

Peramalan Harga Gabah Kering Giling (GKG) Menggunakan Teknik *Bootstrap-Recurrent* Pada Metode *Singular Spectrum Analysis* (SSA)

Oleh: Indah Purboningtyas
Univeristas Muhammadiyah Semarang

Article history	Abstract
Submission : Revised : Accepted :	Milled Dried Unhulled Grain (GKG) is one of the agricultural commodities which is useful as a food ingredient whose production always increases from time to time. Forecasting the price of GKG is very important in order to provide an overview of the projection of the price of unhulled rice for farmers because the majority of Indonesians who live as farmers. The average price of GKG fluctuates following seasonal patterns and trends. The method that can be used to estimate the price of GKG is Singular Spectrum Analysis (SSA). The SSA method is able to decompose the time series pattern into a simple form and has a fairly good prediction accuracy. This study uses the SSA method with bootstrap-recurrent forecasting techniques to be able to see the confidence interval of the forecasting results. Based on the analysis, it is obtained that the correct SSA model in this case is bootstrap 1000 times with windows length 7 and $r = 7$ parameters resulting in a MAPE value of 4.282746% with the forecast results tend to increase.
Keyword: <i>Bootstrap-Recurrent Forecasting</i> , Gabah Kering Giling (GKG), <i>Singular Spectrum Analysis</i> (SSA)	

PENDAHULUAN

Indonesia adalah salah satu negara berkembang yang ada di Asia Tenggara. Sebagai negara berkembang, Indonesia harus terus melakukan pembangunan agar dapat semakin berkembang dan tidak tertinggal dari negara yang lain. Tingkat pertumbuhan ekonomi merupakan salah satu indikator kemajuan suatu negara. Pertumbuhan ekonomi juga diartikan lebih menunjuk pada perubahan yang bersifat kuantitatif dan diukur dengan menggunakan data produk domestik bruto (PDB) atau pendapatan output perkapita (Sri dan Citra, 2017). Menurut (Bappenas, 2020) perekonomian Indonesia masih ditopang beberapa sektor seperti industri pengolahan, perdagangan, dan pertanian meski pertumbuhannya melambat.

Indonesia merupakan negara agraris artinya negara yang mengandalkan sektor pertanian dalam perekonomian yang meliputi sumber mata pencarian maupun penopang pembangunan. Sebagai salah satu sektor penopang pertumbuhan ekonomi negara,

pertanian merupakan sektor yang dominan dalam pendapatan masyarakat Indonesia karena mayoritas masyarakat Indonesia bermata pencarian sebagai petani. Oleh karena itu penghasilannya sangat bergantung pada tinggi rendahnya harga hasil panen khususnya petani yang menanam tanaman pangan seperti padi atau gabah.

Berdasarkan data Badan Pusat Statistik (BPS), grafik rata-rata harga Gabah Giling Kering (GKG) periode Januari 2008 sampai dengan Desember 2020 cenderung mengalami kenaikan dan diduga memiliki pola *trend* naik, musiman serta mempunyai pola yang kompleks yaitu memiliki pola linier dan non linier.

Pada umumnya metode yang digunakan dalam data *time series* yang mengandung pola musiman adalah metode parametrik seperti metode SARIMA. Namun berdasarkan penelitian Ruhiat dan Effendi (2018) dalam Ruhiat *et.al* (2020) menyatakan bahwa metode SARIMA memiliki nilai MAPE yang relatif besar sehingga pada penelitian ini menggunakan alternatif metode non parametrik yaitu metode

Singular Spectrum Analysis (SSA). Menurut Siregar *et.al* (2017) keunggulan dari model SSA terlihat lebih fleksibel dan mampu memodelkan musiman dengan multi periode dan musiman yang kompleks. Selain itu model SSA terhindar dari banyaknya syarat seperti independensi, dan normalitas residual sebagaimana pada metode peramalan parametrik.

Menurut Golyandina, N., & Korobeynikov, A. (2014) menyebutkan bahwa dalam SSA terdapat beberapa jenis teknik peramalan yang dapat digunakan yaitu *recurrent forecasting*, *vector forecasting*. Dalam penelitian ini akan menggunakan teknik peramalan *recurrent forecasting* dan *bootstrap confidence interval* untuk melihat selang kepercayaannya atau biasa disebut dengan teknik peramalan *bootstrap-recurrent forecasting*. *Bootstrap* adalah suatu metode pendekatan nonparametrik untuk menaksir berbagai kuantitas statistik seperti *mean*, *standart error*, dan bias suatu estimator atau untuk membentuk interval konfidensi dengan memanfaatkan kecanggihan teknologi komputer (Cynthia, 2015).

Beberapa penelitian tentang *Singular Spectrum Analysis* (SSA) telah dilakukan, seperti penelitian yang dilakukan oleh Shafira, D (2020) dengan Judul “Peramalan Wisatawan Mancanegara Berkunjung ke Bali Menggunakan Metode *Singular Spectrum Analysis* (SSA)” menghasilkan peramalan dengan nilai MAPE sebesar 10.79%. Penelitian yang dilakukan oleh Siregar *et.al* (2017) dengan Judul “Aplikasi Metode *Singular Spectral Analysis* (SSA) Dalam Peramalan Pertumbuhan Ekonomi Indonesia Tahun 2017” menghasilkan peramalan dengan MAPE 0,82. Penelitian yang dilakukan oleh Penelitian yang dilakukan Hanif, F (2017) dengan Judul “Teknik Peramalan *Bootstrap-Recurrent* Pada Metode *Singular Spectrum Analysis* Untuk Meramalkan Hasil Penjualan Energi Listrik (Studi Kasus di PT PLN (Persero) Area Bandung)” menghasilkan peramalan dengan nilai MAPE 3.183%. Sedangkan untuk penelitian tentang peramalan Harga Gabah Kering Giling telah dilakukan oleh Ayomi *et.al* (2017) dengan Judul “Prediksi Harga Gabah Kering Giling dengan Sistem *Fuzzy* menghasilkan nilai MAPE sebesar 2,17829% pada data testing.

Pada beberapa penelitian yang telah dilakukan, belum terdapat penelitian secara spesifik yang membahas tentang peramalan Harga Gabah Kering Giling (GKG) dengan

metode *Singular Spectrum Analysis* (SSA). Maka peneliti ingin meneliti tentang tingkat akurasi teknik peramalan *Bootstrap-Recurrent* pada metode *Singular Spectrum Analysis* (SSA) dalam peramalan Harga Gabah Kering Giling (GKG).

LANDASAN TEORI

Singular Spectrum Analysis (SSA)

Menurut Golyandina (2001) *Singular Spectrum Analysis* merupakan teknik analisis *time series* yang mengkombinasikan analisis *time series* klasik, statistika multivariat, geometri multivariat, system dinamis dan pemrosesan sinyal. Dalam metode SSA terdapat dua tahapan yaitu dekomposisi dan rekontruksi. Dalam tahap dekomposisi langkah yang perlu dilakukan yaitu *embedding* dan *singular value decomposition*. Kemudian pada tahap rekontruksi langkah yang perlu dilakukan yaitu tahap *grouping* dan *diagonal averaging*.

Dekomposisi

Pada Dekomposisi, parameter yang mempunyai fungsi penting dalam tahapan dekomposisi adalah *Windows Length* (L). Nilai L yang digunakan ditentukan melalui pengecekan *trial and error* karena belum ada metode khusus untuk menentukan nilai L . Tahap dekomposisi itu sendiri mempunyai tahapan-tahapan yang harus dilakukan yaitu *Embedding* dan *Singular Value Decomposition* (SVD).

Embedding

Embedding merupakan proses merubah struktur deret waktu menjadi deret *multidimensional*. Misalnya $X = (X_1, X_2, \dots, X_N)$ merupakan data deret waktu sebanyak N dan tidak ada data yang hilang. Kemudian X akan ditransformasi ke dalam matriks lintasan berukuran $L \times K$ dengan ketentuan $2 < L < \frac{N}{2}$ dan $K = N - L + 1$. Data X akan dipetakan menjadi *lag vector* $X_i = (x_i, \dots, x_{i+L-1})^T$ untuk $i = 1, 2, \dots, K$. *Lag vector* X_i akan dibentuk matriks lintasan $L \times K$.

$$X = [X_1 : \dots : X_K] = \begin{bmatrix} x_1 & x_2 & x_3 & \dots & x_k \\ x_2 & x_3 & x_4 & \dots & x_{k+1} \\ x_3 & x_4 & x_5 & \dots & x_{k+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & x_{L+2} & \dots & x_N \end{bmatrix} \quad (2.1)$$

Matriks X tersebut disebut juga matriks Hankel yang merupakan semua elemen anti diagonalnya bernilai sama

Singular Value Decomposition (SVD)

Tahap selanjutnya dalam dekomposisi setelah *Embedding* adalah tahap *Singular Value Decomposition* (SVD). Untuk penentuan matriks singular dalam SSA dapat didefinisikan dengan $S = XX^T$. Jika $\lambda_1 \dots \lambda_L$ merupakan nilai *eigen* dari matriks dimana $\lambda_1 \geq \dots \geq \lambda_L \geq 0$ dan $U_1 \dots U_L$ merupakan *vector eigen* dari masing-masing nilai *eigen* serta *principal component* dinotasikan dengan $V_i = X^T U_i / \sqrt{\lambda_i}$ ($i = 1, \dots, d$) maka matriks lintasan X diperoleh sebagai berikut :

$$X = X_1 + \dots + X_d \text{ dimana : } X_i = \sqrt{\lambda_i} U_i V_i^T \quad (2.2)$$

$\sqrt{\lambda_i} U_i V_i^T$ disebut dengan eigentriple. Maka yang menjadi output dalam tahapan ini adalah eigentriple $\sqrt{\lambda_i} U_i V_i^T$ yaitu *eigen value*, *eigen vector*, dan *principal componenet*

Rekontruksi

Pada tahapan ini ada dua tahap yang harus dilakukan yaitu tahap *Grouping* dan juga *Diagonal Averaging*. Parameter yang mempunyai peran penting dalam tahapan rekontruksi adalah *grouping effect* (r) yang berfungsi untuk menentukan pola plot data. Hasil dari tahapan ini akan mendekati hasil peramalan dengan data asli maka dengan pengelompokan yang tepat serta dengan MAPE nilai ramal data asli dapat menghasilkan peramalan yang baik

Grouping

Grouping merupakan tahapan penguraian matriks lintasan $L \times K$ menjadi beberapa kelompok pola yang meliputi pola *trend*, pola musiman dan pola *noise*. Tahapan ini juga merupakan partisi dari indeks $\{I_1, \dots, I_m\}$. Maka X akan bekorespondensi dengan kelompok $I = \{I_1, \dots, I_m\}$ dengan persamaan sebagai berikut:

$$X = X_{I1} + \dots + X_{Im} \quad (2.3)$$

Diagonal Averaging

Dalam langkah ini matriks X_{Ij} yang diperoleh dari grouping disusun ulang menjadi data deret baru dengan panjang N. jika Y adalah matriks dengan ukuran $L \times K$ dengan elemen y_{Ij} , dimana $1 \leq i \leq L$ dan $1 \leq j \leq K$. misalkan $L = \min(L, K)$ dan $K^* = \max(L, K)$, $N = L + K - 1$. Dan misalkan juga $y_{Ij}^* = y_{Ij}$ jika $L < K$ dan $y_{Ij}^* = y_{j1}$ selainnya. Menggunakan metode *Diagonal Averaging* Matriks Y ditransformasikan ke bentuk series kembali, $\{y_1, \dots, y_N\}$ dengan persamaan sebagai berikut :

$$y_k = \begin{cases} \frac{1}{k} \sum_{m=1}^k y_{m, k-m+1}^* & \text{untuk } 1 \leq k \leq L^* \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m, k-m+1}^* & \text{untuk } L^* \leq k \leq K^* \\ \frac{1}{N-k+1} \sum_{m=k-K^*+1}^{N-k+1} y_{m, k-m+1}^* & \text{untuk } K^* \leq k \leq N \end{cases} \quad (2.4)$$

Sehingga X_{Ij} akan menjadi deret $\tilde{Y}^{(k)} = \tilde{y}_1^{(k)}, \dots, \tilde{y}_N^{(k)}$ oleh sebab itu, deret asli akan menjadi jumlah dari m deret seperti berikut :

$$y_n = \sum_{k=1}^m \tilde{y}_n^{(k)} \quad (n = 1, 2, \dots, N) \quad (2.5)$$

Recurrent Forecasting

Recurrent Forecasting merupakan teknik peramalan SSA yang paling umum digunakan. Sifat utama pada penguraian SSA adalah seri asli dapat memenuhi persamaan *Linier Recurrent Formula* (LRF). Berikut ini merupakan persamaan LRF :

$$f_n = a_1 f_{n-1} + \dots + a_d f_{n-d} \quad (2.6)$$

Dimana a_i merupakan koefisien LRF dengan $i = 1, 2, \dots, d$

Jika seri asli f_n memenuhi persamaan 2.6 maka seri f_n merupakan penjumlahan dari komponen eksponensial, polynomial dan harmonic dalam jangka waktu yang singkat. Hal ini menyebabkan peramalan diwaktu yang akan datang dapat dilakukan menggunakan nilai LRF yang sama karena efek continuation yang diberikan telah sesuai untuk jangka waktu tidak panjang. Algoritma *Recurrent Forecasting* adalah sebagai berikut :

1. Time Series $Y_{N+M} = (y_1, \dots, y_{N+M})$ didefinisikan oleh

$$y_i = \begin{cases} \bar{x}_i & \text{for } i=1, \dots, N \\ \sum_{j=1}^{L-1} a_j y_{i-j} & \text{for } i=N+1, \dots, N+M \end{cases} \quad (2.7)$$

2. Angka Y_{N+1}, \dots, y_{N+M} akan membuat suatu istilah M dari *Recurrent Forecasting*.

Recurrent Forecasting dilakukan dengan LRR menggunakan koefisien $\{a_j, j = 1, \dots, L-1\}$.

Berikut ini rumus yang mendefinisikan operator linear $P_{Rec} : R^L R^L$

$$P_{Rec} Y = \begin{pmatrix} \bar{Y} \\ R^T \bar{Y} \end{pmatrix} \quad (2.8)$$

Dimana,

$$Z_i = \begin{cases} \bar{x}_i & \text{for } i = 1, \dots, K \\ P_{Rec} Z_{i-1} & \text{for } i = K + 1, \dots, K + M \end{cases} \quad (2.9)$$

Disini matriks $Z = [Z_1 : \dots : Z_{K+M}]$ merupakan matriks lintasan dari Y_{N+M} . Oleh karena itu (2.9) dianggap bentuk vektor dari (2.8).

Bootstrap-SSA Forecasting

Bootstrap merupakan suatu proses pengambilan sampel (*resampling*) dengan

pengembalian sampel hasil dari pengamatan menggunakan replikasi. Metode *Bootstrap* merupakan sebuah metode pendekatan non parametrik yang pertama kali diperkenalkan oleh Bradley Efron pada tahun 1979. Metode ini digunakan untuk menaksir kuantitas statistik seperti rata-rata, *standar error*, dan bias suatu estimator atau untuk membentuk interval konfidensi. Resampling mempunyai 2 metode pendekatan yaitu pendekatan *monte carlo* dan *bootstrap*. Hanif (2017) menyebutkan bahwa simulasi *monte carlo* digunakan saat kondisi ideal yaitu model dari sinyal dan noise diketahui. karena kondisi tersebut jarang ditemui pada peramalan kuantitatif, maka metode *bootstrap* yang lebih dominan digunakan pada peramalan kuantitatif yang membutuhkan teknik resampling.

Menurut Rahmani (2014) penerapan teknik *bootstrap* menghasilkan nilai peramalan disertai batas atas dan bawah dari nilai peramalan. Selang kepercayaan yang terbentuk dapat memberikan informasi untuk mengambil keputusan. Teknik *Bootstrap* ini dapat diterapkan pada teknik peramalan SSA seperti teknik *bootstrap-recurrent forecasting* ketika diterapkan pada teknik peramalan *R-Forecasting* dan teknik *bootstrap-vector forecasting* ketika diterapkan pada teknik peramalan *V-Forecasting*.

Bootstrap Recurrent Forecasting

Bootstrap-Recurrent Forecasting adalah penerapan teknik *bootstrap* pada SSA *R-Forecasting*. Golyandina, dkk. (2001) menyebutkan bahwa algoritma pada peramalan *R-Forecasting* erat kaitannya dengan penaksiran LRF. Penaksiran koefisien LRF yaitu a_1, \dots, a_L menggunakan vektor yang diperoleh dari proses SVD. Koefisien LRF dapat dihitung dengan rumus :

$$A = (a_{L-1}, a_{L-2}, \dots, a_2, a_1)^T = \frac{1}{1-v^2} \sum_{i=1}^r \pi_i U_i^V \quad (2.10)$$

Dengan,

$$v^2 = \sum_{i=1}^r \pi_i^2 \quad (2.11)$$

$\pi_i = u_L$: komponen terakhir dari *eigen vector* U

$U^V = (u_1, u_2, \dots, u_{L-1})^T$: *Eigen vector* U tanpa komponen terakhir.

Deret waktu yang digunakan pada *R-Forecasting* merupakan hasil rekonstruksi yang diperoleh dari *diagonal averaging* yang selanjutnya ditentukan M buah titik baru untuk diramalkan. Hasil peramalan didapatkan berdasarkan rumus berikut :

$$\tilde{F}_n \begin{cases} \bar{x}_i & \text{untuk } i=1, \dots, N \\ \sum_{j=1}^{L-1} a_j y_{i-j} & \text{untuk } i=N+1, \dots, N+M \end{cases} \quad (2.12)$$

Metode ESPRIT

Diberikan deret waktu $X_N = \{x_i\}_{i=1}^N$ dengan $y_i = s_i + p_i$, yang mana $S_N = \{s_i\}_{i=1}^N$ merupakan deret waktu yang diatur oleh *linier recurrence relation* (LRR) orde r (S_N yaitu sinyal) dan $P_N = \{p_i\}_{i=1}^N$ yaitu suatu residual (*noise*). Pada perkiraan keterpisahan sinyal dan residual, ada satu himpunan I dari banyak vektor eigen yang bersesuaian dengan sinyal. Apabila sinyal lebih dominan, maka $I = \{1, \dots, r\}$ dan subruang $\mathcal{L}_r = \text{span}\{U_1, \dots, U_r\}$ dapat dianggap estimasi dari sub ruang sinyal yang sebenarnya. Maka $Y = U_r = [U_1, \dots, U_r]$ dapat digunakan sebagai suatu estimasi dari Y .

Metode ESPRIT ini terjadi dalam estimasi akar sinyal sebagai nilai eigen dari suatu matriks D, yang mana $\underline{UD} \approx \bar{U}_r$. Dengan mengestimasi akar sinyal, metode ESPRIT menyediakan estimasi dari parameter sinyal. Metode ESPRIT juga mampu mengestimasi parameter dari komponen deret waktu yang dapat dipisahkan apabila matriks U_r terdiri dari vektor eigen yang sesuai. Ada dua jenis metode ESPRIT yaitu yang pertama *least squares* (LS-ESPRIT) dan yang kedua *total least squares* (TLS-ESPRIT). Estimasi LS-ESPRIT dari matriks D merupakan $D = \underline{U}_r^\dagger \bar{U}_r = (\underline{U}_r^T \bar{U}_r)^{-1} \underline{U}_r^T \bar{U}_r$. Nilai eigen dari D tidak bergantung pada pilihan basis subruang $\mathcal{L}_r = \text{span}\{U_1, \dots, U_r\}$.

Akurasi Model Peramalan

Dalam mengukur rata-rata kesalahan peramalan yang paling sering digunakan adalah Mean Absolute Percentage Error (MAPE). Ukuran rata-rata kesalahan tersebut dinyatakan sebagai presentase dari nilai observasi yang relevan terlepas dari kesalahan peramalan yang positif yaitu melebihi perkiraan ataupun kesalahan peramalan negative yaitu dibawah perkiraan. Rumus persamaan MAPE dapat dilihat sebagai berikut :

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|e_t|}{d_t} \quad (2.13)$$

Ketentuan nilai MAPE peramalan adalah sebagai berikut :

Tabel 1. Ketentuan nilai MAPE

MAPE	Keterangan
< 10%	Sangat Baik
< 20%	Baik
< 30%	Cukup Baik
> 40%	Tidak Akurat

Sumber : (Lewis, 1997)

METODE PENELITIAN

Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Badan Pusat Statistik (bps.go.id) berupa data rata-rata harga Gabah Kering Giling (GKG) (Rp/Kg) di tingkat pertanian. Data yang digunakan yaitu data periode bulan Januari tahun 2008 sampai dengan bulan Desember tahun 2020 dengan data sebanyak 156. Data periode Januari 2008 sampai dengan Agustus 2019 digunakan sebagai data pengamatan untuk model *training* dengan data sebanyak 144 data yang berfungsi sebagai pembentuk suatu model. Sedangkan data sebanyak 12 data digunakan sebagai data *testing* yang berfungsi untuk memvalidasi model yang terpilih.

Variabel dan Struktur Data

Tabel 2. Variabel Data

Variabel	Keterangan	Sumber
Y_n	Harga Gabah Kering Giling (GKG) di tingkat petani	Badan Pusat Statistik (bps.go.id)

Tabel 3. Struktur Data

N	Bulan	Tahun	Y_n
1	Januari	2008	Y_1
2	Februari	2008	Y_2
3	Maret	2008	Y_3
4	April	2008	Y_4
5	Mei	2008	Y_5
:	:	:	:
73	Januari	2014	Y_{73}
:	:	:	:
156	Oktober	2020	Y_{156}

Langkah Penelitian

Langkah-langkah penelitian yang dapat dilakukan adalah sebagai berikut :

1. Menyiapkan data rata-rata harga Gabah Kering Giling (GKG) periode januari 2008 sampai dengan Desember 2020
2. Membagi data menjadi dua, yaitu 144 data pengamatan untuk pembentukan model *training*, dan 12 data untuk mengukur ketepatan model yang terbentuk yang digunakan untuk peramalan
3. Membuat plot pola data yang digunakan dalam peramalan
4. Melakukan langkah pertama dalam dekomposisi yaitu *Embedding*. Pada tahap ini struktur deret satu dimensi akan dirubah menjadi sebuah deret multidimensi yang disebut dengan *trajectory matrix* (matriks lintasan). Parameter penting yang digunakan dalam tahap ini adalah *Windows Length (L)* yang ditentukan dengan cara *trial and error*
5. Melakukan langkah kedua dari tahap dekomposisi yaitu *Singular Value Decomposition (SVD)*. Pada tahap ini matriks lintasan akan dirubah menjadi tiga elemen yang terdiri dari *eigen value*, *eigen vector*, dan *principal componenet*. Tiga elemen tersebut dikenal dengan sebutan *eigen triple*
6. Melakukan langkah pertama dari rekontruksi yaitu tahap *grouping*. Di dalam tahap ini matriks *eigen triple* akan dikelompokkan menjadi beberapa kelompok yaitu komponen *noise*, *trend* dan musiman. Pada komponen musiman dikelompokkan berdasarkan kemiripan nilai *singular* dari dua *eigen triple* berurutan yang terpilih yang kemudian dilakukan pengujian ESPRIT. Dari hasil ESPRIT akan dipilih pasangan *eigen triple* yang memiliki periode musiman 12,6,4,3,2 untuk dikelompokkan ke dalam komponen musiman.
7. Melakukan langkah kedua dari tahap rekontruksi yaitu *Diagonal Averaging*. Dalam tahap ini hasil *grouping* akan ditransformasikan ke dalam deret baru dengan panjang N deret
8. Melakukan peramalan SSA dengan menggunakan algoritma *Recurrent Forecasting*
9. Melakukan *bootsraping (resampling)* pada peramalan *Recurrent Forecasting*.

Berikut ini langkah yang dapat dilakukan dalam *bootstrap recurrent forecasting* menurut Rahmani (2004)

- a. Misalkan deret yang terbentuk yaitu $F_n = \tilde{F}_n + E_n$, dengan F_n merupakan data asli, \tilde{F}_n merupakan data hasil rekonstruksi SSA dan E_n merupakan residual yang diperoleh dari $E_n = F_n - \tilde{F}_n$
 - b. Melakukan *bootstrapping* terhadap E_n dan hasilnya dinotasikan dengan $E_{n,i}$ kemudian hitung $Y^* = \tilde{F}_n + E_{n,i}$
 - c. Melakukan pengujian SSA lagi terhadap deret baru Y^*
 - d. Ulangi langkah 2 dan 3 sampai jumlah yang cukup besar, dalam penelitian ini menggunakan pengulangan 500 kali, 1000 kali, 1500 kali, 2000 kali dan 2500 kali.
10. Menghitung ketepatan peramaan menggunakan MAPE
 11. Melakukan peramalan untuk 12 periode kedepan

HASIL PENELITIAN dan PEMBAHASAN

Statistika Deskriptif

Rata-rata harga Gabah Kering Giling (GKG) di Indonesia pada Januari 2008 sampai dengan Desember 2020 dapat digambarkan melalui tabel statistik deskriptif sebagai berikut :

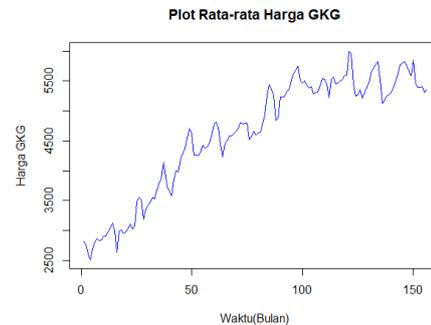
Tabel 4. Statistik Deskriptif Rata-rata harga GKG periode Januari 2008 sampai Desember 2020.

Rata-rata	Standar Deviasi	Minimum	Maksimum
4609	976,5211	2507	6002

Berdasarkan Tabel 4 dapat diketahui bahwa Rata-rata Harga GKG sebesar Rp. 4609 (Rp/Kg) dan memiliki nilai standar deviasi sebesar 976,5211. Harga minimum dari Rata-rata Harga GKG adalah Rp. 2507,- (Rp/Kg) dan Harga maksimum dari Rata-rata Harga GKG adalah Rp. 6002,- (Rp/Kg).

Data dalam penelitian ini dibagi menjadi dua yaitu data *training* untuk pembentukan model terbaik yang terdiri dari 144 data periode Januari 2008 hingga Desember 2019, dan data *testing* untuk mengukur ketepatan model yang terbentuk yang digunakan untuk peramalan yang terdiri dari 12 data periode Januari 2020 hingga Desember 2020 yang kemudian akan

diramalakan menggunakan teknik *Bootstrap-Recurrent* pada metode *Singular Spectrum Analysis* (SSA). Berikut ini merupakan hasil plot data rata-rata harga GKG di Indonesia pada periode Januari 2008 hingga Desember 2020



Gambar 1 Plot Rata-rata harga GKG periode Januari 2008 hingga Desember 2020

Berdasarkan Gambar 1. menunjukkan bahwa Rata-rata Harga GKG periode Januari 2008 hingga Desember 2020 mengandung komponen *trend* cenderung naik dan komponen musiman. Dalam metode SSA terdapat dua tahap untuk memisahkan komponen yaitu tahap dekomposisi dan rekonstruksi.

Dekomposisi

Embedding

Embedding merupakan langkah awal dalam tahap dekomposisi. Proses *Embedding* dilakukan dengan merubah struktur deret satu dimensi menjadi deret multidimensi yang biasa disebut *trajectory matrix* (matriks lintasan). Parameter yang digunakan dalam proses dekomposisi adalah *Window Length* (L) yang dilakukan dengan cara *trial and error*. Dengan data sebanyak 144 data didapatkan nilai batas L adalah $2 < L < \frac{144}{2}$ atau sekitar antara 2 sampai 72. Melalui beberapa percobaan, nilai L yang digunakan dalam penelitian ini adalah L = 7 dan didapatkan nilai K = 144 - 7 + 1 = 138. Kemudian hasil dari *embedding* membentuk matriks lintasan berdimensi L x K seperti berikut :

$$X_{7 \times 138} = \begin{bmatrix} 2822.13 & 2769.87 & 2610.31 & \dots & 5246.00 \\ 2769.87 & 2610.31 & 2507.44 & \dots & 5277.23 \\ 2610.31 & 2507.44 & 2689.91 & \dots & 5308.74 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 2863.19 & 2827.29 & 2838.13 & \dots & 5774.65 \end{bmatrix}$$

Singular Value Decomposition

Proses berikutnya dalam tahap dekomposisi adalah membuat *Singular Value Decomposition* (SVD) dari matriks lintasan. Ada tiga elemen pembentuk SVD yaitu *eigen value*,

eigen vector dan *principal component* dari matriks $H=XX^T$. Tiga elemen tersebut dinamakan *eigen triple*. Berikut ini merupakan matriks $H=XX^T$ yang terbentuk :

$$H_{7 \times 7} = \begin{bmatrix} 2909333849 & 2917608241 & 2925616226 & \dots & 2969431431 \\ 2917608241 & 2929218588 & 2937806750 & \dots & 2980144649 \\ 2925616226 & 2937806750 & 2949729128 & \dots & 2991096076 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 2969431431 & 2980144649 & 2991096076 & \dots & 3045889651 \end{bmatrix}$$

Kemudian setelah terbentuknya matriks H, dapat dicari nilai *eigen value*, *eigen vector* dan *principal component*. Berikut ini merupakan tabel nilai *eigen value*, *singular value*

Tabel 5. *Eigen Value* dan *Singular Value*

Nilai Eigen Value	Nilai Singular Value
2.079691×10^{10}	144211.3346
1.383410×10^7	3719.4216
6.468382×10^6	2543.3014
2.795473×10^6	1671.9667
1.353150×10^6	1163.2497
8.167396×10^5	903.7365
3.973022×10^5	630.3191

Berdasarkan tabel diatas dapat kita lihat bahwa semuanya bernilai positif maka akan didapatkan nilai vektor *eigen vector* dan *principal component* sebanyak 7 dan akan terbentuk 7 buah matriks *eigen triple* yang akan menjadi matriks lintasan.

$$S_1 = \begin{bmatrix} 2692.439 & 2693.545 & 2703.457 & \dots & 5386.056 \\ 2702.389 & 2703.499 & 2713.448 & \dots & 5405.961 \\ 2712.237 & 2713.351 & 2723.336 & \dots & 5425.661 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 2755.018 & 2756.149 & 2766.292 & \dots & 5511.241 \end{bmatrix}$$

$$S_2 = \begin{bmatrix} -1.53499245 & -78.824948 & -113.588511 & \dots & -162.953488 \\ -1.50066446 & -77.062137 & -111.048260 & \dots & -159.309257 \\ -0.93663096 & -48.097883 & -69.310123 & \dots & -99.431943 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1.55466400 & 79.835122 & 115.044193 & \dots & 165.041803 \end{bmatrix}$$

$$S_3 = \begin{bmatrix} 139.40398 & 64.73378 & -45.35836 & \dots & 51.56725 \\ 44.47301 & 20.65153 & -14.47034 & \dots & 16.45111 \\ -99.37870 & -46.14759 & 32.33519 & \dots & -36.76140 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 134.95667 & 62.66862 & -43.91132 & \dots & 49.92213 \end{bmatrix}$$

$$S_4 = \begin{bmatrix} 15.9823324 & 81.845041 & 23.3093395 & \dots & -30.6207590 \\ -6.3327792 & -32.429971 & -9.2360050 & \dots & 12.1330543 \\ -16.8266030 & -86.168525 & -24.5406610 & \dots & 32.2383081 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ -16.0438370 & -82.160004 & -23.3990406 & \dots & 30.7385966 \end{bmatrix}$$

$$S_5 = \begin{bmatrix} -23.01121 & 15.040053 & 25.53348 & \dots & 8.348180 \\ 29.99697 & -19.605925 & -33.28496 & \dots & -10.882528 \\ 10.73630 & -7.017209 & -11.91311 & \dots & -22.19950 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ -22.96369 & 15.008994 & 25.48076 & \dots & 8.330941 \end{bmatrix}$$

$$S_6 = \begin{bmatrix} -5.8890736 & -1.1373488 & 9.1674266 & \dots & -7.8700257 \\ 12.2984276 & 2.3751787 & -19.1447655 & \dots & 16.4353425 \\ -10.2005982 & -1.9700277 & 15.8791080 & \dots & -13.6318503 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 5.9088488 & 1.1411680 & -9.1982104 & \dots & 7.8964529 \end{bmatrix}$$

$$S_7 = \begin{bmatrix} 4.740236 & -5.331252 & 7.790010 & \dots & 1.472830 \\ -11.454067 & 12.882168 & -18.823387 & \dots & -3.558872 \\ 14.679426 & -16.509665 & 24.123877 & \dots & 4.561018 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 4.759727 & -5.353173 & 7.822042 & \dots & 1.478886 \end{bmatrix}$$

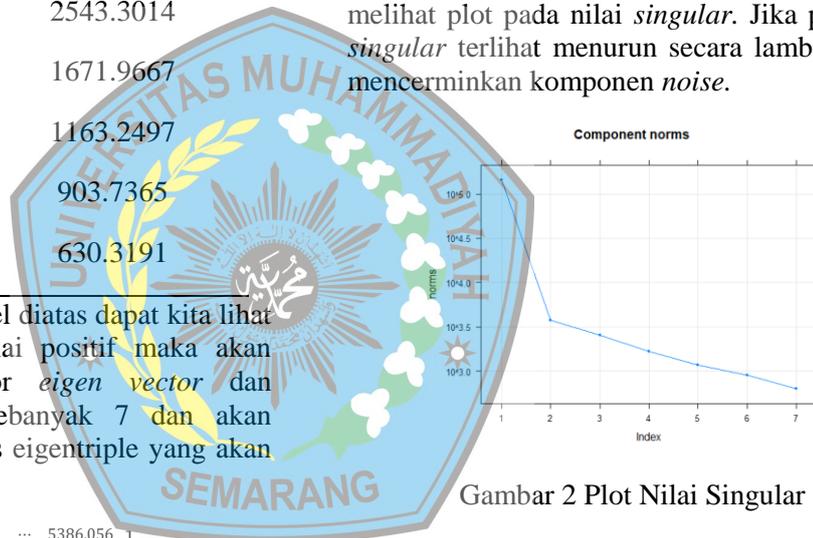
Rekonstruksi

Grouping

Grouping atau pengelompokan ini merupakan proses awal dari tahap rekonstruksi. Pada tahap ini akan dilakukan pengelompokan *eigen triple* ke dalam tiga komponen yaitu *trend*, *musiman* dan *noise*. Parameter yang digunakan dalam proses ini adalah *Grouping effect* (r) yang digunakan untuk mengidentifikasi komponen *trend* dan *musiman*.

Pengelompokan Komponen Noise

Pengelompokan komponen *noise* dapat dikelompokkan dengan menentukan nilai r yang ditentukan berdasarkan jumlah *eigen triple* yang tidak mencerminkan komponen *noise* dengan melihat plot pada nilai *singular*. Jika plot nilai *singular* terlihat menurun secara lambat, maka mencerminkan komponen *noise*.

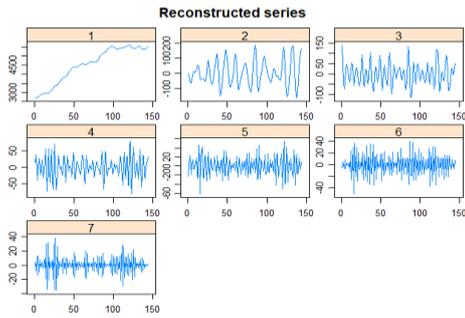


Gambar 2 Plot Nilai Singular

Berdasarkan gambar diatas dapat kita lihat bahwa nilai parameter r adalah 7 karena hanya memiliki tujuh titik *singular*. Dengan demikian tujuh *eigen triple* tersebut yang akan digunakan untuk mengidentifikasi komponen *trend* dan komponen *musiman*.

Pengelompokan Komponen Trend dan Musiman

Tujuh buah *eigen triple* yang akan digunakan dalam proses pengelompokan komponen *trend* dan *musiman* terdiri dari *eigen triple* 1,2,3,4,5,6 dan 7. Untuk dapat mengidentifikasi kelompok komponen dapat menggunakan plot dari deret yang telah direkonstruksi. Berikut ini merupakan plot deret yang telah direkonstruksi :



Gambar 3. Plot deret yang direkonstruksi

Eigentriple dikelompokkan ke dalam komponen trend apabila plot deret yang direkonstruksi bervariasi secara lambat. Berdasarkan Gambar 3 *eigentriple* 1 memperlihatkan komponen bervariasi secara lambat, sehingga *eigentriple* 1 dikelompokkan ke dalam komponen *trend*. Setelah di temukan komponen *trend* selanjutnya melakukan pengelompokan *eigentriple* yang berhubungan dengan komponen musiman. Pengelompokan komponen musiman itu sendiri dapat dilakukan secara subjektif dengan melihat kemiripan nilai *singular* dari *eigentriple* yang berurutan sehingga *eigentriple* satu dan yang lain mempunyai pola dan periode musiman yang sama.

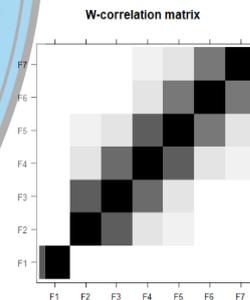
Terlihat pada Gambar 3 Plot deret yang direkonstruksi, ada tiga pasang *eigentriple* yang memiliki kemiripan pola yaitu *eigentriple* 2 dan 3, *eigentriple* 4 dan 5 serta *eigentriple* 6 dan 7. Untuk mengetahui periode musiman yang sama maka pada penelitian ini menggunakan metode ESPRIT. Periode musiman yang dapat dipilih ke dalam pengelompokan musiman hanya komponen musiman yang mempunyai nilai 12,6,4,3,2. Dibawah ini merupakan hasil uji ESPRIT :

Tabel 6. Pengelompokan Eigentriple

Eigentriple	Periode	Pola data
1	-	Trend
2	9	Noise
3	9	Noise
4	3	Musiman
5	3	Musiman
6	2	Musiman
7	2	Musiman

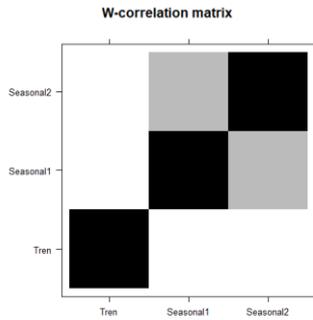
Berdasarkan hasil uji ESPRIT didapatkan deret yang direkonstruksi oleh *eigentriple* 2 dan 3 memiliki periode musiman yang sama yaitu sembilan bulan akan tetapi tidak dapat dikelompokkan dalam komponen musiman karena memiliki periode sembilan bulan. *Eigentriple* 4 dan 5 memiliki periode musiman yang sama yaitu tiga bulan sehingga dapat dikelompokkan ke dalam komponen musiman. Selanjutnya *eigentriple* 6 dan 7 memiliki periode musiman yang sama juga yaitu 2 bulan sehingga *eigentriple* 6 dan 7 juga dapat dikelompokkan ke dalam komponen musiman. Sementara untuk *eigentriple* yang tidak dapat dikelompokkan ke dalam komponen *trend* dan musiman, *eigentriple* tersebut masuk ke dalam komponen *noise*.

Pengidentifikasi *eigentriple* dalam pengelompokan komponen *trend* dan musiman tidak hanya dapat dilihat pada plot deret rekonstruksi saja melainkan juga dapat dilihat pada plot *w-correlation*. Plot ini digunakan untuk melihat seberapa besar korelasi antar *eigentriple* yang mana semakin tua warna plotnya maka semakin tinggi korelasinya. Berikut ini merupakan plot *w-correlation* dari 7 *eigentriple* yang ada :



Gambar 4. Plot *w-Correlation* 7 *eigentriple*

Berdasarkan gambar plot diatas terlihat bahwa pasangan *eigentriple* yang memiliki korelasi yang kuat adalah *eigentriple* 2 dan 3, *eigentriple* 4 dan 5 serta *eigentriple* 6 dan 7. Namun dalam pengidentifikasi komponen *trend* dan musiman tidak dapat hanya melihat plot saja, maka dari itu digunakan metode ESPRIT dalam mencari periode musimannya. Berikut ini gambar plot *w-correlation* jika dilihat dari korelasi antar kelompok komponen yang terbentuk :



Gambar 5. Plot *w*-Correlation komponen

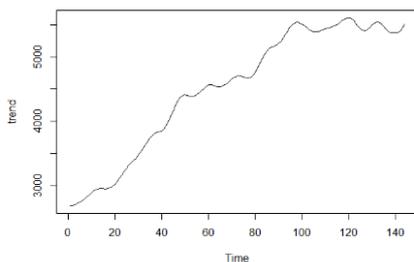
Diagonal Averaging

Pada tahap *diagonal averaging*, hasil grouping akan ditransformasi ke suatu deret baru dengan panjang N. Tahapan ini bertujuan untuk mendapatkan suatu deret baru yang digunakan untuk proses peramalan. Hasil *diagonal averaging* dapat dilihat pada tabel berikut :

Tabel 7. Hasil *diagonal averaging*

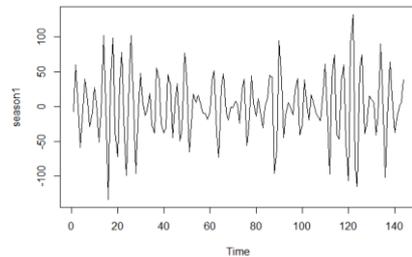
No	Diagonal Averaging				Data Rekonstruksi	Residual
	Tren	Musiman Periode 3	Musiman Periode 2			
1	2692.439	-7.0288738	-1.1488374	2684.261	137.869	
2	2697.967	60.2746413	-2.8121202	2755.429	14.44058	
3	2706.398	-3.0944601	12.2312035	2715.534	-105.224	
4	2723.340	58.6095009	20.6482461	2644.082	-136.642	
5	2746.869	-2.3521772	21.5938851	2766.111	-76.2008	
⋮	⋮	⋮	⋮	⋮	⋮	
144	5511.241	390.695.372	9.3753391	5559.686	214.9639	

Pada proses *diagonal averaging*, masing-masing komponen direkonstruksi dengan masing-masing *eigen*triple yang terkait. Pada penelitian ini komponen tren direkonstruksi oleh *eigen*triple 1. Berikut ini merupakan plot hasil dari komponen tren yang direkonstruksi :

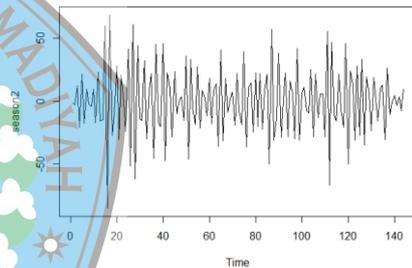


Gambar 6. Plot Komponen Tren yang direkonstruksi

Selanjutnya untuk komponen musiman periode 3 direkonstruksi oleh *eigen*triple 4 dan 5. Sementara untuk komponen musiman periode 2 direkonstruksi oleh *eigen*triple 6 dan 7. Plot hasil dari komponen musiman periode 3 yang telah direkonstruksi dapat dilihat pada Gambar 7 Dan untuk plot hasil dari komponen musiman periode 2 yang direkonstruksi dapat dilihat pada Gambar 8.

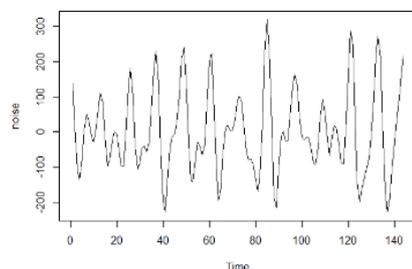


Gambar 7. Plot komponen musiman periode 3 yang direkonstruksi



Gambar 8. Plot komponen musiman periode 2 yang direkonstruksi

Pada komponen *noise* direkonstruksi oleh *eigen*triple 2 dan *eigen*triple 3. Berikut ini merupakan plot hasil dari komponen *noise* yang direkonstruksi :



Gambar 9. Plot komponen *noise* yang direkonstruksi

Peramalan *Bootstrap-Recurrent Forecasting* pada SSA

Bootstrap-Recurrent Forecasting merupakan penerapan dari teknik *bootstrap (resampling)* pada metode peramalan *recurrent forecasting* SSA. Nilai residual yang telah didapatkan pada tabel 4.4 kemudian akan dilakukan *bootstrap* sebanyak 500 kali, 1000 kali, 1500 kali, 2000 kali dan 2500 kali. Kemudian setelah dilakukan *bootstrap* pada residual, nilai residual tersebut akan dibuat deret waktu baru dengan menjumlahkan deret residual hasil *bootstrap* dengan deret data rekonstruksi yang akan dilakukan peramalan *recurrent forecasting* untuk setiap data.

Peramalan dengan *recurrent forecasting* bergantung pada koefisien LRF. Setiap deret data mempunyai nilai LRF dan nilai peramalan masing-masing yang mana nilai peramalan tersebut akan digunakan untuk pembentukan batas bawah dan atas. Nilai peramalan yang digunakan adalah nilai rata-rata dari nilai peramalan yang telah didapatkan. Hasil peramalan SSA menggunakan *bootstrap-recurrent forecasting* dengan *resampling* sebanyak 500 kali, 1000 kali, 1500 kali, 2000 kali dan 2500 kali dapat dilihat pada Lampiran 10.

Menghitung Akurasi Model

Perhitungan akurasi model-model yang sudah diperoleh, dilakukan dengan nilai MAPE. Semakin kecil nilai MAPE maka semakin baik model dan akurat hasil ramalan yang diperoleh dari suatu model. Hasil perhitungan nilai MAPE ditunjukkan pada Tabel 8. berdasarkan hasil perhitungan nilai MAPE didapatkan model yang terbaik adalah teknik peramalan *bootstrap-recurrent forecasting* sebanyak 1000 kali dengan parameter $L=7$ dan $r=7$. Karena mempunyai nilai MAPE paling kecil yaitu sebesar 4.282746%. Maka parameter *windows length (L)* dan *effect grouping (r)* tersebut dapat digunakan dalam meramalkan harga GKG untuk periode Januari 2021 sampai dengan Desember 2021. Berikut ini merupakan tabel nilai perhitungan nilai MAPE dari teknik peramalan *bootstrap-recurrent forecasting* dan teknik peramalan *recurrent forecasting* dengan parameter L dan r .

Tabel 8. Perhitungan nilai MAPE teknik peramalan *bootstrap-recurrent forecasting* dan teknik peramalan *recurrent forecasting* dengan parameter L dan r

L	r	RECURRENT	BOOTSTRAP	
			500	1000
5	5	4.768602	4.5267	4.44751
6	6	4.610391	4.428247	4.36641
7	7	4.475486	4.314567	4.282746
8	8	4.759239	4.569449	4.398968
9	9	6.906779	4.728699	4.74463
10	10	4.529028	4.822578	4.791994
15	8	4.792908	5.72843	5.790826
20	10	5.913416	7.587488	7.542766
25	7	8.517439	9.79639	9.869003
30	12	9.434282	11.44557	11.40306
35	7	10.76394	12.62852	12.75416
40	7	11.68473	13.74752	13.69317
45	5	12.62025	14.53439	14.48769
50	8	13.0255	14.94048	14.94048
55	8	13.21876	15.14152	15.12613
60	8	13.32885	15.27231	15.18817
65	8	13.19733	15.17925	15.19915
70	24	13.15089	15.06187	15.04178

		BOOTSTRAP		
		1500	2000	2500
4.481131		4.429433	4.478477	
4.431871		4.386157	4.384186	
4.409073		4.453161	4.346872	
4.41104		4.427532	4.434108	
4.764161		4.654169	4.571407	
4.834856		4.807273	4.786866	
5.74772		5.766872	5.805458	
7.583283		7.521927	7.559137	
9.749169		9.738175	9.771017	
11.37894		11.42821	11.45085	
12.73804		12.71693	12.6983	
13.65218		13.73013	13.6682	
14.41795		14.44703	14.43489	
14.97909		14.94841	14.93003	
15.15925		15.14068	15.09604	
15.26365		15.17799	15.24538	
15.21958		15.16308	15.23152	
15.06949		15.15148	15.12147	

Peramalan *Bootstrap-Recurrent Forecasting* pada SSA periode Januari 2021 – Desember 2021

Tahapan selanjutnya adalah melakukan peramalan untuk 12 periode kedepan. Dengan

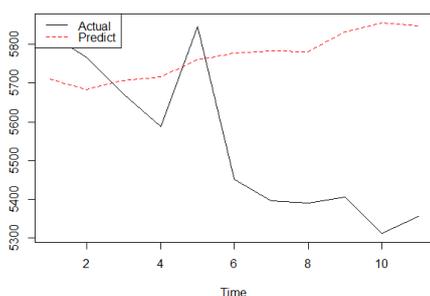
menggunakan *bootstrap* sebanyak 1000 kali dan dengan parameter $L=7$ serta $r=7$ didapatkan hasil peramalan sebagai berikut :

Tabel 9. Hasil peramalan Harga GKG pada Januari-Desember 2021 menggunakan teknik *bootstrap-recurrent forecasting*

Waktu	Nilai Peramalan	Batas Bawah (2.5%)	Batas Atas (97.5%)
Januari 2021	5659.893	4309.142	7197.233
Februari 2021	5709.493	4148.538	7353.315
Maret 2021	5684.073	4101.669	7343.788
April 2021	5707.353	3772.524	7608.983
Mei 2021	5715.403	3704.227	7618.616
Juni 2021	5760.152	3903.983	7743.004
Juli 2021	5778.096	3920.245	7554.969
Agustus 2021	5783.547	3906.012	7765.679
September 2021	5781.759	3590.521	7838.444
Oktober 2021	5833.098	3636.734	8180.088
November 2021	5856.625	3556.310	8314.625
Desember 2021	5848.609	3367.199	8188.077

Pada Tabel 9. terlihat bahwa peramalan harga GKG pada Januari-Desember 2021, harga tertinggi berada pada bulan November dengan harga sebesar Rp 5856,62 dan harga terendah berada pada bulan maret yaitu sebesar Rp 5684,07. Sedangkan untuk selang kepercayaannya dapat diinterpretasikan bahwa peramalan Harga GKG pada bulan Januari tidak akan lebih rendah dari Rp 4309,42 dan tidak akan lebih tinggi dari Rp 7197,23 begitupun seterusnya sesuai dengan Tabel 9.

Plot hasil ramalan dengan menggunakan metode Bootstrap Recurrent Forecasting pada SSA dan data aktual ditampilkan pada gambar 10.



Gambar 10. Perbandingan hasil Peramalan dengan Data Aktual

SIMPULAN dan SARAN

Simpulan

Berdasarkan uraian hasil analisis dan pembahasan, maka kesimpulan yang diperoleh dari penelitian ini adalah:

1. Data Rata-rata Harga GKG periode Januari 2008 hingga Desember 2020 memiliki rata-rata sebesar 4609 dan standar deviasi sebesar 976,5211. Selain itu juga dapat dilihat bahwa data Harga GKG terdiri dari komponen *trend*, komponen musiman, dan komponen *noise*.
2. Nilai MAPE yang didapatkan dari model SSA dengan menggunakan teknik *bootstrap-recurrent forecasting* dan parameter $L=7$ dan $r=7$ adalah sebesar 4,282746% menunjukkan bahwa tingkat keakuratan hasil ramalan yang didapatkan sangat baik.
3. Harga GKG tertinggi berada pada bulan November dengan harga sebesar Rp 5856,62 dan harga terendah berada pada bulan Maret yaitu sebesar Rp 5684,07. Sedangkan untuk selang kepercayaannya dapat diinterpretasikan bahwa peramalan Harga GKG pada bulan Januari tidak akan lebih rendah dari Rp 4309,42 dan tidak akan lebih tinggi dari Rp 7197,23 begitupun seterusnya sesuai dengan hasil peramalan.

Saran

Saran yang diberikan oleh peneliti untuk penelitian selanjutnya adalah :

1. Melakukan pengkajian lebih lanjut mengenai memilih komponen dalam pengelompokan eigentriple.
2. Melakukan pengkajian lebih lanjut mengenai kelebihan dan kelemahan untuk setiap teknik-teknik peramalan yang dapat dilakukan pada metode SSA seperti *Recurrent Forecasting*, *Vector Forecasting* dan *Teoplitz Forecasting*.

Daftar Pustaka

- Andhika, G. B., Sumarjaya, I. W., & Srinadi, I. G. A. M. (2020). Peramalan Nilai Tukar Petani Menggunakan Metode Singular Spectrum Analysis. *E-Jurnal Matematika*, 9(3), 171-176.

- Asrof, A. (2017). Peramalan Produksi Cabai Merah di Jawa Barat Menggunakan Metode Singular Spectrum Analysis (SSA). *STATISTIKA: Journal of Theoretical Statistics and Its Applications*, 17(2), 77-87.
- Ayomi, N., Ambarwati, R., & Abadi, A. M. (2018). Prediksi Harga Gabah Kering Giling dengan Sistem Fuzzy.
- Badan Pusat Statistik (BPS). (2020). Nilai Tukar Petani (NTP) Agustus 2020 sebesar 100,65 atau naik 0,56 persen. <https://www.bps.go.id/pressrelease/2020/09/01/1706/nilai-tukar-petani--ntp--agustus-2020-sebesar-100-65-atau-naik-0-56-persen.html>. 14 Desember 2020 (10:24)
- Badan Pusat Statistik (BPS). (2020). Harga Produsen. <https://www.bps.go.id/subject/36/harga-produsen.html>. 11 Desember 2020 (11:46)
- Badan Pusat Statistik (BPS). (2020). Rata-rata Harga Gabah Bulanan Menurut Kualitas, Komponen Mutu dan HPP di Tingkat Petani 2020. Badan Pusat Statistik (bps.go.id). 21 November 2020 (15:52)
- Darmawan, G. (2016). Identifikasi Pola Data Curah Hujan Pada Proses Grouping dalam Metode Singular Spectrum Analysis.
- Darmawan, G., Hendrawati, T., & Arisanti, R. (2015). Model Auto Singular Spectrum untuk Meramalkan Kejadian Banjir di Bandung dan Sekitarnya. In *Seminar Nasional Matematika dan Pendidikan Matematika UNY*.
- Cynthia, A., Sugiman, S., & Zaenuri, Z. (2016). Analisis Perbandingan Menggunakan ARIMA dan Bootstrap pada Peramalan Nilai Ekspor Indonesia. *UNNES Journal of Mathematics*, 5(1), 31-38.
- Golyandina, N., Nekrutkin, V., & Zhigljavsky, A. A. (2021). *Analysis of Time Series Structure : SSA and Related Techniques*. New York: Chapman & Hall/CRC.
- Golyandina, N., & Korobeynikov, A. (2014). Basic singular spectrum analysis and forecasting with R. *Computational Statistics & Data Analysis*, 71, 934-954
- Hanif, F. (2017). Teknik Peramalan Bootstrap-Recurrent pada Metode Singular Spectrum Analysis untuk Meramalkan Hasil Penjualan Energi Listrik. Skripsi. Universitas Padjadjaran (UNPAD). Bandung
- Indah, D. R., & Rahmadani, E. (2018). Sistem Forecasting Perencanaan Produksi dengan Metode Single Eksponensial Smoothing pada Keripik Singkong Srikandi Di Kota Langsa. *J. Penelit. Ekon. Akutansi*, 2(1), 10-18.
- Khaeri, H., Yulian, E., & Darmawan, G. (2018). Penerapan Metode Singular Spectrum Analysis (SSA) Pada Peramalan Jumlah Penumpang Kereta Api Di Indonesia Tahun 2017. *Euclid*, 5(1), 8-20.
- Lewis, C. D. (1997). *Demand Forecasting and Inventory Control: A Computer Aided Learning Approach*. https://books.google.com/books/about/Demand_Forecasting_and_Inventory_Control.html?hl=id&id=ga6AxVa23AgC. 13 Desember 2020 (00:08)
- Noviyar, G., Toharudin, T., Darmawan, G., & Winarni, S. (2013). Penerapan Singular Spectrum Analysis Dengan V-Forecasting Algorithm Pada Peramalan Penerimaan Pajak. *Journal Biostatistics | Departemen Statistika FMIPA Universitas Padjadjaran*, 7(2), 31-40.
- Rahmi, D. (2014). A forecasting algorithm for Singular Spectrum Analysis based on bootstrap Linear Recurrent Formula coefficients. *International Journal of Energy and Statistics*, 02, 287-299. DOI-10.1142/S2335680414500197
- Ruhat, D., Andiani, D., & Kamilah, W. N. (2020). Forecasting Data Runtun Waktu Musiman Menggunakan Metode Singular Spectrum Analysis (SSA). *Teorema: Teori dan Riset Matematika*, 5(1), 47-60.
- Sari, M. A. N., Sumarjaya, I. W., & Susilawati, M. (2019). Peramalan Jumlah Kunjungan Wisatawan Mancanegara ke Bali Menggunakan Metode Singular Spectrum Analysis. *E-Jurnal Matematika*, 8(4), 303-308.
- Setyowati, E. (2018). Model Hybrid Singular Spectrum Analysis dan Neural Network

untuk Peramalan Nilai Pecahan Inflow dan Outflow Uang Kartal di Indonesia (Doctoral dissertation, Institut Teknologi Sepuluh Nopember).

Siregar, R. S. K., Prariesa, D., & Darmawan, G. (2017). Aplikasi Metode Singular Spectral Analysis (SSA) dalam Peramalan Pertumbuhan Ekonomi Indonesia Tahun 2017. *Jurnal Matematika" MANTIK"*, 3(1), 5-12.

Shafira, D. (2020). Peramalan Wisatawan Mancanegara Berkunjung ke Bali Menggunakan Metode Singular Spectrum Analysis (SSA). Skripsi. Universitas Muhammadiyah Semarang (UNIMUS). Semarang

Syahputra, I., Fuadi, W., & Pratama, A. (2017). Peramalan Persediaan Gabah Kering Giling (GKG) Dengan Menggunakan Metode Lot Sizing Di Kilang Padi Markom. *Jurnal Sistem Informasi*, 1(2).

Zhigljavsky, A. (2011). Singular Spectrum Analysis for Time Series. In *International Encyclopedia of Statistical Science*. https://doi.org/10.1007/978-3-642-04898-2_5_hite/finalrp



