

## PERBANDINGAN PERAMALAN NILAI TUKAR RUPIAH TERHADAP DOLAR AMERIKA SERIKAT MENGGUNAKAN SINGULAR SPECTRUM ANALYSIS (SSA) DAN SUPPORT VECTOR REGRESSION (SVR)

Jelita Ratu Rizkiani<sup>1\*</sup>, Etik Zukhronah<sup>2</sup>, Respatiwan<sup>3</sup>

Program Studi Statistika, Universitas Sebelas Maret, Surakarta, Jawa Tengah

\*Penulis korespondensi: [jelitaratur@student.uns.ac.id](mailto:jelitaratur@student.uns.ac.id)

### ABSTRAK

Nilai tukar merupakan salah satu indikator penting dalam perkembangan ekonomi suatu negara sebab pergerakannya mempengaruhi stabilitas ekonomi. Saat ini, dolar Amerika Serikat (AS) menjadi acuan dalam menentukan nilai tukar mata uang negara lain. Pergerakan nilai tukar rupiah terhadap dolar AS terus berfluktuasi dari waktu ke waktu. Pergerakan ini berdampak luas pada perekonomian di Indonesia. Oleh karena itu, diperlukan peramalan untuk mengantisipasi dan meminimalisir dampak dari ketidakpastian pergerakan nilai tukar. *Singular Spectrum Analysis* (SSA) dan *Support Vector Regression* (SVR) merupakan metode yang dapat digunakan untuk meramalkan data runtun waktu. Tujuan dari penelitian ini adalah membandingkan hasil peramalan nilai tukar rupiah terhadap dolar AS menggunakan SSA dan SVR. Peramalan pada SSA dilakukan dengan menggunakan metode *recurrent*, sedangkan pada SVR dilakukan dengan bantuan fungsi kernel serta algoritma *grid search cross validation*. Di antara kedua metode tersebut dipilih metode yang lebih baik berdasarkan nilai *Mean Absolute Percentage Error* (MAPE) terkecil. Hasil penelitian menunjukkan bahwa SVR menghasilkan nilai MAPE yang lebih kecil yaitu sebesar 0,13% dibanding dengan SSA yang menghasilkan MAPE sebesar 0,16%. Dengan demikian, penelitian ini menyimpulkan bahwa SVR adalah metode yang lebih baik untuk meramalkan data nilai tukar rupiah terhadap dolar AS.

**Kata kunci:** SSA, SVR, Rupiah, Dolar AS, MAPE

### 1 PENDAHULUAN

Nilai tukar merupakan nilai mata uang suatu negara yang dibandingkan dengan mata uang negara lain (Are & Sitorus, 2020). Nilai tukar erat kaitannya dengan aktivitas perdagangan internasional. Pada perdagangan internasional, suatu mata uang akan dipertukarkan dengan mata uang negara lain. Besarnya nilai tukar suatu mata uang ditentukan melalui aktivitas tersebut. Dolar Amerika Serikat (AS), saat ini menjadi mata uang asing yang paling banyak digunakan sebagai alat transaksi perdagangan internasional, menjadikannya acuan dalam menentukan nilai tukar mata uang negara lain. Sebagai salah satu indikator penentu dalam perkembangan ekonomi suatu negara, pergerakan nilai tukar sangat mempengaruhi stabilitas ekonomi. Nilai tukar rupiah terhadap dolar AS diketahui terus mengalami fluktuasi setiap waktu. Dampak dari pergerakan ini masif dirasakan pada berbagai sektor ekonomi di Indonesia, seperti harga barang yang terus mengalami peningkatan, upah kerja yang cenderung stagnan, suku bunga meningkat, dan jumlah pengangguran bertambah dalam masyarakat. Bagi pelaku bisnis dan investasi, pergerakan nilai tukar mempengaruhi keuntungan yang didapatkan. *Singular Spectrum Analysis* (SSA) adalah metode peramalan yang menggunakan pendekatan nonparametrik untuk mengidentifikasi komponen tren, musiman, dan *noise* dari suatu runtun waktu. Pengaplikasian SSA bersifat lebih fleksibel dan terhindar dari berbagai asumsi (Golyandina and Korobeynikov, 2014). Selain SSA, metode peramalan *Support Vector Regression* (SVR) juga dapat digunakan untuk meramalkan data runtun waktu yang bersifat nonlinear.

Metode ini mampu mengatasi *overfitting* sehingga akan menghasilkan performansi yang bagus (Suprayogi dan Pardede, 2022).

Penelitian menggunakan SSA pernah dilakukan oleh Anshory dkk. (2020) untuk meramalkan nilai tukar rupiah terhadap dolar AS pada periode 2 Juni hingga 30 November 2020. Hasil penelitian menyimpulkan bahwa SSA mampu meramalkan data dengan sangat baik karena menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) data *testing* yang kecil yaitu sebesar 2,54%. Jayaswara et al. (2023) melakukan peramalan menggunakan SVR pada data harga saham Bank Central Asia. Dari peramalan tersebut diperoleh model SVR terbaik dengan fungsi kernel linear yang menghasilkan nilai MAPE data *training* sebesar 0,234% dan MAPE data *testing* sebesar 0,1021%. Hasilnya menunjukkan bahwa metode SVR dengan model tersebut memiliki kemampuan yang sangat baik dalam meramalkan harga saham Bank Central Asia.

Berdasarkan uraian di atas, diketahui bahwa SSA dan SVR memiliki kemampuan peramalan yang baik dalam meramalkan suatu data runtun waktu. Oleh karena itu, pada penelitian ini SSA dan SVR digunakan untuk meramalkan nilai tukar rupiah terhadap dolar AS. Penelitian ini bertujuan untuk menemukan metode yang lebih baik di antara kedua metode tersebut dalam meramalkan data nilai tukar rupiah terhadap dolar AS.

## 2 METODE

Penelitian ini menggunakan data harian nilai tukar rupiah terhadap dolar AS dari tanggal 28 April – 27 September 2023. Data yang digunakan merupakan data sekunder yang bersumber dari *website* resmi Bank Indonesia (BI) (Bank Indonesia, 2020). Data tersebut berjumlah 100 data yang dibagi menjadi dua, yaitu data *training* sebanyak 80 data (28 April – 30 Agustus 2023) dan data *testing* sebanyak 20 data (31 Agustus – 27 September 2023). Berikut langkah-langkah yang dilakukan dalam penelitian ini.

### 1. Melakukan peramalan menggunakan SSA.

#### a. Mendekomposisi data *training*.

##### 1) *Embedding*

Pada tahap ini, data runtun waktu berbentuk satu dimensi dengan panjang  $N$  diubah menjadi sebuah matriks lintasan  $\mathbf{X}$  berdimensi  $L \times K$ .  $L$  adalah *window length*, parameter tahap dekomposisi yang berguna dalam menentukan banyaknya dimensi matriks lintasan. Besarnya  $L$  ditentukan melalui *trial* dan *error* berdasarkan nilai MAPE terkecil dengan ketentuan  $2 < L < \frac{N}{2}$ . Sementara  $K$  dapat dihitung menggunakan rumus  $K = N - L + 1$ . Matriks lintasan  $\mathbf{X}$  diilustrasikan sebagai berikut (Golyandina & Zhigljavsky, 2013).

$$\mathbf{X} = \begin{pmatrix} x_1 & x_2 & x_3 & \cdots & x_K \\ x_2 & x_3 & x_4 & \cdots & x_{K+1} \\ x_3 & x_4 & x_5 & \cdots & x_{K+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & x_{L+2} & \cdots & x_N \end{pmatrix}$$

##### 2) *Singular Value Decomposition* (SVD)

Tahap SVD dilakukan dengan mendekomposisi matriks lintasan  $\mathbf{X}$  menjadi sebanyak  $d$  matriks dengan  $d = \max\{i, \lambda_i > 0\}$ . SVD dari matriks lintasan  $\mathbf{X}$  dapat dinyatakan melalui persamaan (1).

$$\mathbf{X} = \mathbf{X}_1 + \cdots + \mathbf{X}_d \text{ dengan } \mathbf{X}_i = \sqrt{\lambda_i} \mathbf{U}_i \mathbf{V}_i^T \quad (1)$$

Matriks  $\mathbf{X}_i$  terbentuk dari *eigen triple* yang terdiri atas *singular value* ( $\sqrt{\lambda_i}$ ), *eigenvector* ( $\mathbf{U}_i$ ), dan *principal component* ( $\mathbf{V}_i^T$ ). Dimisalkan matriks  $\mathbf{S} = \mathbf{X}\mathbf{X}^T$ , maka diperoleh  $\lambda_1, \dots, \lambda_L$  dengan  $\lambda_1 \geq \dots \geq \lambda_L \geq 0$  merupakan *eigenvalue* dari matriks  $\mathbf{S}$  dan  $\mathbf{U}_1, \dots, \mathbf{U}_L$  adalah *eigenvector*.  $\mathbf{V}_i = \frac{\mathbf{X}^T \mathbf{U}_i}{\sqrt{\lambda_i}}$  untuk  $i = 1, 2, \dots, d$  adalah *principal component*.

b. Merekonstruksi data *training*.

1) *Grouping*

*Grouping* bertujuan untuk memisahkan komponen SVD ke dalam beberapa sub kelompok, seperti tren, musiman, dan *noise* (Idrus dkk., 2022). Matriks  $\mathbf{X}_i$  dengan  $i = 1, \dots, d$  sebagai hasil dari tahap dekomposisi dipartisi menjadi  $m$  himpunan bagian yang saling lepas,  $I_k$  ( $k = 1, 2, \dots, m; m \leq d$ ) sehingga persamaan (1) dapat ditulis menjadi persamaan (2).

$$\mathbf{X} = \mathbf{X}_{I_1} + \mathbf{X}_{I_2} + \dots + \mathbf{X}_{I_m} \text{ dengan } \mathbf{X}_{I_k} = \sum_{i \in I_k} \mathbf{X}_i \quad (2)$$

Penentuan himpunan  $I_k$  ( $k = 1, 2, \dots, m; m \leq d$ ) disebut sebagai pengelompokan *eigen triple* yang dilakukan dengan melihat grafik nilai singular. Melalui grafik tersebut dapat ditentukan parameter *grouping effect* ( $r$ ) dari *eigen triple* yang tidak mencerminkan *noise*. Selanjutnya, *eigen triple* dapat dikelompokkan ke dalam kelompok tren, musiman, dan *noise* dengan menggunakan grafik rekonstruksi deret dan kontribusi.

2) *Diagonal Averaging*

Pada tahap ini, setiap matriks  $\mathbf{X}_{I_k}$  dari tahap *grouping* ditransformasikan menjadi sebuah runtun waktu baru dengan panjang  $N$  sehingga terbentuk runtun rekonstruksi  $\tilde{\mathbf{X}}^{(k)} = (\tilde{x}_1^{(k)}, \dots, \tilde{x}_p^{(k)}, \dots, \tilde{x}_N^{(k)})$ . Runtun rekonstruksi tersebut diperoleh dengan menggunakan persamaan (3).

$$y_k = \begin{cases} \frac{1}{k} \sum_{m=1}^k y_{m, k-m+1}^* & ; 1 \leq k \leq L^* \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m, k-m+1}^* & ; L^* \leq k \leq K^* \\ \frac{1}{N-k+1} \sum_{m=k-K^*+1}^{N-K^*+1} y_{m, k-m+1}^* & ; K^* \leq k \leq N \end{cases} \quad (3)$$

$y_{ij}$  adalah elemen matriks  $\mathbf{X}_{I_k}$  dan  $i + j = k + 1$ . Runtun waktu awal  $\mathbf{X}_N = (x_1, \dots, x_p, \dots, x_N)$  telah didekomposisi menjadi jumlah dari  $m$  runtun rekonstruksi yang dinyatakan pada persamaan (4).

$$x_p = \sum_{k=1}^m \tilde{x}_p^{(k)} \quad ; p = 1, 2, \dots, N \quad (4)$$

c. Meramalkan data *testing*.

Data *testing* diramalkan dengan menggunakan metode *recurrent* (*R-Forecasting*), yaitu metode dasar yang sering digunakan pada peramalan SSA karena relatif lebih mudah (Golyandina *et al.*, 2001). Metode ini berkaitan dengan penaksiran koefisien *Linear Recurrent Formula* (LRF) yang diperoleh dari *eigenvector* hasil SVD. Runtun waktu yang digunakan dalam peramalan SSA adalah runtun waktu rekonstruksi hasil dari *diagonal averaging*, kemudian ditentukan  $M$  titik data baru yang akan diramalkan dengan menggunakan persamaan (5).

$$\hat{y}_i = \begin{cases} \tilde{x}_i & ; i = 1, \dots, N \\ \sum_{j=1}^{L-1} a_j \hat{y}_{i-j} & ; i = N + 1, \dots, N + M \end{cases} \quad (5)$$

Persamaan (5) menghasilkan  $\hat{Y} = (\hat{y}_1, \dots, \hat{y}_{N+M})$  dimana  $\hat{y}_{N+1}, \dots, \hat{y}_{N+M}$  adalah hasil ramalan untuk M periode ke depan.

## 2. Melakukan peramalan menggunakan SVR.

### a. *Pre-processing*.

*Pre-processing* dilakukan dengan melakukan normalisasi data. Normalisasi data bertujuan untuk menstandarkan data agar berada pada jarak tertentu. Pada penelitian ini, normalisasi data dilakukan dengan menggunakan skala MinMax

### b. Menentukan nilai *timesteps*.

*Timesteps* merupakan jeda waktu yang digunakan pada peramalan metode SVR, dimana pada metode ini mempertimbangkan hubungan antara nilai periode  $y_t$  dengan nilai dari data elemen runtun waktu sebelumnya. Nilai *timesteps* ditentukan melalui *trial* dan *error* dengan memperhatikan nilai MAPE terkecil.

### c. Menentukan nilai percobaan *hyperparameter*.

*Hyperparameter* yang berperan penting dalam membentuk model pada metode SVR adalah parameter  $C$ ,  $\epsilon$ , dan fungsi kernel beserta parameternya (Patriya, 2020). Fungsi kernel yang diuji coba pada penelitian ini adalah kernel linear, RBF, dan sigmoid.

### d. Melakukan *tuning hyperparameter*.

*Tuning hyperparameter* dilakukan dengan menggunakan kombinasi *grid search* dan *k-fold cross validation*. *Grid search* merupakan algoritma pada SVR yang berguna dalam menentukan parameter optimal, bekerja dengan cara membagi rentang parameter yang akan dioptimalkan ke dalam *grid* dan mencoba setiap kemungkinan untuk memperoleh parameter optimal (Qadri, 2022). Parameter optimal dipilih dengan melihat nilai *error* terkecil dari semua parameter yang dicobakan pada data *training*. Nilai *error* tersebut dihitung dengan menggunakan *k-fold cross validation* yang membagi data menjadi  $k$  kelompok berukuran sama besar dan menggunakan  $k-1$  bagian sebagai data *training* untuk melatih model, sedangkan sisa bagian lainnya digunakan sebagai data *testing* untuk mengevaluasi kinerja model. Nilai  $k$  yang digunakan pada penelitian ini adalah 5.

### e. Meramalkan data *testing*.

Parameter optimal yang diperoleh dari tahap *tuning hyperparameter* kemudian digunakan untuk meramalkan data *testing*.


## 3. Membandingkan hasil peramalan kedua metode dengan melihat nilai MAPE.

Hasil peramalan dari kedua metode dibandingkan untuk melihat metode mana yang lebih baik dalam meramalkan data nilai tukar rupiah terhadap dolar AS. *Mean Absolute Percentage Error* (MAPE) digunakan untuk mengukur nilai kesalahan peramalan pada penelitian ini. Semakin kecil nilai MAPE suatu metode, maka semakin baik hasil peramalan yang dihasilkan metode tersebut (Sam dkk., 2022). MAPE dapat dihitung menggunakan persamaan (6).

$$MAPE = \frac{\sum \left| \frac{y_t - \hat{y}_t}{y_t} \right|}{n} \times 100\% \quad (6)$$

dengan  $n$  adalah jumlah data,  $y_t$  adalah nilai aktual pada periode ke- $t$ , dan  $\hat{y}_t$  adalah nilai peramalan pada periode ke- $t$ .

### 3 HASIL DAN PEMBAHASAN



**Gambar 1.** Plot Data Nilai Tukar Rupiah terhadap Dolar AS

**Gambar 1** menunjukkan bahwa data nilai tukar rupiah terhadap dolar AS dari tanggal 28 April hingga 30 Agustus 2023 cenderung meningkat seiring berjalannya waktu. Berdasarkan pola tersebut, maka plot data di atas dapat diidentifikasi berpola tren.

#### 3.1 Peramalan Metode SSA

Peramalan menggunakan metode SSA diawali dengan tahap dekomposisi, tahap ini dimulai dengan proses *embedding*. Pada proses ini dilakukan percobaan untuk menentukan nilai  $L$  yang berada di rentang  $2 < L < 40$ . Diperoleh  $L$  dengan MAPE terkecil sebesar 0,16% pada  $L = 40$ . Selanjutnya, ditentukan nilai  $K = 80 - 40 + 1 = 41$ . Dengan demikian, matriks lintasan  $X$  berdimensi  $40 \times 41$  dapat disusun sebagai berikut.

$$X = \begin{pmatrix} 14661 & 14703 & 14706 & \dots & 15018 \\ 14703 & 14706 & 14632 & \dots & 15013 \\ 14706 & 14632 & 14674 & \dots & 15062 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 15034 & 15018 & 15013 & \dots & 15239 \end{pmatrix}$$


Dekomposisi dilanjutkan dengan proses SVD, matriks lintasan  $X$  didekomposisi menjadi 40 *eigentruple* yang terdiri dari 40 *eigenvector*, 40 *singular value*, dan 40 *principal component*. Hasil SVD ditunjukkan pada **Tabel 1**.

**Tabel 1.** Komponen *Eigentruple*

$i$	<i>Singular Value</i> ( $\sqrt{\lambda_i}$ )	<i>Eigenvector</i> ( $U_i$ )			<i>Principal Component</i> ( $V_i$ )		
1	607967,2	-0,1567	...	0,2462	-0,1547	...	-0,0341
2	1344,9	-0,1568	...	-0,1797	-0,1548	...	0,2459
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
40	13,7	-0,1596	...	-0,2851	-0,1576	...	0,3019
41					-0,1576	...	-0,2611


Tahap kedua, yaitu rekonstruksi yang terdiri dari *grouping* dan *diagonal averaging*. Pada proses *grouping*, *eigentruple* hasil dari tahap SVD dikelompokkan berdasarkan kemiripan

karakteristiknya. Pengelompokan dilakukan dengan mempertimbangkan grafik nilai singular, rekonstruksi deret, dan kontribusi.




**Gambar 2.** Scree Plot 40 Singular Value

**Gambar 2** menunjukkan bahwa *singular value* mulai menurun secara lambat pada *eigen triple* 4 sampai *eigen triple* 40 sehingga dapat diidentifikasi sebagai komponen *noise*. Dengan demikian, nilai parameter  $r = 3$  karena ketiga *eigen triple* tersebut tidak mencerminkan *noise*. Selanjutnya, ketiga *eigen triple* tersebut digunakan untuk pengelompokan komponen tren dan musiman dengan membentuk grafik rekonstruksi deret dan kontribusi.




**Gambar 3.** Plot Rekonstruksi Deret



**Gambar 4.** Plot Kontribusi

**Gambar 3** menunjukkan bahwa *eigen triple* 1 memuat komponen yang bervariasi secara lambat sehingga diidentifikasi sebagai komponen tren. Selain itu, pada **Gambar 4**, diketahui bahwa *eigen triple* 1 memiliki kontribusi sebesar 100% pada keseluruhan *eigen triple* sehingga *eigen triple* 2 dan 3 termasuk ke dalam komponen *noise*.

Setelah masing-masing komponen telah berhasil dikelompokkan, kemudian direkonstruksi menggunakan *eigen triple* masing-masing melalui tahap terakhir dari rekonstruksi yaitu *diagonal averaging*.



**Gambar 5.** Plot Hasil Rekonstruksi Kelompok Komponen

**Gambar 5** menyajikan plot hasil rekonstruksi dengan keterangan *original* merupakan data *training*, *reconstructed* merupakan data hasil rekonstruksi dari komponen tren, dan *residuals* merupakan selisih antara data *training* dan data hasil rekonstruksi.

Peramalan SSA pada data *testing* dilakukan dengan terlebih dahulu menghitung koefisien LRF untuk membentuk model. Model peramalan SSA yang terbentuk setelah nilai koefisien LRF diperoleh adalah sebagai berikut.

$$\hat{y}_i = \sum_{j=1}^{40-1} a_j \hat{y}_{i-j} = 0,0261189 \hat{y}_{i-1} + \dots + 0,025655108 \hat{y}_{i-39}$$

untuk  $i = 81, 82, \dots, 100$

Hasil peramalan data *testing* menggunakan model di atas dapat dilihat melalui **Tabel 2**.

**Tabel 2.** Perbandingan Data *Testing* dan Data Hasil Peramalan Metode SSA

$t$	Data <i>Testing</i>	Hasil Peramalan
81	15237	15295,67
82	15252	15302,75
83	15247	15309,83
⋮	⋮	⋮
100	15526	15434,93

### 3.2 Peramalan Metode SVR

Langkah pertama pada peramalan menggunakan metode SVR adalah *pre-processing* data. Data dinormalisasi dengan cara *scaling* menggunakan skala MinMax. Skala MinMax akan mengubah nilai data menjadi berada pada rentang nilai 0 sampai 1 (Rahmawati, 2023). Proses normalisasi dilakukan dengan tujuan agar data seragam berada pada jarak tertentu.

Setelah dilakukan normalisasi, dilanjutkan dengan menentukan nilai *timesteps* melalui *trial* dan *error* hingga diperoleh nilai *timesteps* dengan MAPE terkecil. **Tabel 3** menunjukkan bahwa nilai MAPE terkecil dimiliki oleh *timesteps* = 6 yaitu sebesar 0,13%.

**Tabel 3.** Nilai *timesteps* dan MAPE

<i>Timesteps</i>	MAPE (%)
2	0,16
3	0,17
4	0,17
5	0,17
6	0,13
7	0,15


Selain nilai *timesteps*, perlu ditentukan juga nilai percobaan untuk *hyperparameter* SVR yang terdiri dari parameter  $C$ ,  $\epsilon$ , dan fungsi kernel beserta parameternya. Penelitian ini menggunakan

fungsi kernel linear, RBF, dan sigmoid.  $\gamma$  merupakan parameter untuk kernel RBF dan sigmoid. Nilai percobaan *hyperparameter* SVR disajikan melalui **Tabel 4**.

**Tabel 4.** Nilai Percobaan *Hyperparameter* SVR

Parameter	Nilai Percobaan
$C$	$10^{-3}, 10^{-2}, 10^{-1}, \dots, 10^3$
$\varepsilon$	$10^{-3}, 10^{-2}, 10^{-1}, \dots, 10^3$
$\gamma$	$10^{-3}, 10^{-2}, 10^{-1}, \dots, 10^3$

Penentuan parameter dan jenis fungsi kernel terbaik dilakukan melalui proses *tuning hyperparameter* dengan menggunakan kombinasi *grid search* dan *k-fold cross validation*. Untuk melatih model pada data *training* digunakan  $k = 5$  dan diperoleh parameter terbaik dengan nilai *error* terkecil yaitu parameter  $C = 1000$ ,  $\varepsilon = 0,01$ , dan  $\gamma = 0,01$ , serta fungsi kernel sigmoid. Parameter tersebut selanjutnya digunakan untuk meramalkan data *testing*. Hasil peramalan disajikan dalam bentuk plot perbandingan pada **Gambar 6**.



**Gambar 6.** Plot Perbandingan Data *Testing* dan Data Hasil Peramalan Metode SVR

Plot hasil peramalan menggunakan metode SVR terlihat cukup mengikuti plot data *testing*.

### 3.3 Perbandingan Hasil Peramalan

Setelah diperoleh hasil peramalan dari kedua metode, dilakukan evaluasi terhadap hasil tersebut menggunakan MAPE. Nilai MAPE yang semakin kecil menunjukkan bahwa semakin kecil kesalahan peramalan yang dihasilkan suatu metode. Perbandingan nilai MAPE metode SSA dan SVR ditunjukkan melalui **Tabel 5**.

**Tabel 5.** Perbandingan Nilai MAPE Metode SSA dan SVR

Data	MAPE SSA (%)	MAPE SVR (%)
<i>Training</i>	0,36	0,21
<i>Testing</i>	0,16	0,13

Berdasarkan **Tabel 5**, diketahui bahwa metode SVR memiliki nilai MAPE yang lebih kecil daripada metode SSA sehingga dapat disimpulkan bahwa metode yang lebih baik untuk meramalkan data nilai tukar rupiah terhadap dolar AS adalah metode SVR.

## 4 KESIMPULAN



Berdasarkan hasil dan pembahasan dapat disimpulkan bahwa metode SVR merupakan metode yang lebih baik dalam meramalkan data nilai tukar rupiah terhadap dolar AS dibanding dengan metode SSA. Metode SVR dengan nilai  $timesteps = 6$  dan parameter terbaik  $C = 1000$ ,  $\varepsilon = 0,01$ ,  $\gamma = 0,01$ , serta fungsi kernel sigmoid menghasilkan nilai MAPE data *testing* sebesar 0,13%. Sedangkan, metode SSA dengan parameter  $L = 40$  dan  $r = 3$  menghasilkan nilai MAPE data *testing* sebesar 0,16%.

## DAFTAR PUSTAKA

- Anshory, M.A.H.A., Sulandari, W., & Susanti, Y. (2020). Peramalan Nilai Tukar Rupiah terhadap Dolar Amerika Serikat Menggunakan Singular Spectrum Analysis. *Prosiding Seminar Nasional Pendidikan dan Ilmu Matematika (SENANDIKA)*. <https://conference.unisma.ac.id/index.php/senandika/2020/paper/view/1055>.
- Are, G.P.B. & Sitorus, S.H. (2020). Prediksi Nilai Tukar Mata Uang Rupiah Terhadap Dolar Amerika Menggunakan Metode Hidden Markov Model. *Coding : Jurnal Komputer dan Aplikasi*, 8(1), 44-54. <https://dx.doi.org/10.26418/coding.v8i1.39192>.
- Bank Indonesia. (2020). *Informasi Kurs JISDOR* [Data set]. <https://www.bi.go.id/id/statistik/informasi-kurs/jisdor/Default.aspx>.
- Golyandina, N. & Korobeynikov, A. (2014). Basic Singular Spectrum Analysis and Forecasting with R. *Computational Statistics dan Data Analysis*, 71, 934-954. <http://dx.doi.org/10.1016/j.csda.2013.04.009>.
- Golyandina, N. & Zhigljavsky, A. (2013). *Singular Spectrum Analysis for Time Series*, New York: Spinger Briefs in Statistics.
- Golyandina, N., Nekrutkin, V., & Zhigljavsky, A.A. (2001). *Analysis of Time Series Structure: SSA and Related Techniques*, Florida: Chapman dan Hall/CRC.
- Idrus, R.A., Ruliana, & Aswi. (2022). Penerapan Metode Singular Spectrum Analysis dalam Peramalan Jumlah Produksi Beras di Kabupaten Gowa. *VARIANSI: Journal of Statistics and Its Application on Teaching and Research*, 4(2), 49-58. <https://doi.org/10.35580/variansiunm40>.
- Jayaswara, D.G., Slamet, I., & Susanti, Y. (2023). Prediction of Central Asia Bank's Stock Price using Support Vector Regression Method. *Proceeding International Conference on Religion, Science and Education*, 2, 7-12. <https://sunankalijaga.org/prosiding/index.php/icrse/article/view/883>.
- Patriya, E. (2020). Implementasi Support Vector Machine pada Prediksi Harga Saham Gabungan (IHSG). *Jurnal Ilmiah Teknologi dan Rekayasa*, 25(1), 24-38. <https://doi.org/10.35760/tr.2020.v25i1.2571>.
- Qadri, L. (2022). *Prediksi Curah Hujan dengan Menggunakan Algoritma Support Vector Regression* [Skripsi, Universitas Hasanuddin]. Arsip Digital Universitas Hasanuddin. <https://repository.unhas.ac.id/id/eprint/32395/>.
- Rahmawati, E. (2023). *Penerapan Metode Support Vector Regression (SVR) Menggunakan Kernel Linear, Polinomial, dan Radial dengan Grid Search Optimization* [Skripsi, Universitas Lampung]. Arsip Digital Universitas Lampung. <http://digilib.unila.ac.id/74539/3/SKRIPSI%20TANPA%20BAB%20PEMBAHASAN.pdf>.
- Sam, M., Kurniawati, E., & Fausia, S. R. (2022). Peramalan Permintaan Smartphone Oppo Android Menggunakan Metode Single Moving Average. *Infinity: Jurnal Matematika Dan Aplikasinya*, 2(2), 93-103. <https://doi.org/10.30605/27458326-93>.
- Suprayogi, D. & Pardede, H.F. (2022). Support Vector Regression dalam Prediksi Penurunan Jumlah Kasus Penderita Covid-19. *(JOINTECS) Journal of Information Technology and Computer Science*, 7(2), 63-70. <https://doi.org/10.31328/jointecs.v7i2.3687>.