUPING

Grouping adalah tahapan pemisahan komponen-komponen aditif seperti *trend*, *musiman*, dan *noise* yang terdapat pada data deret waktu. Proses *grouping* dilakukan dengan cara mengelompokkan set-set indeks $\{1, 2, \dots, d\}$ menjadi m subset yang dapat dilambangkan dengan $I_x = I_1 + I_2 + \dots + I_m$ yang selanjutnya membentuk matriks yang didasarkan pada *Singular Value Decomposition* untuk matriks *trajectory* sebagai berikut.

$$\mathbf{T}_{I_x} = T_{I_1} + T_{I_2} + \dots + T_{I_m}.$$

Tahapan untuk memilih set $I_x = I_1 + I_2 + \dots + I_m$ disebut dengan *eigen triple grouping*.

DIAGONAL AVERAGING

Diagonal averaging merupakan tahapan kedua pada rekonstruksi data. Tahapan *diagonal averaging* ini adalah tahapan merekonstruksi masing-masing matriks yang terdapat pada matriks \mathbf{T}_{I_x} menjadi data deret waktu yang baru dengan panjang N .

Misalkan matriks $\mathbf{Y} = L \times K$; $Y_{ij}, 1 \leq i \leq L, 1 \leq j \leq K$. Matriks \mathbf{Y} diubah menjadi deret waktu g_1, \dots, g_N melalui *diagonal averaging* yaitu:

$$g_k = \begin{cases} \frac{1}{k} \sum_{m=1}^k y_{m, k-m+1}^*; 1 \leq k < L^*, \\ \frac{1}{L^* - 1} \sum_{m=1}^{L^* - 1} y_{m, k-m+1}^*; L^* \leq k < K^* + 1, \\ \frac{1}{N - k + 1} \sum_{m=k-K^*+1}^{N-K^*+1} y_{m, k-m+1}^*; K^* + 1 \leq k \leq N, \end{cases} \quad (4)$$

dengan

$$L^* = \min(L, K),$$

$$K^* = \max(L, K),$$

$$N = L + K - 1,$$

$$y_{ij}^* = \begin{cases} y_{ij}; L < K, \\ y_{ij}; \text{selainnya.} \end{cases}$$

Misalkan $k = 1$ akan dihasilkan $g_1 = y_{11}$, $k = 2$ akan dihasilkan $g_2 = \frac{(y_{12} + y_{21})}{2}$, dan seterusnya.

R-FORECASTING

Peramalan *R-forecasting* berkaitan dengan penaksiran *Linier Recurrent Formula* (LRF). Apabila dimisalkan $U = (u_1, u_2, \dots, u_{L-1}, u_L)^T$, $U^\nabla = (u_1, u_2, \dots, u_{L-1})^T$ dan π_q adalah komponen terakhir dari *eigenvectors* U atau dapat ditulis $\pi_q = u_L$ maka koefisien LRF dapat dihitung menggunakan Persamaan (5).

$$\mathfrak{R} = (a_{L-1}, a_{L-2}, \dots, a_1)^T = \frac{1}{1-v^2} \sum_{q=1}^r \pi_q U^\nabla \tag{5}$$

dimana $v^2 = \sum_{q=1}^r \pi_q^2$.

Data deret waktu yang digunakan pada *R-forecasting* merupakan hasil rekonstruksi yang diperoleh dari *diagonal averaging*. Langkah selanjutnya yaitu menentukan M buah titik baru untuk diramalkan. Sehingga deret hasil peramalan dapat ditulis dengan persamaan berikut.

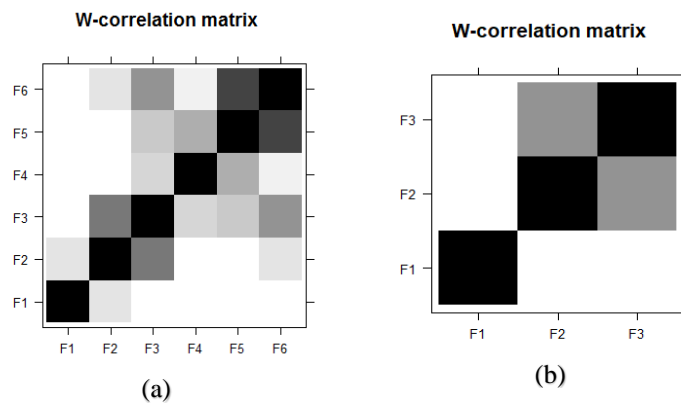
$$G_{N+M} = (g_1, g_2, \dots, g_{N+M}),$$

Hasil peramalan diperoleh berdasarkan

$$g_i = \begin{cases} \bar{y}_i & ; i = 0, 1, \dots, N, \\ \sum_{j=1}^{L-1} a_j g_{i-j} & ; i = N + 1, \dots, N + M, \end{cases} \tag{6}$$

MATRIKS W-CORRELATION

Besarnya korelasi ditunjukkan oleh gradasi warna dari warna terang hingga gelap dari matriks *W-correlation*. Semakin tua warnanya semakin tinggi korelasinya [7]. Contoh dari matrix *w-correlation* dapat dilihat pada Gambar 3.1.



Gambar 3.1 (a) contoh matriks *w-correlation* lemah, (b) contoh matriks *w-correlation* kuat

UKURAN AKURASI TRACKING SIGNAL

Salah satu alat pengukuran akurasi peramalan lainnya untuk data deret waktu adalah nilai *tracking signal*. *Tracking signal* adalah ukuran toleransi yang dapat digunakan untuk menentukan kemungkinan apakah hasil dari peramalan dapat digunakan. Batas toleransi dari nilai *tracking signal* yang dapat diterima yaitu $-5 \leq \textit{tracking signal} \leq 5$ [8]. Dengan perhitungan sebagai berikut.

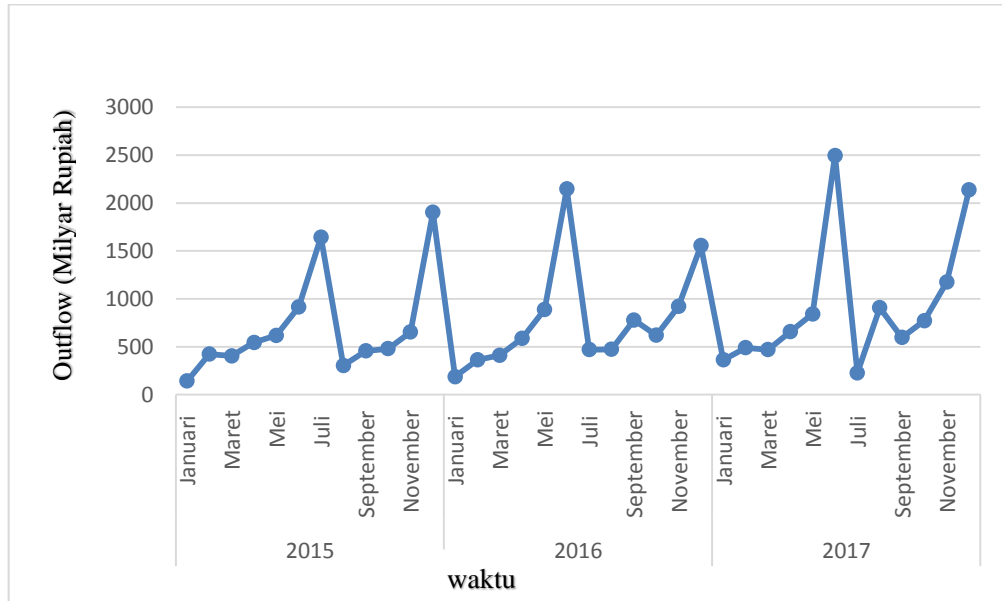
$$\textit{Tracking Signal} = \frac{\sum_{t=1}^n e_t}{\sum_{t=1}^n \frac{|e_t|}{n}}$$

dengan $e_t = \textit{error}$ periode ke- t .

STUDI KASUS

Penentuan pola data ini digunakan untuk menentukan apakah data *outflow* ini mengandung musiman atau tidak. Data yang digunakan pada penelitian ini merupakan data sekunder. Data yang digunakan berupa data deret waktu dengan selang waktu dari Januari 2015 sampai Oktober 2018 dalam bentuk bulanan. Data *outflow* tersebut dibagi menjadi data *in sample* dan data *out sample*. Data *in sample* yang digunakan sebesar 36 data (pada $i = 1, 2, \dots, 36$) dan 10 data (pada $i = 37, 38, \dots, 46$)

digunakan sebagai data *out sample*. Data *in sample outflow* uang kartal ini dibentuk menjadi sebuah grafik yang disajikan pada Gambar 1.



Gambar 1 Grafik *outflow* uang kartal di Kalimantan Barat

Gambar 1 menunjukkan bahwa terdapat fluktuasi pada data *outflow* di Kalimantan Barat, sehingga data mengandung pola musiman. Data *outflow* tersebut juga menunjukkan bahwa perubahannya masih terbilang stabil.

Langkah awal yang harus dilakukan sebelum memasuki langkah-langkah dalam tahap dekomposisi adalah menentukan *window length*. Nilai *window length* berada pada rentang $2 < L \leq 18$. *Window length* dihitung dengan membandingkan hasil *forecasting in sample* dengan data *out sample*. Penentuan *window length* (L) ini dilakukan dengan tanpa *grouping* menggunakan aplikasi RStudio. Hasil penghitungan *trial and error* terhadap data *outflow* uang kartal di Kalimantan Barat diperoleh nilai L yang optimum pada $L = 8$.

Setelah menentukan *window length* langkah selanjutnya adalah dekomposisi. Langkah dekomposisi diawali dengan *embedding* yang menghasilkan matriks lintasan $L \times K$. Data yang digunakan dalam langkah ini adalah data *in sample*, untuk nilai $L = 8$, maka $K = 36 - 8 + 1 = 29$. Sehingga diperoleh matriks lintasannya adalah berukuran 8×29 , berdasarkan Persamaan (1) menghasilkan matriks berikut.

$$T_x = T_{i,j(8,29)} = \begin{bmatrix} 141,3884 & 422,2595 & \dots & 842,7860 \\ 422,2595 & 403,6973 & \dots & 2.495,5060 \\ 403,6973 & 544,7802 & \dots & 227,2875 \\ 544,7802 & 617,6888 & \dots & 907,3601 \\ 617,6888 & 915,3113 & \dots & 596,9492 \\ 915,3113 & 1.644,334 & \dots & 772,1399 \\ 1.644,334 & 303,5567 & \dots & 1.173,7804 \\ 303,5567 & 456,4291 & \dots & 2.138,6446 \end{bmatrix}$$

Sebelum mencari nilai *Singular Value Decomposition* (SVD) tahap yang harus dilakukan adalah membentuk matriks baru S sesuai Persamaan (2) menggunakan matriks T_x yang sudah diperoleh. Berdasarkan Persamaan (2) diperoleh matriks S sebagai berikut.

$$S_{i,j(8,8)} = \begin{bmatrix} 21675306 & 16534598 & \cdots & 16866209 \\ 16534598 & 27882865 & \cdots & 26844493 \\ 14752432 & 17042093 & \cdots & 20031195 \\ 14936797 & 16959677 & \cdots & 17700559 \\ 14704019 & 16349462 & \cdots & 17340529 \\ 17439682 & 16543565 & \cdots & 18154257 \\ 21739983 & 20239444 & \cdots & 18870170 \\ 16866209 & 26844493 & \cdots & 31100708 \end{bmatrix}$$

Tahap selanjutnya dalam dekomposisi ini adalah SVD yang menghasilkan *eigen triple* yaitu *eigenvalue*, *eigenvector*, dan matriks *W-correlation* yang ditampilkan bersama bentuk grafiknya. Nilai *eigen triple* ini digunakan untuk memisahkan komponen, sehingga komponen ini dapat dikelompokkan. Grafik-grafik berikut akan menjadi dasar dalam *grouping* pada tahapan rekonstruksi data.

Tahapan SVD ini dimulai dengan menentukan *singular value* ($\sqrt{\lambda_i}$). *Singular value* merupakan akar dari *eigenvalue*. Matriks yang digunakan untuk memperoleh *eigenvalue* adalah matriks *trajectory* **S**. Hasil dari *singular value* dapat dilihat pada Tabel 2.

Tabel 2 Eigenvalues dan singular values

| No. | Eigenvalues | Singular Values |
|-----|----------------|-----------------|
| 1 | 151992676,6200 | 12328,5310 |
| 2 | 17812518,9600 | 4220,4880 |
| 3 | 15560350,4000 | 3944,6610 |
| 4 | 11076435,9800 | 3328,1280 |
| 5 | 10971530,0300 | 3312,3300 |
| 6 | 10654916,7700 | 3264,1870 |
| 7 | 3271052,0500 | 1808,6050 |
| 8 | 1889816,5900 | 1374,7060 |

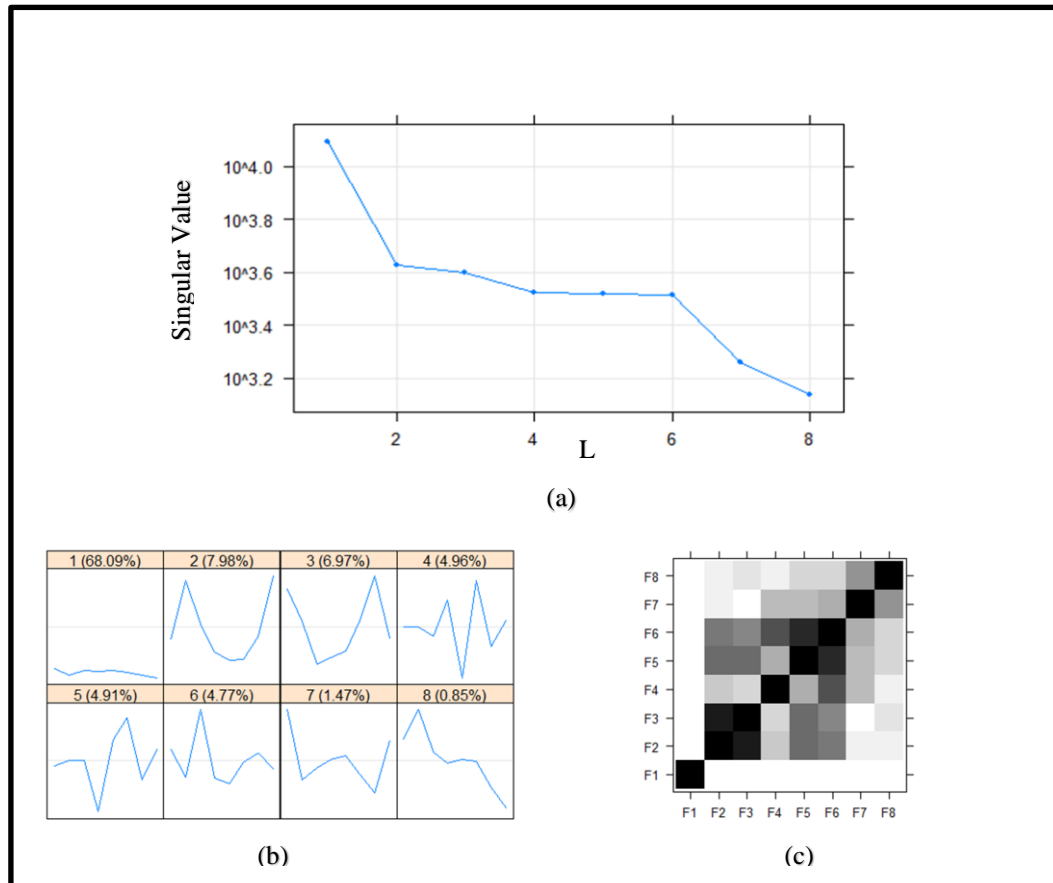
Langkah selanjutnya adalah untuk mendapatkan *eigenvector*. Nilai dari *eigenvector* ini digunakan untuk mempermudah dalam menentukan karakteristik data dari matriks *trajectory*. Hasil *eigenvector* dari matriks *trajectory* **S** adalah sebagai berikut.

$$U = \begin{bmatrix} -0,3219 & 0,1392 & -0,4546 & 0,0027 & 0,0777 & -0,1757 & -0,7448 & -0,2803 \\ -0,3722 & -0,5260 & -0,0666 & -0,0013 & 0,0005 & 0,2649 & 0,2869 & -0,6540 \\ -0,3397 & -0,0351 & 0,4391 & -0,1211 & 0,0036 & -0,8088 & 0,1027 & -0,1054 \\ -0,3403 & 0,2802 & 0,3600 & 0,3489 & 0,6927 & 0,2702 & -0,0222 & 0,0312 \\ -0,3388 & 0,3777 & 0,2879 & -0,6589 & -0,2840 & 0,3732 & -0,0714 & -0,0194 \\ -0,3476 & 0,3662 & -0,0745 & 0,5987 & -0,5842 & 0,0219 & 0,1983 & 0,0051 \\ -0,3701 & 0,1071 & -0,6013 & -0,2542 & 0,2623 & -0,1213 & 0,4723 & 0,3446 \\ -0,3922 & -0,5796 & 0,1282 & 0,0797 & -0,1529 & 0,1317 & -0,2903 & 0,6019 \end{bmatrix}$$

Tahap berikutnya adalah *principal component*. Tahap ini menggunakan nilai *singular value* dan *eigenvectors* yang telah diperoleh dari matriks *trajectory* **S**. Berdasarkan perhitungan pada Persamaan (3) hasil *principal component* yang didapat adalah sebagai berikut.

$$V_{(29,8)} = \begin{bmatrix} -1780,4032 & 390,3164 & -559,1046 & -46,2202 & 64,7859 & -1,6488 & 871,1580 & 970,2269 \\ -634,9260 & 306,9159 & 219,2037 & 1817,4567 & -736,9928 & 193,1900 & 87,4818 & -121,6776 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ -894,7695 & -1554,7455 & -201,7799 & 228,9542 & 210,0494 & 953,1459 & 259,8755 & -179,7615 \end{bmatrix}$$

Lebih jelasnya pola dari SVD dapat dilihat pada Gambar 2.



Gambar 2 (a) grafik *singular value* (b) grafik *eigenvector* (c) matriks *W-Correlations*

Berdasarkan Gambar 2 (a) grafik *eigenvalue* menunjukkan banyaknya grouping yang terbentuk yaitu 3 kelompok berdasarkan patahan yang terbentuk. Gambar 2 (b) menunjukkan bahwa *eigenvector* 1 mempengaruhi data sebesar 68,09%, *eigenvector* 2 mempengaruhi data sebesar 7,98%, *eigenvector* 3 mempengaruhi data sebesar 6,97%, *eigenvector* 4 mempengaruhi data sebesar 4,96%, *eigenvector* 5 mempengaruhi data sebesar 4,91%, *eigenvector* 6 mempengaruhi data sebesar 4,77%, *eigenvector* 7 mempengaruhi data sebesar 1,47%, dan *eigenvector* 8 dengan pengaruh paling kecil terhadap data yaitu sebesar 0,85%. Grafik *eigenvector* juga menunjukkan masing-masing anggota dari masing-masing kelompok yang dilihat dari kemiripan pola. Gambar 2 (c) menunjukkan korelasi antar data yang lemah.


Tahapan rekonstruksi data merupakan tahapan yang sangat penting dalam SSA. Pada tahap ini, berdasarkan pada Gambar 2 jumlah kelompok yang ditetapkan dalam tahap *grouping* adalah sebanyak 3 kelompok. Kelompok 1 diberi nama *trend*, kelompok 2 diberi nama *season 1*, dan kelompok 3 diberi nama *season 2* sesuai dengan pola dari masing-masing kelompok tersebut. Berdasarkan kemiripan pola pada grafik *eigenvector* dan besarnya pengaruh *eigenvector* tersebut terhadap data. Kelompok *trend* terdiri dari *eigenvalue* 1, *season 1* terdiri dari *eigenvalue* 2,3 dan *season 2* terdiri dari *eigenvalue* 4,5,6,7. *Eigenvalue* 8 tidak dimasukkan ke dalam kelompok karena pengaruh *eigenvector* 8 terhadap data paling kecil yaitu sebesar 0,85%.

Setelah mendapatkan kelompok dan anggota dari masing-masing kelompok, tahapan selanjutnya adalah *diagonal averaging*. *Diagonal averaging* diperoleh dengan menjumlahkan hasil rekonstruksi untuk tiap kelompok dengan menggunakan Persamaan (4). Hasil rekonstruksi *outflow* uang kartal dapat dilihat pada Tabel 3.

Tabel 3 Hasil rekonstruksi *outflow* uang kartal

| No. | Data | Hasil Rekonstruksi | | | Diagonal Average |
|-----|------------|--------------------|------------|-----------|------------------|
| | | Trend | Season 1 | Season 2 | |
| 1 | 141,3884 | 573,2276 | 324,4223 | -643,9164 | 253,7335 |
| 2 | 422,2595 | 629,9356 | -123,3105 | 39,6147 | 546,2398 |
| 3 | 403,6973 | 632,8666 | -289,3260 | 54,7714 | 398,3120 |
| 4 | 544,7802 | 642,0664 | -128,09427 | 8,2683 | 522,2405 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| 35 | 1.173,7804 | 1148,0651 | 215,1209 | -148,5560 | 1214,6299 |
| 36 | 2.138,6446 | 1306,4183 | 844,6935 | 95,7465 | 2246,8584 |

Kedekatan dan kemiripan bentuk dari hasil rekonstruksi dapat dilihat pada Gambar 3.



Gambar 3 (a) hasil rekonstruksi tahap *grouping*, (b) matriks *W-Correlation* setelah rekonstruksi

Dari Gambar 3 (a) hasil rekonstruksi data hampir mendekati data aslinya. Gambar 3 (b) dapat dilihat adanya *strong separability* saat masing-masing kelompok tidak lagi berkorelasi. Hal ini mengakibatkan bahwa rekonstruksi menggunakan SSA dengan *window length* (L) = 8 dan *grouping* = 3 kelompok dapat dikatakan baik.

Langkah selanjutnya adalah peramalan menggunakan metode *R-forecasting*. Algoritma pada peramalan *R-forecasting* berkaitan dengan penaksiran koefisien *Linear Recurrent Formula* (LRF) atau a_j yang dihitung berdasarkan *eigenvector* pada tahap SVD dengan menggunakan aplikasi RStudio. Data yang digunakan pada tahap *R-forecasting* adalah data hasil rekonstruksi pada tahap *diagonal averaging*. Berdasarkan Persamaan (5) koefisien dari LRF dapat dilihat pada Tabel 4.

Tabel 4 Koefisien *Linear Recurrent Formula* (a_j)

| No. | a_j |
|-----|------------|
| 1 | 0,4952538 |
| 2 | 0,3918369 |
| 3 | -0,1272117 |
| 4 | 0,1403106 |
| 5 | 0,0442653 |
| 6 | 0,02787991 |
| 7 | 0,03612966 |

Tabel 4 memperlihatkan bahwa terdapat 7 koefisien dari LRF, dimana ada 1 koefisien yang bernilai negatif. Hasil koefisien LRF ini akan digunakan dalam perhitungan peramalan.

Langkah selanjutnya adalah menentukan model persamaan SSA untuk meramalkan *outflow* uang kartal di Kalimantan Barat. Model ini dibentuk berdasarkan koefisien LRF yang telah diperoleh. Berdasarkan Persamaan (6), adapun model persamaan untuk meramalkan *outflow* uang kartal adalah sebagai berikut:

$$g_i = 0,4952538g_{i-1} + 0,3918369g_{i-2} + (-0,1272117g_{i-3}) + \dots + 0,0361297g_{i-7}.$$

Model peramalan yang diperoleh kemudian divalidasi menggunakan sejumlah indikator. Akurasi peramalan pada penelitian ini menggunakan indikator *Mean Absolute Percentage Error* (MAPE) dan *Tracking Signal*.

Perhitungan akurasi peramalan dilakukan dengan membandingkan hasil ramalan *in sample* dengan data *out sample*. Perbandingan ini dilakukan untuk melihat apakah model tersebut layak atau tidak untuk meramalkan *outflow* uang kartal di Kalimantan Barat. Berdasarkan perhitungan menggunakan persamaan SSA yang telah diperoleh maka didapat hasil perbandingan data *out sample* dan hasil peramalan untuk *outflow* uang kartal di Provinsi Kalimantan Barat yang disajikan pada Tabel 5.

Tabel 5 Perbandingan data *out sample* dan hasil peramalan

| Periode | Data | Hasil Ramalan |
|----------------|--------------------------------------|-----------------|
| | <i>Out Sample</i> (Milyar Rupiah) | (Milyar Rupiah) |
| Januari 2018 | 133,5 | 157,1695 |
| Februari 2018 | 758,6 | 864,2044 |
| Maret 2018 | 685,9 | 711,8246 |
| April 2018 | 617,4 | 709,2159 |
| Mei 2018 | 1543 | 1732,9850 |
| Juni 2018 | 2409,7 | 2070,9910 |
| Juli 2018 | 446,2 | 184,8302 |
| Agustus 2018 | 999,3 | 920,2649 |
| September 2018 | 600,1 | 812,4110 |
| Oktober 2018 | 863,6 | 796,1540 |

Tabel 4.5 menunjukkan bahwa data ramalan yang diperoleh hampir mendekati data aktual (*out sample*). Kedekatan tersebut diperoleh dari MAPE dan *tracking signal* yaitu sebesar 18,63% dan 0,6377. Berdasarkan nilai MAPE dan *tracking signal* tersebut metode SSA dapat dikatakan layak untuk meramalkan *outflow* uang kartal di Kalimantan Barat.

PENUTUP

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan, maka dapat diperoleh beberapa kesimpulan, yaitu sebagai berikut:

1. Model persamaan SSA yang terbaik untuk meramalkan *outflow* uang di Kalimantan barat adalah $g_i = 0,4952538g_{i-1} + 0,3918369g_{i-2} + (-0,1272117g_{i-3}) + \dots + 0,0361297g_{i-7}$.
2. Akurasi hasil ramalan dihitung menggunakan MAPE dan *tracking signal*. MAPE dan *tracking signal* dari ramalan untuk metode SSA adalah 18,63% dan 0,6377 dengan *window length* (L) sebesar 8. Berdasarkan nilai MAPE dan *tracking signal* tersebut, maka dapat dikatakan metode SSA cocok digunakan pada peramalan selanjutnya karena MAPE dan *tracking signal* masih berada di batas toleransi.

DAFTAR PUSTAKA

- [1] Bank Indonesia. 2013. *Bank Indonesia*. www.bi.go.id. [9 November 2018].
- [2] Bank Indonesia. 2016. *Data Penelitian Kurs dan Inflasi*. www.bi.go.id. [9 November 2018].

- [3] Solikin dan Suseno. *Pengertian, Penciptaan dan Peranan Uang dalam Perekonomian*. Jakarta: Pusat Pendidikan dan Studi Kebanksentralan (PSSK), 2002.
- [4] Gerai Info. *Pengedaran Uang: yang Penting Pas Agar Ekonomi Nggak Kolaps*. Edisi XVI Tahun 2. Jakarta: Bank Indonesia, 2011.
- [5] Golyandana, Netrutkin, dan Zhigljavsky. *Analysis of Time Series Structure SSA and Related Techniques*. Chapman dan Hall, 2001.
- [6] Golyandina dan Zhigljavsky. Basic Singular Spectrum Analysis and Forecasting with R. *Computational Statistics and Data Analysis*. 2013; 71: 34-954.
- [7] Jatmiko, Y.A., Rahayu, R.L., dan Darmawan, G. Perbandingan Keakuratan Hasil Peramalan Produksi Bawang Merah Metode *Holt-Winters* dengan *Singular Spectrum Analysis (SSA)*. *Jurnal Matematika*. 2017; 3(1): 13-23.
- [8] Bovas, A., dan Ledolter, J. *Statistical Methods for Forecasting*. New York: John Wiley and Son Inc, 1983.

AGENG WICAKSONO : Universitas Tanjungpura, Jl. Prof. Dr. H. Hadari Nawawi,
agengwicaksono9711@gmail.com

HELMI : Universitas Tanjungpura, Jl. Prof. Dr. H. Hadari Nawaawi,
helmi132205@yahoo.co.id

YUNDARI : Universitas Tanjungpura, Jl. Prof. Dr. H. Hadari Nawawi,
yundari@math.untan.ac.id
