PERBANDINGAN PERAMALAN EKSPOR SEKTOR AGRIKULTUR MENGGUNAKAN *SINGULAR SPECTRUM ANALYSIS* (SSA) DAN *SEASONAL-ARIMA*

Irtania Muthia Rizki[1], Rani Andriani[2], Gumgum Darmawan[3],
[1]Mahasiswa Pascasarjana Statistika Terapan FIMIPA UNPAD
email: irtaniamuthiarizki@gmail.com
[2]Mahasiswa Pascasarjana Statistika Terapan FMIPA UNPAD
email: randriani99@gmail.com
[3]Departemen Statistika FMIPA UNPAD
email: gumstat@gmail.com

Abstrak

Seiring dengan perkembangan zaman, lahan pertanian semakin berkurang, disebabkan oleh peningkatan alih sektor pertanian ke sektor industri. Besarnya tingkat pengalihan serta jumlah tenaga kerja yang menurun menyebabkan kekurangan terhadap ketersediaan pangan. Dengan kondisi seperti ini negara-negara agraris seperti Indonesia memiliki peluang untuk memasarkan hasil pertaniannya. Guna memanfaatkan besarnya peluang petanian pada pasar dunia maka daerah-daerah utama penghasil pertanian di Indonesia perlu dipertahankan. Ekspor pertanian (agrikultur) selain sebagai penyedia pangan, juga penyedia lapangan pekerjaan serta penyumbang devisa negara. Karena besarnya manfaat dari ekspor agrikultur tersebut maka perlu dilakukan peramalan agar dapat digunakan sebagai informasi bagi pemerintah serta dunia usaha dalam meningkatkan ekspor dari sektor agrikultur tersebut. Data ekspor sektor agrikultur merupakan data musiman yang memiliki periode 12. Untuk meramalkannya dapat digunakan metode SARIMA dan SSA yang digunakan untuk data musiman. Hasil analisis menunjukkan metode SSA menghasilkan nilai MAPE yang lebih kecil yaitu sebesar 9,95%, yang artinya metode ini lebih baik untuk digunakan. Hasil peramalan menunjukkan ekspor sektor agrikultur bulan April sebesar 377.9908 Juta US$, untuk bulan Mei sebesar 402.6907 Juta US$, bulan Juni sebesar 404.7789 Juta US$ dan untuk bulan Juli sebesar 392.6011 Juta US$.

Kata Kunci : Ekspor Sektor Agrikultur , *Seasonal Autoregressive Integrated Moving Average* (SARIMA), *Singular Spectrum Analysis* (SSA)

1. PENDAHULUAN

Indonesia dikenal memiliki tanah yang luas dan subur, sehingga menghasilkan hasil pertanian yang melimpah. Pertanian di Indonesia merupakan sektor penggerak perekonomian yang penting. Selain sebagai penyedia pangan, pertanian juga penyedia lapangan pekerjaan serta penyumbang devisa melalui ekspor.

Seiring dengan perkembangan zaman, lahan pertanian semakin berkurang, disebabkan oleh peningkatan alih sektor pertanian ke sektor industri. Lahan yang awalnya digunakan sebagai lahan pertanian dialihkan guna perluasan pemukiman penduduk atau pendirian perusahaan ataupun mall. Selain itu menurunnya jumlah tenaga kerja di sektor pertanian juga menjadi ancaman pada produktifitas pertanian. Besarnya tingkat pengalihan serta jumlah tenaga kerja yang menurun menyebabkan kekurangan terhadap ketersediaan pangan. Kondisi seperti ini negara-negara agraris seperti Indonesia memiliki peluang untuk memasarkan hasil pertaniannya ke pasar internasional.

Besarnya peluang Indonesia dalam memasarkan hasil pertanian di pasar Internasional harus dimanfaatkan, yaitu dengan mempersiapkan dan lain sebagainya. Peningkatan ilmu pengetahuan serta teknologi perlu ditingkatkan agar petani dapat mengelola lahan pertanian secara efisien dan mampu

meningkatkan produktivitasnya seiring peningkatan ilmu pengetahuan dan teknologi.

Guna memanfaatkan peluang pada pasar dunia sehingga daerah-daerah penghasil utama pertanian perlu dipertahankan. Di Indonesia komoditi penyumbang ekspor terbesar merupakan kelapa sawit, rempah-rempah dan kakao. Berdasarkan data dari Kementrian Perdagangan hasil dari ekspor pertanian (agrikultur) yaitu pada Januari 2017 adalah sebesar 419 juta US$. Besarnya hasil ekspor pada sektor agrikultur terhadap devisa Negara maka perlu dilakukan peramalan terhadap hasil ekspor tersebut agar selalu mengalami peningkatan. Jika dalam hasil peramalan mengalami penurunan maka pemerintah dapat melakukan kebijakan atau perencana tertentu.

Analisis yang sama mengenai peramalan ekspor agrikultur Indonesia pernah dilakukan Pujiyati (2001). Namun penelitian ini tidak memperhatikan musiman yang terjadi pada data ekspor agrikultur. Karena itu penelitian ini melakukan perbandingan antara metode SARIMA (*Seasonal Autoregressive Integrated Moving Average*) dengan metode SSA (*Singular Spectrum Analysis*). Metode SARIMA dan Metode SSA merupakan metode yang digunakan untuk menangani data musiman. Kedua metode ini digunakan untuk melihat model yang terbaik karena data dari ekspor sektor agrikultur.

Berdasarkan uraian tersebut, masalah yang dapat diidentifikasi dari penelitian ini adalah metode yang terbaik dapat digunakan untuk memprediksi ekspor sektor agrikultur serta peramalan rata-rata ekspor sektor agrikultur pada bulan April hingga bulan Juli tahun 2017.

2. KAJIAN LITERATUR

Pada penelitian ini, akan dikaji 2 metode untuk data musiman yaitu SSA dan metode SARIMA sehingga didapatkan model terbaik untuk peramalan data ekspor sektor agrikultur.

2.1 SARIMA (*Seasonal Autoregressive Integrated Moving Average*)

Musiman adalah kecenderungan mengulangi pola tingkah gerak dalam periode musiman. Model SARIMA merupakan model ARIMA yang digunakan untuk menyelesaikan data deret waktu musiman yang terdiri dari dua bagian, yaitu bagian tak musiman dan bagian musiman (Neswin & Retno,2015). Bagian non-musiman dari metode ini adalah model ARIMA.

Secara umum bentuk model SARIMA $(p,d,q)(P,D,Q)^S$ adalah (Wei,2006) :

$$\phi_P(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D Z_t = \delta + \theta_q(B)\Theta_Q(B^S)a_t \quad ..(1)$$

dimana Z_t= variabel respon waktu ke-t, a_t= error pada waktu t, $(1-B)^d$= pembeda periode d non seasonal, $(1-B^S)^D$= pembeda periode D seasonal, $\phi_P(B)$ = operator AR (p) non seasonal, $\Phi_P(B^S)$ = operator AR(p) seasonal, $\theta_q(B)$ = operator MA(q) non seasonal, $\Theta_Q(B^S)$ = operator MA(q) seasonal, δ = konstanta

Langkah-langkah pemodelan metode SARIMA (*Seasonal Autoregressive Integrated Moving Average*) adalah mengidentifikasi model, melakukan pendugaan parameter model, memeriksa residual, barulah model digunakan untuk peramalan jika model memenuhi syarat.

Dalam melakukan pemodelan data menggunakan SARIMA diperlukan data yang stasioner dalam rata-rata maupun stasioner dalam varians. Untuk melihat kestasioneran data bisa dilihat dari plot data, plot ACF serta plot PACF nya. Ketidakstasioneran data dalam means dapat diatasi dengan proses pembedaan (differencing), sedangkan kestasioneran data dalam varians dapat dilihat dengan transformasi berdasarkan nilai λ.

Setelah data yang digunakan stasioner maka langkah selanjutnya dilakukan penaksiran dan pengujian parameter. Dalam menentukan model SARIMA yang terbaik, harus memperhatikan:

a. Signifikansi Parameter

Model peramalan yang diperoleh diuji signifikansi parameter modelnya dengan hipotesis bahwa estimasi parameter 0 melawan hipotesis alternatif estimasi alternatif tidak sama dengan 0. Dimana statistik uji (Ukhra, 2014) :

$$t_{hitung} = \frac{\text{estimasi parameter}(\phi_1)}{\text{standart error parameter}} \quad \ldots(2)$$

hipotesis akan ditolak jika $t_{hitung} \geq t_{\frac{\alpha}{2},n-1}$

b. Residual Berdistribusi Normal

Pengujian kenormalan dari residual dapat dilakukan dengan menggunakan *Kolmogorov-Smirnov* dengan hipotesis residual berdistribusi normal melawan hipotesis alternatif residual tidak berdistribusi normal.

c. Residual Bersifat *White Noise*

Suatu residual model bersifat *white noise* artinya residual model tersebut telah memenuhi asumsi identik (variasi residual homogen) serta independen (antar residual tidak berkorelasi). Pengujian *white noise* dilakukan dengan menggunakan uji *Ljung-Box*. Hipotesis dari uji *Ljung*-Box yaitu residual *white noise* melawan hipotesis alternatif residual tidak *white noise*.

2.2 SSA (*Singular Spectrum Analysis*)

SSA (*Singular Spectrum Analysis*) merupakan teknik analisis deret waktu dan peramalan yang menggabungkan unsur analisis klasik *time series, multivariate statistics, multivariate geometric, dynamical system,* dan *signal processing*.

Metode ini merupakan metode *time series* yang *powerful* dan bersifat non-parametrik. Pendekatan dari metode ini berbeda dengan metode peramalan bersifat parametrik yang membutuhkan asumsi data stasioner yang dapat digambarkan secara praktis stasioner pada nilai tengah (*mean*), varians, dan lain-lain.

Metode ini didasarkan pada nilai dekomposisi singular dari matriks khusus yang dibangun pada waktu tertentu. Baik model parametrik atau stasioneritas diasumsikan untuk kurun waktu tertentu. Hal ini membuat SSA metode bebas model sehingga memungkinkan SSA memiliki rentang sangat luas penerapanya.

Pengelompokkan komponen-komponen yang ada dalam deret waktu dengan menggunakan metode SSA (*Singular Spectrum Analysis*) akan mendukung hasil peramalan yang baik dengan menunjukkan MSE atau MAPE dari nilai ramalan dan nilai sesungguhnya. Selain itu, hasil rekonstruksinya akan lebih mendekatkan hasil peramalan dengan data sebenarnya.

Dalam algoritma SSA, misalkan terdapat data deret waktu $X = X_N = (x_1, \ldots, x_N)$ dengan panjang *N*. Diasumsikan bahwa $N > 2$ dan tidak terdapat data hilang atau dapat ditulis $x_i \neq 0$. Algoritma dasar SSA terdiri dari dua buah tahap yaitu dekomposisi dan rekonstruksi (Golyandina & Zhigljavsky, 2013).

2.2.1 Dekomposisi

Pada proses dekomposisi terdapat dua buah proses yaitu proses *Embedding* dan proses *SVD* (*Singular Value Decomposition*).

a. *Embedding*

Langkah pertama pada tahap dekomposisi adalah *embedding* yaitu memetakan data deret waktu pada lag vektor yang berukuran *L* dengan $K = N - L + 1$.

$X_i = (x_i, \ldots, x_{i+L-1})^T$ dengan $(1 \leq i \leq K)$ …(3)

Dari lag vektor X_i tersebut kemudian dibentuk matriks lintasan berukuran *L x K* dengan semua elemen pada anti diagonalnya bernilai sama.

$$\mathbf{X} = [X_1 : \ldots : X_N]$$

$$= (x_{ij})_{i,j=1}^{L,K} = \begin{bmatrix} x_1 & x_2 & \cdots & x_L \\ x_2 & x_3 & \cdots & x_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & \cdots & x_N \end{bmatrix} \quad \ldots(4)$$

Lag vektor X_i adalah kolom pada matriks lintasan **X**. Tahap ini merupakan penentuan parameter *window length* (*L*) dengan ketentuan $2 < L < N/2$ (Golyandina & Zhigljavsky, 2013).

b. SVD (*Singular Value Decomposition*)

Langkah selanjutnya yaitu tahap dekomposisi adalah membuat *Singular Value Decomposition* (SVD) dari matriks lintasan. Diketahui bahwa matriks $\mathbf{S} = \mathbf{X}\mathbf{X}^{\mathbf{T}}$ dan dinotasikan dengan $\lambda_1, \dots, \lambda_L$ yang merupakan *eigen value* dari matriks **S** dengan urutan yang menurun $\lambda_1 \geq \cdots \geq \lambda_L \geq 0$ dan $U_1, \dots, U_L$ merupakan *eigen vector* dari matriks **S**.

Rank dari matriks **X** dapat ditunjukkan dengan $d = \operatorname{rank}\mathbf{X} = \max\{i, \lambda_i > 0\}$ dan $V_i = \mathbf{X}^{\mathbf{T}} U_i / \sqrt{\lambda_i}$ dengan *i* = 1, …, *d*. SVD dari matriks lintasan dapat ditulis sebagai berikut :

$$\mathbf{X} = \mathbf{X}_1 + \mathbf{X}_2 + \cdots + \mathbf{X}_{\mathrm{d}} \quad \dots(5)$$

dimana $\mathbf{X}_i = \sqrt{\lambda_i} U_i V_i^T$, sehingga :

$$\mathbf{X} = \mathbf{X}_1 + \mathbf{X}_2 + \cdots + \mathbf{X}_{\mathrm{d}} = \sqrt{\lambda_1} U_1 V_1^T + \sqrt{\lambda_2} U_2 V_2^T + \cdots + \sqrt{\lambda_d} U_d V_d^T$$

Matriks **X** terbentuk dari *eigen vector* U_i, *singular value* $\sqrt{\lambda_i}$ dan *principal component* V_i^T. Ketiga elemen pembentuk SVD ini disebut dengan *eigentriple* (Darmawan dkk, 2015).

2.2.2 Rekonstruksi

Parameter yang memiliki peran penting dalam tahapan rekonstruksi adalah *grouping effect* (*r*). Pada tahap ini terdapat 2 proses yaitu:

a. *Eigentriple Grouping*

Pada langkah ini, matriks lintasan berukuran *L x K* diuraikan menjadi beberapa sub-kelompok yaitu pola tren, musiman, periodic, dan *noise*. Pengelompokkan berhubungan erat dengan pemecahan matriks $\mathbf{X}_i$ menjadi beberapa kelompok dan menjumlahkan matriks dalam masing-masing kelompok. Matriks $\mathbf{X}_i$ akan dipartisi ke dalam *m* subset disjoin $\boldsymbol{I} = \{I_1, I_2, \dots, I_m\}$.

Misalkan $\boldsymbol{I} = \{I_1, I_2, \dots, I_p\}$ matriks resultan $\mathbf{X}_I$ dengan indeks $i_1, i_2, \dots, i_p$ sesuai dengan kelompok $\boldsymbol{I}$ yang dapat didefinisikan sebagai $\mathbf{X}_{\mathrm{I}} = \mathbf{X}_1 + \cdots + \mathbf{X}_{\mathrm{ip}}$. Kemudian $\mathbf{X}_i$ disesuaikan dengan kelompok $\boldsymbol{I} = \{I_1, I_2, \dots, I_m\}$, maka $\mathbf{X} = \mathbf{X}_1 + \mathbf{X}_2 + \cdots + \mathbf{X}_{\mathrm{d}}$ dapat diekspansi menjadi (Darmawan dkk, 2015):

$$\mathbf{x} = \mathbf{X}_{\mathrm{i1}} + \mathbf{X}_{\mathrm{i2}} + \cdots + \mathbf{X}_{\mathrm{im}} \quad \dots(6)$$

b. *Diagonal Averaging*

Pada tahap ini akan dilakukan transformasi dari hasil pengelompokkan matriks $\boldsymbol{X}_{\boldsymbol{I}j}$ ke dalam seri baru dengan panjang N. Misalkan **F** merupakan matriks berdimensi *L x K* dengan masing-masing elemen f_{ij}, dimana $1 \leq i \leq L$ dan $1 \leq j \leq K$. Diketahui bahwa $L^* = \min(L, K)$, $K^* = \max(L, K)$ dan $N = L + K - 1$. Diperoleh $f_{ij}^* = f_{ij}$ jika $L < K$ dan $f_{ij}^* = f_{ji}$ untuk lainnya. Dengan menggunakan *diagonal averaging*, maka matriks **Y** ditransformasi ke dalam seri $y_1, \dots y_N$ dengan rumus sebagai berikut :

$$f_k = \begin{cases} \frac{1}{i}\sum_{j=1}^{i} a_{k,i-j+1} P_{j,k} & untuk\, 1 \leq i \leq L-1 \\ \frac{1}{L}\sum_{j=1}^{L} a_{k,i-j+1} P_{j,k} & untuk\, L \leq i \leq N-L+1 \\ \frac{1}{N-i+1}\sum_{j=i-N+L}^{L} a_{k,i-j+1} P_{j,k} & untuk\, N-L+2 \leq i \leq N \end{cases} \quad \dots(7)\ \dots(8)$$

dengan mengaplikasikan persamaan diatas pada matriks resultan $\boldsymbol{X}_{\boldsymbol{I}m}$ akan membentuk deret

$$\tilde{x}^{(k)} = (\tilde{x}_1^{(k)}, \dots, \tilde{x}_N^{(k)}).$$

Oleh karena itu, deret asli akan didekomposisikan menjadi jumlah dari *m* deret :

$$x_n = \sum_{k=1}^{m} \tilde{x}_n(k). \quad \dots(7)$$

(Darmawan dkk, 2015)

Dari kedua metode yang digunakan yaitu SARIMA dan SSA akan dihitung kriteria pemilihan model terbaik. Dibutuhkan kriteria untuk menentukan model yang terbaik dan akurat. Pemilihan model terbaik salah satunya dapat menggunakan *Mean Absolute Percentage Error* (MAPE) yaitu

$$MAPE = \frac{\sum_{t=1}^{n} \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|}{n} \text{x}100\% \quad \dots(8)$$

3. METODE PENELITIAN

Pada penelitian ini digunakan data ekspor sektor agrikultur pada periode April hingga Juli 2017. Data yang digunakan merupakan data dari kementrian perdagangan Januari 2009 hingga Januari 2017. Data ekspor sektor agrikultur merupakan data dalam satuan juta US$. Dalam komputasinya untuk SARIMA

menggunakan software Minitab 16 dan untuk SSA dengan software R 3.3.0.

4. HASIL DAN PEMBAHASAN

Dalam analisis akan dilakukan pembandingan peramalan jika menggunakan metode SARIMA dan menggunakan metode *Singular Spectrum Analysis* (SSA). Sebelum melakukan analisis data, maka terlebih dahulu dilakukan eksplorasi data berupa plot data yang digunakan. Berikut adalah plot data :

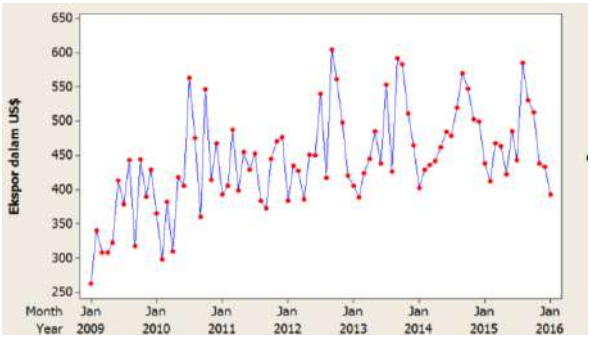

Gambar 1 Plot Ekspor Sektor Agrikultur

Berdasarkan plot di atas tampak bahwa data yang digunakan mengalami kenaikan dari Januari 2009 hingga pertengahan tahun 2010, namun setela itu sampai dengan Januari tahun 2017 data berfluktuatif di sekitar rata-rata. Dari plot data di atas juga didapatkan bahwa data ekspor sektor agrikultur diduga memiliki pola musiman. Selanjutnya juga akan di plot*Autocorrelation Function* (ACF) dan plot *Partial Autocorrelation Function* (PACF) dari data. Plotnya adalah sebagai berikut :

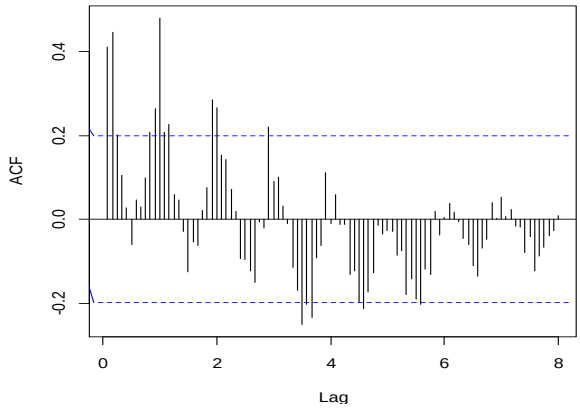

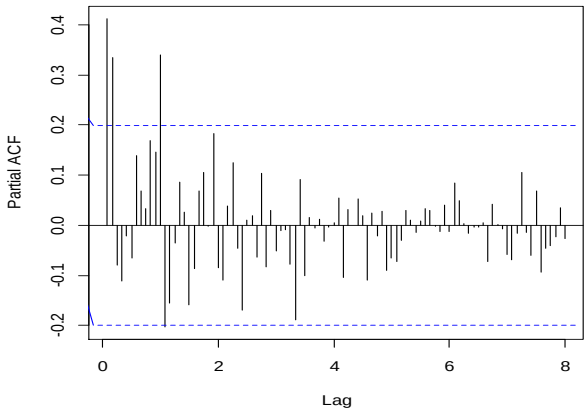

Gambar 2 Plot PACF Data

Dari plot ACF dan PACF tampak bahwa ACF membentuk pola *cut off* di lag 3 serta tampak bahwa data memiliki pola musiman, selain itu dari plot ACF juga dapat diketahui bahwa data yang digunakan merupakan data *sort memory*. Sementara untuk PACF *cut* off di lag 1.

4.1 *Seasonal Autoregressive Integrated Moving Average* (SARIMA)

Metode SARIMA merupakan salah satu model analisis untuk data runtut waktu yang mempunyai pola musiman. Proses pemodelan data pada metode ini melalui tahapan identifikasi model, tahap penaksiran parameter, *diagnostic checking*, dan penerapan model. Metode SARIMA ini dapat dilakukan pada data musiman *sort memory* yang memiliki parameter pembeda (d) berupa bilangan bulat. Hasil dari pengecekan parameter pembeda untuk data ekspor sektor agrikultur menggunakan *macro R* didapatkan d sebesar **0,072**. Parameter pembeda sebesar **0,072** dianggap sebagai bilangan bulat 0.

Analisis data dengan metode ini menggunakan *software Minitab 16*. Pada metode ini akan dilihat terlebih dahulu periode musiman dari data yang digunakan, dimana pada data ekspor sektor agrikultur memiliki periode 12. Setelah dilakukan pengecekan periode maka langkah selanjutnya akan dilihat pola *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) dari data *insample*. Dari plot data, plot ACF dan plot PACF maka akan terlihat apakah data

stasioner, pada data ekspor sektor agrikultur data telah stasioner dalam rata-rata namun belum stasioner dalam varians, sehingga dilakukan transformasi. Selanjutnya dari plot ACF dan PACF pada data yang telah stasioner menunjukkan pola cut off, dari plot ini akan terlihat model SARIMA apa yang baik digunakan. Model SARIMA yang diduga sesuai adalah sebagai berikut:

Tabel 4.1 Estimasi Parameter

No	Model	Uji Signifikansi Model	Uji White Noise	Normalitas	MAPE
1	SARIMA $(1,0,0)(1,1,0)_{12}$	Tidak Signifikan	White Noise	Normal	13.81%
2	SARIMA $(1,0,1)(1,1,0)_{12}$	Signifikan	White Noise	Normal	10.51%
3	SARIMA $(1,0,1)(1,1,1)_{12}$	Tidak Signifikan	White Noise	Normal	12.00%
4	SARIMA $(0,0,1)(0,1,1)_{12}$	Tidak Signifikan	White Noise	Normal	17.52%
5	SARIMA $(0,0,1)(1,1,1)_{12}$	Tidak Signifikan	White Noise	Normal	16.32%
6	SARIMA $(1,1,0)(1,1,1)_{12}$	Tidak Signifikan	Tidak White Noise	Normal	6.32%

Berdasarkan tabel di atas dapat diketahui bahwa SARIMA $(1,0,1)(1,1,0)_{12}$ yang memenuhi uji signifikansi model, white noise dan residual berdistribusi normal. Sehingga model ini yang paling baik digunakan untuk meramalkan data. Tahapan berikutnya yaitu tahapan penaksiran parameter berdasarkan model SARIMA $(1,0,1)(1,1,0)_{12}$. Hasil analisis yang didapatkan adalah seperti tabel di bawah:

Tabel 4.2 Estimasi Parameter

Type	Coef	SE Coef	t	P value
AR 1	0.8725	0.1824	4.78	0.000
SAR 12	-0.3234	0.1197	-2.70	0.009
MA 1	0.7161	0.2413	2.97	0.004
Constant	0.007644	0.0052	1.46	0.149

Setelah didapatkan model yang memiliki parameter signifikan maka langkah selanjutnya yaitu tahapan *diagnostic checking* terdiri dari pengecekan asumsi normalitas residual. Hasil pengecekan normalitas residual menggunakan Kolmogorov Smirnov menghasilkan nilai p value 0,150 yang bernilai lebih besar dari alpha sehingga dapat dikatakan residual berdistribusi normal. Pada tahap *diagnostic checking,* juga dilakukan pengujian L-jung Box yang memberikan hasil sebagai berikut:

Tabel 4.3 Uji *Ljung Box*

Lag	12	24	36	48
Chi-Square	12.8	30.2	42.0	51.0
Df	8	20	32	44
P-Value	0.120	0.067	0.112	0.217

Hasil pengujian *Ljung box* memberikan hasil nilai p-*value* yang semuanya bernilai lebih besar dari alpha yang artinya semua residual dari data sudah *white noise*. Jika residual berupa *white noise a*rtinya bahwa model yang terpilih sudah cocok dengan data. Sementara jika residual tidak *white noise* berarti harus melakukan pemilihan model ulang.

Berdasarkan signifikansi dari parameter, asumsi yang telah terpenuhi serta residual yang telah *white noise*, maka model yang terbentuk dari SARIMA $(1,0,1)(1,1,0)_{12}$ berdasarkan persamaan 1 adalah sebagai berikut:

$$Z_t = \delta_t + \Phi_1 Z_{t-12} - \Phi_1 Z_{t-24} + \phi_1 Z_{t-1} - \phi_1 Z_{t-13} - \phi_1 \Phi_1 Z_{t-13} + \phi_1 \Phi_1 Z_{t-25} + Z_{t-12} - \Theta_1 a_{t-1} + a_t$$

Dari Tabel 4.2, dengan memasukkan nilai parameter maka model yang terbentuk:

$$Z_t = 0.007644 - 0.3234 Z_{t-12} + 0.3234 Z_{t-24} + 0.8725 Z_{t-1} - 0.8725 Z_{t-13} + 0.2822 Z_{t-13} - 0.2822 Z_{t-25} + Z_{t-12} - 0.7161 a_{t-1} + a_t$$

Hasil peramalan metode ini akan dihitung ketepatan peramalannya berdasarkan data *insample*. Untuk mengukur ketepatan dari model SARIMA $(1,0,1)(1,1,0)_{12}$, untuk data ekspor sektor agrikultur maka digunakan *Mean Absolute Percentage Error* (MAPE). Nilai MAPE dari model SARIMA $(1,0,1)(1,1,0)_{12}$ adalah sebesar 10,51%.

4.2 *Singular Spectrum Analysis* (SSA)

Dalam proses SSA terdapat dua tahapan yang harus dilakukan yaitu Dekomposisi dan Rekonstruksi. Tahapan dekomposisi terdiri dari proses *Embedding* dan proses *Singular Value Decomposition (SVD).* Sedangkan tahapan Rekontruksi terdiri dari proses Pengelompokkan dan proses Perataan Diagonal.

Proses *embedding* yaitu mengubah deret waktu awal yang berdimensi satu menjadi deret multidimensi yang disebut dengan matriks lintasan. Kemudian tahapan ini

merupakan tahapan untuk menentukan nilai *Window Length* (L). Nilai L yang mungkin yaitu $2 < L < 48$. Melalui *Trial and Error* dilakukan pemilihan terhadap *L*, dengan melihat nilai *Mean Absolute Persentage Error* (MAPE) minimum , hasilnya sebagai berikut:

Tabel 4.4 MAPE dari Pemilihan Nilai L

Window Length	MAPE
L = 10	10.17%
L = 20	13.60%
L = 30	14.15%
L = 40	16.16%
L = 9	14.90%
L = 11	10.56%

Berdasarkan tabel di atas maka didapatkan *Window Length* (L) yang menghasilkan MAPE terkecil adalah ketika L=10. Maka untuk selanjutnya nilai *Window Length* yang digunakan adalah 10. Selanjutnya yaitu mendapat nilai K=85-10+1=75, sehingga untuk tahapan berikutnya yaitu pada proses SVD akan membuat matriks dengan L x K.. Pada Proses SVD menghasilkan 10 nilai *eigentriple* ($\sqrt{\lambda_i}, U_i, V_i$). 10 nilai *eigentriple* ini akan mendekomposisikan matriks lintasan menjadi penjumlahan dari beberapa matriks sesuai dengan nilai singularnya yang disebut dengan *Singular Value* Decomposition. *Eigentriple* terdiri dari *singular value* ($\sqrt{\lambda_1}, \ldots, \sqrt{\lambda_L}$), e*igenvector* ($U_1, \ldots, U_L$) dan *principal component* ($V_1, \ldots, V_L$). Nilai – nilai ini akan digunakan untuk memisahkan ke dalam beberapa komponen yaitu trend, musiman dan siklis, sehingga komponen ini dapat dikelompokkan, kemudian menjumlahkan matriks dalam setiap kelompok. Banyaknya kelompok yang terbentuk akan memperhatikan plot singular value sebagai berikut:

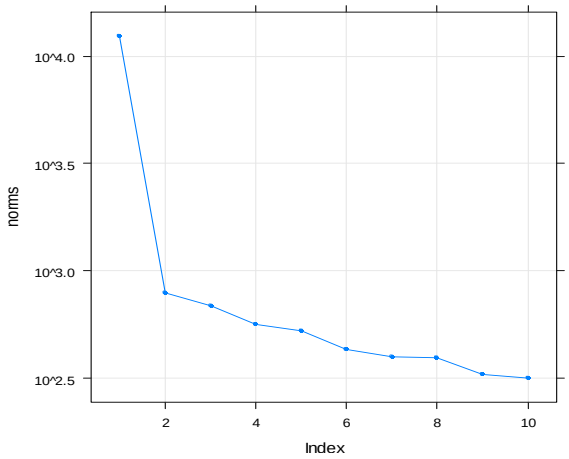

Gambar 3 *Singular Value*

Gambar 3 memperlihatkan bahwa *eigenvalue* pertama memiliki nilai yang paling besar. Hal ini menunjukkan bahwa pengaruh komponen pertama sangat besar pada pembentukan rekonstruksi sinyal.

Setelah tahap dekomposisi dilakukan, selanjutnya yang dilakukan adalah rekonstruksi. Tahap ini terdiri dari *grouping* dan *diagonal averaging*. Dengan memperhatikan *plot eigentriple*, diperoleh bahwa terdapat 3 pengelompokkan sebagi berikut:

Tabel 4.5 Nilai *Principal Component*

Grup	Komponen	*Eigentriple*
1	Periodik (12)	1,2,3
2	Periodik (6)	6
3	Periodik (3)	4,5,7,8,9,10

Berdasarkan hasil pengelompokkan maka terbentuk sebanyak 3 grup. Maka matriks SVD akan mengalami penyesuaian sesuai hasil *grouping* dan *eigentriple* yang terkandung. Setelah ini maka masuk ke tahap *diagonal averaging.* Pada tahap ini, hasil dari ekspansi matriks berdasarkan proses *grouping* dijumlahkan untuk dihitung sesuai perhitungan *diagonal averaging* agar memperoleh deret baru.

Untuk melakukan perhitungan ketepatan dalam melakukan peramalan dari data *insample*. akan dilihat dari nilai MAPE. Nilai yang didapatkan yaitu nilai MAPE sebesar 9,95%.

4.3 Kecocokan Model untuk Data Ekspor sektor agrikultur

Data ekspor sektor agrikultur merupakan data deret waktu yang memiliki pola musiman. Dari pengecekan data melalui *macro syntax* R, diketahui bahwa periode dari musiman adalah 12. Periode ini menunjukkan bahwa data membentuk pola tertentu yang berulang setiap 12 bulan. Hal ini terjadi karena permintaan akan ekspor sektor agrikultur selalu mengalami penurunan ketika lebaran Idul Fitri, penurunan ini terjadi karena konsumsi akan sektor agrikultur dalam Negeri meningkat, sehingga harus mencukupi permintaan dalam Negeri terlebih dahulu.

Hasil dari peramalan data ekspor sektor agrikultur dengan metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dan metode *Singular Spectrum Analysis* (SSA) menghasilkan ukuran ketepatan peramalan yang diukur melalui nilai MAPE menghasilkan nilai sebagai berikut:

Tabel 4.6 MAPE dari Kedua Metode

Model	MAPE
SARIMA $(1,0,1)(1,1,0)_{12}$	10.51%
SSA	9.95%

Berdasarkan tabel di atas tampak bahwa niali MAPE dari metode SSA bernilai lebih kecil dibandingkan dengan metode SARIMA $(1,0,1)(1,1,0)_{12}$. Sehingga metode SSA dianggap lebih cocok untuk digunakan pada data ekspor sektor agrikultur karena memiliki nilai MAPE yang lebih kecil.

Data ekspor sektor agrikultur yang digunakan yaitu data Januari 2009 hingga dengan Januari 2017. Sehingga untuk menjawab tujuan yaitu mengetahui ekspor sektor agrikultur pada lebaran Idul Fitri tahun 2017 maka perlu dilakukan peramalan sebanyak 6 data atau selama 6 bulan. Untuk mengetahui tingkat kebaikan atau keandalan dalam peramalan sepanjang 1 tahun maka dilakukan *tracking signal*. Hasil dari *tracking signal* menunjukkan hasil bahwa hingga pramalan hingga bulan Juli memiliki nilai *tracking signal* bernilai lebih besar dari -5 dan kurang dari 5. Hal ini menunjukkan bahwa nilai *tracking signal* bernilai ±5.Menurut Bovas dan Ledolter (1983) jika nilai *tracking signal* bernilai dalam batas ±5 maka peramalan sudah cukup handal. Sementara jika nilai *tracking signal* bernilai diluar batas ±5, maka model peramalan harus ditinjau kembali dan akan dipertimbangkan model baru.

Berdasarkan perbandingan nilai MAPE antara model SARIMA $(1,0,1)(1,1,0)_{12}$ dan SSA yang menunjukkan MAPE dari metode SSA yang lebih kecil serta nilai *tracking signal* yang bernilai ±5, maka nilai peramalan untuk ekspor sektor agrikultur untuk bulan April sampai dengan Juli 2017 memiliki hasil sebagai berikut:

Tabel 4.7 Hasil Peramalan Ekspor Sektor Agrikultur dengan Metode SSA

Bulan	Ekspor Sektor Agrikultur (Juta US$)
Februari	436.0024
Maret	435.0514
April	377.9908
Mei	402.6907
Juni	404.7789
Juli	392.6011

Berdasarkan tabel di atas dapat diperkirakan ekspor sektor agrikultur untuk bulan April sampai dengan bulan Juli. Peramalan ekspor sektor agrikultur bulan April sebesar 377.9908 Juta US$, untuk bulan Mei sebesar 402.6907 Juta US$, bulan Juni sebesar 404.7789 Juta US$ dan untuk bulan Juli sebesar 392.6011 Juta US$. Dari hasil peramalan ini tampak bahwa terjadi penurunan ekspor sektor agrikultur pada bulan April, dan bulan Mei serta Juni kembali meningkat, namun kembali mengalami penurunan pada bulan Juli. Hal ini dikarenakan pada bulan Juni akhir hingga awal bulan Juli terdapat lebaran Idul Fitri sehingga diperkirakan akan terjadi kenaikan permintaan bahan pertanian seperti rempah-rempah dan lain sebagainya oleh dari pasar dalam Negeri. Sehingga ekspor sektor agrikultur akan berkurang untuk memenuhi

kebutuhan dalam Negeri. Hasil dari peramalan ini akan dapat dijadikan informasi dan masukan untuk kementrian perdagangan untuk ekspor sektor agrikultur ,yang mana jika ekspor sektor agrikultur terlalu rendah maka dapat dipersiapkan lahan tambahan agar dapat mengakomodasi permintaan tambahan pada pasar dalam Negeri sehingga tidak berdampak kepada penurunan ekspor sektor agrikultur.

5. KESIMPULAN

Metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dan metode *Singular Spectrum Analysis* (SSA) merupakan metode peramalan untuk data yang memiliki pola musiman. Nilai MAPE dari peramalan terhadap data ekspor sektor agrikultur dari kedua model menunjukkan metode SSA lebih cocok digunakan pada data ekspor sektor agrikultur karena memiliki nilai MAPE yang lebih kecil yaitu sebesar 9.95%. Akan tetapi belum tentu pada semua data metode SSA akan menghasilkan peramalan yang selalu lebih baik (menghasilkan MAPE lebih kecil) dari pada menggunakan metode SARIMA.

Hasil peramalan ekspor sektor agrikultur adalah untuk bulan April sebesar 377.9908 Juta US$, untuk bulan Mei sebesar 402.6907 Juta US$, bulan Juni sebesar 404.7789 Juta US$ dan untuk bulan Juli sebesar 392.6011 Juta US$. Hasil penelitian ini menunjukkan bahwa terjadi enurunan hasil ekspor pada bulan April, kemudian kembali naik pada bulan Mei dan Juni, Sementara pada bulan Juli kembali mengalami penurunan yang diperkirakan penurunan ekspor sektor agrikultur dikarenakan lebaran Idul Fitri.

6. REFERENSI

Bovas A. & Ledolter J. 1983. *Statistical Methods for Forecasting. A John Wiley & Sons,INC,. Publication*. United States of Amerika.

Data Ekspor Sektor Agrikultur. Diakses pada tanggal 14 Maret 2017. www.kemendag.go.id

Darmawan, G. 2016. Identifikasi Pola Data Curah Hujan pada Proses *Grouping* dalam Metode *Singular Spectrum Analysis*. Bandung.

Darmawan, G., Hendrawati, T., & Aristanti, R. 2015. Model Auto Singular Spectrum untuk Meramalkan Kejadian Banjir di Bandung dan Sekitarnya. *Seminar Nasional Matematika dan Pendidikan Matematika UNY* .

Golyandina, N., & Zhigljavsky, A. 2013. *Singular Spectrum Analysis for Time Series.* New York: Springer.

Pujiyati,Sri. 2001. Analisis Perkembangan dan Peramalan Ekspor Pertanian Indonesia Tahun 1990-2000. Thesis Institut Pertanian Bogor.

Ukhra, A. U. 2014. Pemodelan dan Peramalan Data Deret Waktu dengan Metode Seasonal Arima. *Jurnal Matematika UNAND Vol.3 No.3* , 59-67.

Wei, W.W.S. 2006. *Time Series Analysis Univariat and Multivariate Methods* Addison Wesley. New York.