

Peramalan Indeks Harga Konsumen Dengan Metode *Singular Spectral Analysis* (SSA) dan *Seasonal Autoregressive Integrated Moving Average* (SARIMA)

Deltha Airuzsh Lubis¹, Muhamad Budiman Johra², Gumgum Darmawan³

Magister Statistika Terapan, Universitas Padjajaran, Jl. Dipati Ukur No.35, Bandung 40132

delthalubis@gmail.com¹, muhamadbudiman8271@gmail.com², gumstat@gmail.com³

DOI:<https://doi.org/10.15642/mantik.2017.3.2.74-82>

Abstrak

Indeks Harga konsumen (IHK) merupakan indikator yang digunakan untuk mengukur inflasi maupun deflasi dari sekelompok barang dan jasa secara umum. Peramalan IHK menjadi penting sebagai deteksi dini dalam menghadapi lonjakan harga. Penelitian ini menggunakan metode SSA dan SARIMA. SARIMA merupakan model parametrik yang membutuhkan berbagai asumsi sedangkan SSA merupakan teknik nonparametrik yang bebas dari berbagai asumsi namun kedua metode tersebut mensyaratkan adanya pola musiman pada data. Berdasarkan hasil penelitian, metode SSA dengan *length window* (L) sebesar 24 dan *grouping* sebanyak 4 (1 kelompok *trend* dan 3 kelompok musiman) dan model SARIMA berorde $(0,1,1)(0,1,1)_6$ merupakan model yang tepat dan andal dalam peramalan IHK Kota Padangsidempuan. Peramalan IHK Kota Padangsidempuan untuk 5 bulan ke depan dengan metode SSA dan SARIMA $(0,1,1)(0,1,1)_6$ menunjukkan pola tren yang cenderung meningkat tetapi peramalan pada bulan ke-5 dengan metode SSA menunjukkan lonjakan nilai IHK yang tinggi atau akan terjadi inflasi yang tinggi.

Kata kunci: *ARIMA, IHK Seasonal, Singular Spectral Analysis*

Abstract

Consumer Price Index (CPI) are the indicators used to measure the inflation and deflation of a group of goods and services in general. Forecasting CPI to be important as early detection in facing price hikes. This study uses the SSA and SARIMA. SARIMA a parametric model that requires various assumptions while SSA is a nonparametric technique that is free from a variety of assumptions, but both methods require seasonal patterns in the data. Based on the research results, methods of SSA with length window(L) of 24 and a grouping of 4 (1 group of seasonal and 3 groups of trends) and SARIMA models of order $(0,1,1), (0,1,1)_6$ is the most accurate and reliable models in forecasting CPI to the value Padangsidempuan City. Forecasting CPI Padangsidempuan City for the next 5 months with SSA method and SARIMA $(0,1,1), (0,1,1)_6$ shows the pattern of trend is likely to increase but forecasting the 5th month with SSA method showed a surge in the value of CPI high or high inflation will occurs.

Keywords: *ARIMA, CPI, Seasonal, Singular Spectral Analysis*

1. Pendahuluan

Indeks Harga konsumen (IHK) merupakan nilai indeks yang menggambarkan rata-rata perubahan harga dari suatu paket barang dan jasa yang dikonsumsi oleh rumah tangga dalam kurun waktu tertentu. Perubahan IHK dari waktu ke waktu menggambarkan inflasi maupun deflasi

dari barang dan jasa secara umum. Data IHK secara resmi dirilis oleh pemerintah melalui Badan Pusat Statistik (BPS) setiap bulannya yang mencakup 65 kota di Indonesia.

Kebutuhan barang dan jasa pada musim-musim tertentu seperti idul fitri, tahun ajaran baru dan sebagainya selalu melonjak sehingga menyebabkan peningkatan harga pada musim-

musim tersebut. Keadaan seperti ini akan mempengaruhi perubahan nilai IHK dan membentuk pola musiman di setiap tahunnya. Dalam melakukan analisis deret waktu pada data IHK sebaiknya melibatkan efek musiman tersebut, diantaranya dengan menggunakan metode SSA dan SARIMA. Pemodelan SSA merupakan metode nonparametrik sehingga lebih fleksibel dalam penggunaannya dan terhindar dari berbagai asumsi seperti stasioneritas, independensi dan normalitas residual sebagaimana pada model SARIMA yang parametrik [1]. Selain itu, SSA efektif dalam meminimalisir error [2]. Dalam metode SSA tidak ada model yang dibangun seperti model SARIMA sehingga parameter pada SSA berupa panjang *window* (L) dan banyaknya *grouping* (r).

Kota Padangsidempuan merupakan salah satu kota yang berada di bagian paling selatan di provinsi Sumatera Utara yang menjadi jalur perdagangan yang penting bagi beberapa kabupaten di sekitarnya. Kota ini memiliki jarak yang paling jauh ke ibukota provinsi yaitu 448 km bila dibandingkan kota lain yang menjadi kota penghitung inflasi seperti Sibolga (382 km), Pematangsiantar (128 km), dan Medan (0 km) [3].

Peramalan IHK menjadi penting untuk melihat bagaimana perkembangan IHK di Kota Padangsidempuan, sehingga dapat menjadi deteksi dini dalam mengatasi lonjakan harga yang mungkin terjadi.

2. Kajian Teori

2.1 Singular Spectrum Analysis (SSA)

SSA merupakan teknik analisis data deret waktu yang terkini dan powerful dalam menggabungkan analisis deret waktu, statistik multivariat, geometrik multivariat, sistem dinamis dan proses signal. Penerapan SSA kian meluas dari bidang matematika dan fisika ke bidang ekonomi dan matematika keuangan, dari ilmu metrologi dan oseanologi ke ilmu sosial dan riset pemasaran [4].

SSA dapat mengatasi beberapa masalah seperti, menemukan trend pada resolusi yang berbeda; *smoothing*; mengekstrak komponen musiman; mengekstrak secara simultan pola siklis; mengekstrak periodesitas dengan amplitudo yang beragam; menemukan struktur data pada data deret waktu yang pendek dan mendeteksi perubahan titik [4].

2.2. Seasonal Autoregressive Integrated Moving Average (SARIMA)

Model ARIMA yang melibatkan efek musiman didalamnya disebut juga dengan model SARIMA. Secara umum, model SARIMA ditulis dengan persamaan berikut [6]:

$$\Phi_P B^S \phi_p(B) (1 - B)^d (1 - B^S)^D Z_t = \theta_q(B) \Theta_Q(B^S) a_t \quad (1)$$

dimana:

- $\phi_p(B)$: AR non seasonal
- Φ_P : AR seasonal
- $(1 - B)^d$: differencing non seasonal
- $(1 - B^S)^D$: differencing seasonal
- $\theta_q(B)$: MA non seasonal
- $\Theta_Q(B^S)$: MA seasonal

2.3. Penelitian Terdahulu

Peramalan data IHK cukup banyak dilakukan dengan menggunakan model ARIMA, salah satunya peramalan IHK Bangladesh dengan model ARIMA (1,1,1)(1,0,1)₁₂ diperoleh akurasi peramalan berdasarkan nilai *Mean Average Percentage Error* (MAPE) sekitar 0,08 persen [5].

Sementara itu, perbandingan metode SSA dan SARIMA oleh [4] untuk meramalkan tingkat kematian bulanan akibat kecelakaan di USA menunjukkan bahwa metode SSA memiliki akurasi paling baik dibandingkan metode SARIMA. Hal tersebut dapat dilihat dari nilai *Mean Relative Average Error* (MRAE) untuk SSA sekitar 2 persen dan SARIMA sekitar 6 persen.

3. Metode Penelitian

3.1. Pengecekan Pola Musiman

Tahapan dalam pengujian pola musiman yaitu [7]:

1. Tentukan koefisien pembeda (*d*)
2. Jika nilai *d* > 0.5 maka lakukan pembedaan terlebih dahulu
3. Tentukan nilai Frekuensi Fourier

$$\omega_k = \frac{2\pi k}{N}, \text{ dengan } k = 1, 2, \dots, \frac{N}{2} \quad (2)$$

4. Tentukan nilai periode dari

$$P_k = \frac{2^* \pi}{\omega_k} \quad (3)$$

dari setiap ω_k

5. Tentukan nilai periodogram (nilai periodogram akan menghasilkan nilai α dan β)
6. Tentukan hipotesis penelitian yaitu
 $H_0: \alpha = \beta$ (ada pola musiman)
 $H_1: \alpha \neq \beta$ (tidak ada pola musiman)

Statistik uji:

$$F = \frac{(n-3)(\alpha_k^2 + \beta_k^2)}{2 \sum_{j \neq k}^{n/2} (\alpha_k^2 + \beta_k^2)} \quad (4)$$

dengan $j = 1, 2, \dots, \frac{n-1}{2}$ dan $k = \frac{n}{2}$

Kriteria Uji : Tolak H_0 jika $F_{\text{Hitung}} > F_{\text{Tabel}(2, n-3; \alpha)}$ dengan taraf signifikansi α .

3.2. Tahapan SSA

Tahapan dasar SSA terdiri dari 2 tahap, yaitu: dekomposisi dan rekonstruksi. Tahap dekomposisi terdiri dari proses *embedding* dan SVD. *Embedding* mendekomposisi data *time series* awal ke dalam matriks lintasan yang akan membentuk pola tren, musiman, komponen bulanan, dan eror sesuai dengan nilai singularnya. Tahap rekonstruksi mencakup pengelompokan yang berdasar dari dekomposisi matriks lintasan dan proses *diagonal averaging* untuk merkonstruksi data *time series* baru dari pengelompokan yang sudah dilakukan sebelumnya.

• Dekomposisi - Embedding

Pada tahap embedding, data *time series* awal $\mathbf{X} = (x_1, x_2, \dots, x_N)$ diubah ke dalam bentuk matriks lintasan. Matriks lintasan yang dibentuk adalah:

$$\mathbf{T}_{i,j} = \begin{pmatrix} x_1 & x_2 & \dots & x_L \\ \vdots & \vdots & \ddots & \vdots \\ x_K & x_{K+1} & \dots & x_N \end{pmatrix} \quad (5)$$

Matriks lintasan \mathbf{T}_X berdimensi $L \times K$ dimana L adalah *window length* dengan $2 < L < N/2$ dan $K = N-L+1$

- Singular Value Decomposition (SVD)

Pada tahap ini, \mathbf{T}_X didekomposisi menjadi $\mathbf{T}_X = \mathbf{U}\mathbf{D}\mathbf{V}^T$ yang disebut dengan *triple eigen*. Atau dapat ditulis menjadi:

$$\begin{aligned} \mathbf{T}_X &= \mathbf{T}_1 + \dots + \mathbf{T}_d \\ &= \mathbf{U}_1 \sqrt{\lambda_1} \mathbf{V}_1^T + \dots + \mathbf{U}_d \sqrt{\lambda_d} \mathbf{V}_d^T \\ &= \sum_{i=1}^d \mathbf{U}_i \sqrt{\lambda_i} \mathbf{V}_i^T \end{aligned} \quad (6)$$

• Rekonstruksi

- Grouping

Pada tahap ini, matriks \mathbf{T}_i yang berdimensi $L \times K$ diekstrak ke dalam pola tren, musiman, komponen bulanan dan eror. Tahap pengelompokan merupakan partisi himpunan dari indeks $\{I, \dots, d\}$ ke dalam kelompok himpunan disjoint m dari $I = \{I_1, \dots, I_m\}$. Jadi \mathbf{T}_i berkorespondensi dengan kelompok $I = \{I_1, \dots, I_m\}$. T_{I_i} adalah jumlah dari T_j dimana $j \in I_i$.

Sehingga \mathbf{T}_X dapat dijabarkan menjadi:

$$\mathbf{T}_X = \mathbf{T}_1 + \dots + \mathbf{T}_L = \mathbf{T}_{I_1} + \dots + \mathbf{T}_{I_m} \quad (7)$$

• Diagonal Averaging

Pada *diagonal averaging* matriks \mathbf{T}_i yang telah dikelompokkan akan ditransformasi menjadi data deret berkala yang baru dengan panjang N dengan ketentuan berikut:

$$\tilde{T}_{i,j} \begin{cases} \frac{1}{s-1} \sum_{j=1}^{s-1} x_{j,s-j} & \text{untuk } 2 \leq s \leq L & (8) \\ \frac{1}{L} \sum_{j=1}^L x_{j,s-j} & \text{untuk } L+1 \leq s \leq K+1 & (9) \\ \frac{1}{N-s+2} \sum_{j=s-K}^{N-s+2} x_{j,s-j} & \text{untuk } K+2 \leq s \leq N+1 & (10) \end{cases}$$

3.3. Peramalan SSA

Peramalan SSA pada penelitian ini menggunakan model *Linear Recurrence Relations* (LRR) bentuk polynomial yang dapat dituliskan dalam bentuk berikut:

$$y_{i+d} = \sum_{k=1}^d a_k y_{i+d-k} : 1 \leq i \leq N-d \quad (11)$$

Koefisien LRF a_j diperoleh dari persamaan:

$$\begin{aligned} \mathfrak{R} &= (a_{L-1}, a_{L-2}, \dots, a_2, a_1)^T \\ &= \frac{1}{1-v^2} \sum_{i=1}^r \pi_i \mathbf{U}^\nabla \end{aligned} \quad (12)$$

3.4. SARIMA

SARIMA merupakan model parametrik sehingga diperlukan beberapa uji asumsi yang harus dipenuhi, diantaranya:

a. Stasioneritas.

Data deret waktu disebut stasioner jika nilai rata-rata dan varians konstan di sepanjang waktu.

Prosedur uji stasioneritas dalam mean dengan uji Augmented Dickey Fuller (ADF):

$H_0 : \rho = 0$ (Terdapat unit roots, variabel Z tidak stasioner)

$H_1 : \rho \neq 0$ (Tidak terdapat unit roots, variabel Z stasioner)

$$\text{Statistik uji: } \tau = \frac{\hat{\rho}}{\text{std}(\hat{\rho})} \quad (13)$$

dan hasil statistik hitungnya dibandingkan dengan tabel τ_α

- b. Uji Normalitas. Pengujian kenormalan dapat dilakukan dengan uji *Shapiro Wilk*.

Hipotesis:

H_0 : residual berdistribusi normal

H_1 : residual tidak berdistribusi normal

- c. Uji *White Noise*. Suatu model bersifat *white noise* artinya residual dari model tersebut telah memenuhi asumsi variasi residual homogen serta antar residual tidak berkorelasi.

Hipotesis:

$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0$

H_1 : Minimal ada satu ρ_i sama dengan nol;
 $i = 1, 2, \dots, k$

Statistik uji (uji Ljung-Box):

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k}; \quad n > k \quad (14)$$

Wilayah kritis:

$$Q > \chi^2_{(\alpha; K-p-q)}$$

dengan:

- K : lag maksimum
- n : jumlah data (observasi)
- k : lag ke-k
- p, q : order dari ARMA (p,q)
- $\hat{\rho}_k$: autokorelasi residual lag ke-k

3.5. Ukuran Ketepatan Peramalan

MAPE merupakan ukuran yang dipakai untuk mengetahui persentase penyimpangan hasil peramalan. Jika X_i adalah data aktual untuk periode i dan F_i adalah hasil peramalan untuk periode yang sama, maka MAPE dapat dihitung dengan formula berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \left(\frac{X_i - F_i}{X_i} \right) \times 100\% \right| \quad (15)$$

Interpretasi dari hasil perhitungan MAPE yaitu [8]:

- < 10% : *highly accurate forecasting*
- 10%-20% : *good forecasting*
- 20%-50% : *reasonable forecasting*
- >50% : *weak and inaccurate predictability*

3.6. Ukuran Keandalan Peramalan

Tracking signal adalah ukuran toleransi yang digunakan untuk menentukan sampai periode ke berapa peramalan dapat dilakukan. Jika nilai-nilai *tracking signal* berada di luar batas yang dapat diterima yaitu ± 5 maka model peramalan harus ditinjau kembali [9].

Tracking signal dapat dihitung dengan formula:

$$\text{Tracking Signal} = \frac{\sum_1^n e_n}{\sum_1^n |e_n| / n} \quad (16)$$

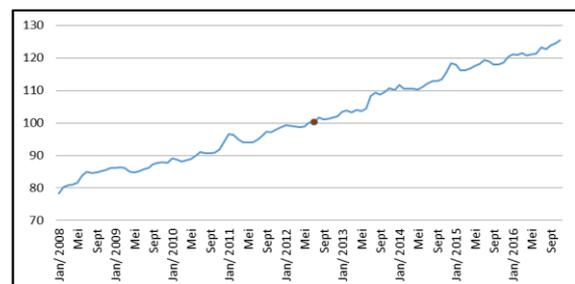
4. Pembahasan Hasil

4.1. Gambaran IHK Kota Padangsidempuan

Penelitian ini menggunakan data IHK Kota Padangsidempuan periode bulanan mulai Januari 2008 sampai November 2016 yang diperoleh dari web BPS Kota Padangsidempuan [10].

Perkembangan IHK Kota Padangsidempuan pada Januari 2008 sampai November 2016 yang disajikan pada gambar 1 menunjukkan pola tren dan juga terjadi volatilitas nilai indeks di setiap bulannya. Fenomena ini mengindikasikan bahwa indeks harga sepanjang tahun 2008 hingga akhir 2016 cenderung terus meningkat serta terjadi fluktuasi yang disebabkan adanya perubahan harga komoditas. Perubahan harga tersebut disebabkan oleh adanya intervensi pemerintah, adanya efek musiman seperti bulan Ramadhan, Idul Fitri, tahun ajaran baru dan faktor lainnya.

Keadaan IHK Kota Padangsidempuan sebelum periode Juni 2012 menunjukkan nilai indeks di bawah 100, hal ini mengindikasikan bahwa kondisi harga barang dan jasa secara umum di Kota Padangsidempuan sebelum periode Juni 2012 lebih murah dibandingkan setelah Juli 2012. Begitu pula sebaliknya, data IHK setelah Juli 2012 menunjukkan nilai indeks di atas 100 yang mengindikasikan harga barang dan jasa secara umum lebih mahal dibandingkan keadaan tahun 2012 yang merupakan dasar.



Gambar 1. Perkembangan IHK Kota Padang Sidempuan Tahun 2008-2016

4.2. Pengujian Pola Musiman

Pada gambar 1 perkembangan data IHK Kota Padangsidempuan memiliki pola tren yang jelas, akan tetapi untuk melihat pola musiman perlu dilakukan pengujian secara statistik.

Pengujian dengan menggunakan formula (1), (2) dan (3) serta dengan bantuan *software* R diperoleh hasil bahwa data IHK Kota Padang Sidempuan mengikuti pola musiman dengan periode 6 bulanan atau semesteran.

4.3. Singular Spectral Analysis

4.3.1. Embedding

Pada tahap ini akan diperoleh matriks lintasan untuk kemudian didekomposisi sesuai dengan nilai singularnya. Namun sebelumnya, harus ditentukan terlebih dahulu *window length* (L)-nya. Penentuan nilai *window length* (L) dilakukan dengan *tracking* dalam dua tahap yaitu tahap pertama menghitung MAPE terkecil pada *window length* nilai puluhan, kemudian setelah mendapat *window length* terbaik pada tahap satu maka dilakukan *tracking* tahap dua dengan mencari nilai satuan lima keatas dan lima kebawah.

Tabel 1. Tracking Tahap I Windows Length

L	L=10	L=20	L=30	L=40	L=50
MAPE	2,302	0,917	0,949	1,529	1,997

Dari tabel 1 dapat terlihat bahwa *window length* dengan nilai 20 menunjukkan nilai MAPE terkecil, yaitu 0,917%. *Tracking window length* dilakukan lagi dengan mencari nilai satuan terkecil diantara nilai 20. Proses *tracking window length* tahap II dapat dilihat pada tabel berikut.

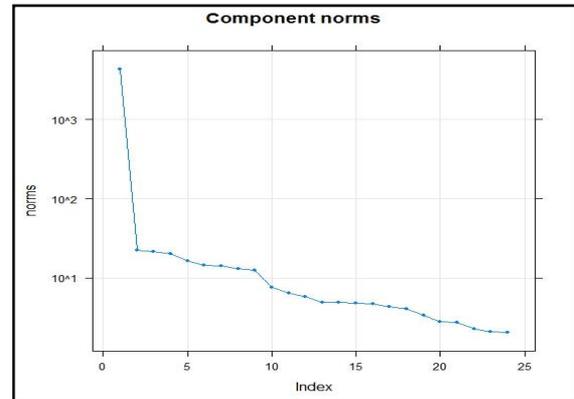
Tabel 2. Tracking Tahap II Windows Length

L	MAPE	L	MAPE
15	1,257	21	1,118
16	1,764	22	0,925
17	1,861	23	1,002
18	1,475	24	0,770
19	1,202	25	0,958

Tabel 2 menunjukkan nilai MAPE antara *windows length* 21-25 pada proses *tracking signal* tahap II. Dari tabel 2 tersebut diperoleh bahwa *window length* dengan L=24 menunjukkan nilai MAPE terkecil sehingga dapat dikatakan bahwa dalam penelitian ini *window length* yang terbaik adalah 24 dan matriks lintasan yang terbentuk berukuran 24x78, yaitu:

$$\begin{vmatrix} 78,23 & 80,32 & \dots & 87,74 \\ 80,32 & 80,91 & \dots & 89,15 \\ \vdots & \ddots & \ddots & \vdots \\ 87,74 & 89,15 & \dots & 121,04 \end{vmatrix}$$

4.3.2. SVD



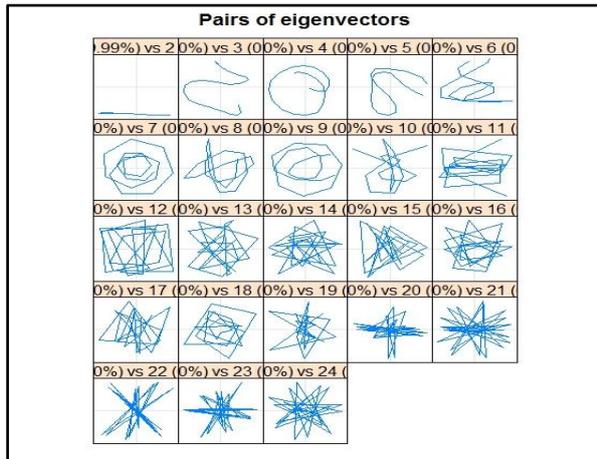
Gambar 2. Plot Eigen Value

Pada tahap SVD terbentuk *eigen value* dan *eigen vector* dari matriks lintasan. *Eigen value* yang diperoleh disajikan dalam gambar 2 berikut.

Dari gambar 2 dapat dilihat bahwa nilai *eigen value* untuk $L_1 = 4346,124$ merupakan nilai terbesar yang berarti yang berarti *eigenvalue* dari L_1 memberikan pengaruh terbesar dari komponen deret waktu terhadap karakteristik data dibandingkan dengan yang lainnya. Hal ini dapat juga diartikan bahwa pengaruh komponen pertama sangat besar pada pembentukan rekonstruksi sinyal. *Eigenvalue* selanjutnya cukup jauh berbeda dengan yang pertama dan cenderung menurun. Dari penurunan ini dapat diketahui dua hal, yaitu komponen periodik dan *noise*. Komponen periodik dengan periodisasi yang berbeda akan memiliki nilai singular yang berdekatan [4]. Ini terjadi pada nilai singular 1 hingga 15. Sedangkan penurunan perlahan (*eigenvalue* 16 sampai 24) menunjukkan adanya *noise*.

4.3.3. Grouping

Proses pengelompokan masih bersifat subjektif yang dilakukan berdasarkan plot berpasangan dari *eigen vector*. Plot yang berbentuk simetris mengindikasikan pola trend dan musiman sedangkan plot yang berbentuk random menunjukkan *noise*.



Gambar 3. Plot Berpasangan *Eigen Vector*

Berdasarkan gambar 3, terlihat bahwa pasangan *eigenvector* 1-15 adalah gabungan pola tren dengan pola periodik. Komponen trend dan periodik tidak dapat digabungkan menjadi satu kelompok karena akan terdapat *noise*. Komponen trend menjadi tidak halus karena masih mengandung komponen periodik [11].

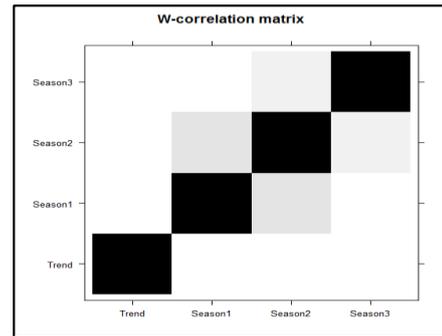
Grouping dilakukan sampai periode ke-15. Hal ini dapat disimpulkan dari pola sudah tidak dapat diidentifikasi lagi (berpola acak) Berdasarkan identifikasi diatas, dengan *window length* $L = 24$ terbentuk sebanyak 4 grup yang terdiri dari 1 *group* trend dan 3 *group* musiman. Komponen yang terhimpun dalam masing-masing group disajikan dalam tabel 3.

Tabel 3. Pengelompokan Komponen

Grup	Komponen	<i>Eigentriple</i>
1	Trend	1
2	Season 1	2-6
3	Season 2	6-9
4	Season 3	10-15

Berdasarkan group yang telah terbentuk akan dilakukan pengecekan *weak seperability* antar group untuk memastikan bahwa antar group sudah tidak ada korelasi yang kuat.

Pada gambar 4 tampak bahwa hubungan antar group cukup lemah yang ditandai dengan korelasi antar group yang tersisir abu-abu.



Gambar 4. Plot Matriks Korelasi Antar Group

4.3.4. Diagonal Averaging

Tabel 4. Proses Perhitungan *Diagonal Averaging*

t	IHK Aktual	Rekonstruksi				Diagonal Averaging	Residual
		Tren	Season 1	Season 2	Season 3		
1	78.23	80.609	-1.121	-0.418	-0.440	78.63	-0.400
2	80.32	81.004	-0.753	-0.336	0.200	80.115	0.205
3	80.91	81.365	-0.489	-0.316	0.198	80.758	0.152
...
99	121.51	122.187	-1.227	0.152	0.219	121.194	0.316
100	120.67	122.654	1.731	-0.008	0.167	121.082	-0.412
101	121.04	123.130	-1.970	0.342	-0.613	120.889	0.151

Pada tahap ini, hasil dari ekspansi matriks berdasarkan proses *grouping* dijumlahkan untuk dihitung sesuai perhitungan *diagonal averaging* agar memperoleh deret baru. Perhitungan *diagonal averaging* menggunakan hasil penjumlahan matriks ekspansi yang menghasilkan deret baru. Proses perhitungannya dapat dilihat pada tabel 4 berikut.

4.4. Peramalan SSA

Koefisien *Linear Recurrent Formula* (a_j) yang diperoleh dari persamaan (12) yaitu:

Tabel 5. Koefisien Linear Recurrent Formula (a_j)

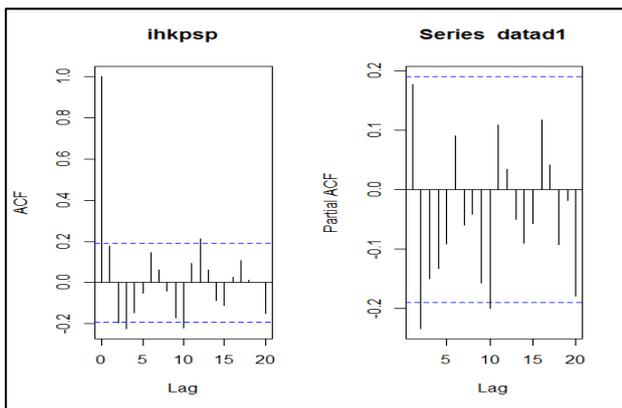
No.	a_j	No.	a_j	No.	a_j
1	-0.065	9	0.023	17	-0.059
2	-0.073	10	0.072	18	0.054
3	-0.032	11	-0.118	19	-0.013
4	0.215	12	-0.075	20	0.013
5	-0.021	13	0.126	21	0.003
6	-0.216	14	0.000	22	-0.250
7	-0.022	15	0.044	23	0.302
8	0.007	16	-0.058		

Dengan menggunakan persamaan (11) dan koefisien pada tabel 5 akan diperoleh hasil peramalannya.

4.5. SARIMA

Pada tahap awal, dilakukan pengecekan stasioneritas data dengan uji ADF dan diperoleh nilai $p\text{-value} = 0.357$. Sehingga disimpulkan data tidak stasioner. Selanjutnya data akan di-differencing pada $d=1$ agar data stasioner dalam mean. Setelah data di-differencing maka data IHK sudah stasioner, hal ini dapat dibuktikan jika dilakukan uji ADF pada data $d=1$ maka diperoleh nilai $p\text{-value} = 0.01$ yang berarti data sudah stasioner.

Selanjutnya, dilakukan plot ACF dan PACF untuk identifikasi awal orde ARIMA.



Gambar 5. Plot ACF dan PACF

Plot ACF pada gambar 5 menunjukkan *cut off* terjadi pada lag ke-3 yang berarti orde MA bernilai $p = 3$, sedangkan pada plot PACF terjadi *cutoff* pada lag ke-2 yang berarti orde AR bernilai $q = 2$. Sehingga identifikasi model SARIMA sementara adalah $(2,1,3)(2,1,3)$. Selanjutnya akan dilakukan uji coba model SARIMA beberapa orde dengan *software* R untuk memperoleh model terbaik dan memenuhi uji asumsi.

Tabel 6. Hasil Simulasi SARIMA dan Uji Asumsi

Model SARIMA	AIC	Signifikan Koef. Model	White Noise	Residual Normal
$(2,1,3)(2,1,3)_6$	245.9	Ya	Ya	Tidak
$(1,1,1)(0,1,1)_6$	243.3	Tidak	Ya	Ya
$(0,1,1)(0,1,1)_6$	243.0	Ya	Ya	Ya

$(0,1,2)(0,1,1)_6$	242.8	Tidak	Ya	Ya
$(0,1,3)(0,1,1)_6$	244.8	Tidak	Ya	Ya
$(0,1,2)(0,1,2)_6$	244.7	Ya	Ya	Ya
$(0,1,1)(0,1,2)_6$	244.9	Ya	Ya	Ya
$(0,1,1)(1,1,2)_6$	264.1	Ya	Ya	Ya

Dari tabel 6 diatas, diperoleh model terbaik yang memiliki nilai AIC terkecil dan memenuhi semua uji asumsi yaitu model SARIMA $(0,1,1)(0,1,1)_6$. Model SARIMA $(0,1,1)(0,1,1)_6$ dapat dituliskan dalam persamaan berikut:

$$(1 - B)(1 - B^6)Y_t = (1 - 0.2671 B)(1 - B^6)a_t.$$

Selanjutnya, dengan model tersebut dapat dilakukan permalan IHK untuk beberapa bulan ke depan.

4.6. Evaluasi Hasil Peramalan SSA Dengan Model SARIMA

Dari hasil analisis dan pembahasan diatas, tingkat ketepatan dan kestabilan peramalan pada metode SSA dan SARIMA disajikan dalam tabel 7. Nilai MAPE dari kedua metode sangat kecil (dibawah 10 persen) sehingga bisa dikatakan peramalan dengan SSA dan SARIMA $(0,1,1)(0,1,1)_6$ tingkat akurasi sangat tinggi. Hal ini sejalan dengan penelitian yang dilakukan sebelumnya oleh [4] bahwa metode SSA dan SARIMA sama-sama memiliki akurasi yang sangat tinggi dalam meramalkan jumlah kematian akibat kecelakaan di USA.

Sementara itu, berdasarkan nilai *tracking signal* diketahui bahwa permalan IHK Kota Padangsidempuan baik dengan metode SSA maupun SARIMA stabil pada peramalan hingga 5 bulan ke depan saja karena nilai *tracking signal* yang diperoleh antara -5 sampai +5 di setiap bulannya, sedangkan pada bulan ke-6 nilai *tracking signal*-nya sudah lebih besar dari 5 dimana hal ini mengindikasikan bahwa peramalan sudah tidak stabil pada bulan ke-6.

Tabel 7. Tracking Signal Metode Peramalan SSA dan SARIMA

Periode	SSA Forecasting		SARIMA (0,1,1)(0,1,1) ₆	
	Resid.	Tracking Signal	Resid.	Tracking Signal
Des/2016	-1.179	-1.000	-0.699	-1
Jan/2017	-0.098	-2.000	0.063	-1.668
Feb/2017	-0.825	-3.000	-0.581	-2.717
Mar/2017	0.209	-3.278	0.504	-1.543
Apr/2017	-0.605	-4.285	1.050	0.581
Mei/2017	-2.812	-5.563	1.560	2.552
MAPE	0,770		0,559	

Tabel 8. Perbandingan Hasil Peramalan Data IHK Kota Padangsidempuan dengan Metode SSA dan SARIMA

Periode Peramalan	Metode Peramalan	
	SSA Forecasting	SARIMA (0,1,1)(0,1,1) ₆
Des/ 2016	122.499	122.0194
Jan/ 2017	123.328	123.1667
Feb/ 2017	123.555	123.3114
Mar/ 2017	123.541	123.2455
Apr/ 2017	124.975	123.3203

Berdasarkan tabel 8 diatas, tampak bahwa hasil peramalan IHK Kota Padangsidempuan menunjukkan pola yang terus meningkat selama 5 bulan ke depan atau dapat juga dikatakan akan terjadi inflasi untuk 5 bulan ke depan. Hasil peramalan pada metode SSA menunjukkan akan terjadi inflasi yang cukup tinggi pada April 2017 sementara itu pada metode SARIMA menunjukkan inflasi yang terjadi selama lima bulan ke depan cenderung tidak begitu melonjak tinggi.

5. Kesimpulan

Berdasarkan hasil analisis yang dilakukan, dapat disimpulkan bahwa:

- Dengan *Singular Spectral Analysis* data IHK Kota Padang Sidempuan memiliki *length window* (L) sebesar 24 dan group sebanyak 4 (1 kelompok trend dan 3 kelompok musiman) dengan periode musiman terjadi di setiap semester

- Ketepatan hasil peramalan data IHK Kota Padang Sidempuan dengan metode SSA dan SARIMA (0,1,1)(0,1,1)₆ sama-sama berada pada kategori *highly accurate*
- Keandalan hasil peramalan data IHK Kota Padang Sidempuan dengan metode SSA dan SARIMA (0,1,1)(0,1,1)₆ sama-sama stabil/andal untuk meramalkan IHK 5 bulan ke depan
- Peramalan data IHK Kota Padang Sidempuan dengan metode SSA serta SARIMA (0,1,1)(0,1,1)₆ memiliki nilai yang tidak begitu jauh berbeda selama 4 bulan pertama. Namun peramalan pada bulan ke-5 dengan metode SSA menunjukkan peningkatan nilai IHK yang cukup tinggi atau terjadi inflasi yang cukup tinggi.
- Peramalan IHK baik dengan metode SSA maupun SARIMA sama-sama memiliki pola trend atau akan terjadi inflasi selama 5 bulan ke depan

Daftar Pustaka

- Darmawan,G, dkk, Perbandingan peramalan pada model singular spectrum analysis, Studi kasus : Curah Hujan Kota Bandung Dan Sekitarnya, Seminar Nasional Universitas Muhammadiyah Purwokerto, 2015
- No Kang Myung, Singular Spectrum Analysis, Graduate Thesis, University of California, Los Angeles, 2009
- BPS Sumatera Utara, Sumatera Utara Dalam Angka 2016. Medan: BPS SUMUT, (2016)
- Hassani, H., Singular Spectrum Analysis: Methodology and Comparison, Journal of Data Science 5(2007), 239-257
- Akhter Tahsina, Short-Term Forecasting Inflation of Inflation in Bangladesh with Seasonal ARIMA Processes, Munich Personal RePec Archive No. 43729, 2013, diakses melalui https://mpra.ub.uni-muenchen.de/43729/1/MPRA_paper_43729.pdf pada 15 Februari 2017
- Wei, W.W.S, Time Series Analysis Univariate and Multivariate Methods, 2nd Edition, Pearson Education Inc. (2006)
- Darmawan,G, Identifikasi Pola Data Curah Hujan Pada Proses Grouping Dalam Metode Singular Spectrum Analysis. Seminar Nasional Pendidikan Matematika 2016

- [8] Lewis, C.D, Industrial and business forecasting methods, Butterworths (1982)
- [9] Abraham, Bovas and Johannes Ledolter, Statistical Methods for Forecasting, Wiley (1983)
- [10] www.padangsidimpuankota.bps.go.id diakses pada 1 Februari 2017
- [11] Sakinah, A. M., Perbandingan Stabilitas Hasil Peramalan Suhu Dengan R-Forecasting Dan V-Forecasting SSA Untuk Long Horizon, Tesis, Departemen Statistika, FMIPA UNPAD (2013)