



Perbandingan Hasil Peramalan Uang M1 di Indonesia Menggunakan Metode SARIMA dan Metode SVR

Etik Zukhronah*, Nurul Hidayah, Irwan Susanto

Fakultas Matematika dan Ilmu Pengetahuan Alam, Program Studi Statistika, Universitas Sebelas Maret, Kota Surakarta, Indonesia

Email: ^{1,*}etikzukhronah@staff.uns.ac.id, ²nurulhidayah99@student.uns.ac.id, ³irwansusanto@staff.uns.ac.id

Email Penulis Korespondensi: etikzukhronah@staff.uns.ac.id

Abstrak—Uang M1 merupakan bentuk uang beredar paling likuid karena seluruh komponennya (kartal dan giral) dapat langsung digunakan untuk transaksi harian serta mencerminkan dinamika konsumsi masyarakat. Peramalan uang M1 diperlukan untuk mengantisipasi fluktuasinya yang dapat memengaruhi stabilitas harga dan inflasi. Penelitian ini bertujuan untuk membandingkan hasil peramalan uang M1 dengan metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dan *Support Vector Regression* (SVR). Data Uang M1 dibagi menjadi dua, yaitu 80% data *training* dari bulan Januari 2010 hingga bulan Februari 2021 dan 20% data *testing* dari bulan Maret 2021 hingga bulan Desember 2023. Pemodelan SARIMA dan SVR dilakukan terpisah yang kemudian model terbaik dipilih berdasarkan *Mean Absolute Percentage Error* (MAPE) terkecil. Hasil penelitian didapatkan model SARIMA terbaik adalah SARIMA (1,1,0)(1,1,0)₁₂ dengan MAPE sebesar 2,250%, sedangkan model SVR terbaik menggunakan kernel linear dengan *hyperparameter* optimalnya $C=100$; $\epsilon=0,001$; dan $\gamma=0,001$ menghasilkan MAPE sebesar 2,254%. Dengan demikian, model SARIMA memiliki tingkat akurasi yang lebih baik dalam memprediksi uang M1 di Indonesia. Penerapan model ini dalam memprediksi diharapkan dapat membantu pihak terkait dalam mengevaluasi arah kebijakan moneter serta memahami kondisi ekonomi.

Kata Kunci: Uang M1; *Seasonal Autoregressive Integrated Moving Average*; *Support Vector Regression*; *Mean Absolute Percentage Error*; *Hyperparameter*

Abstract—M1 money is the most liquid form of money supply because all its components (currency and giral) can be directly used for daily transactions and reflect the dynamics of public consumption. M1 money forecasting is necessary to anticipate its fluctuations that can affect price stability and inflation. This study aims to compare the results of M1 money forecasting with the Seasonal Autoregressive Integrated Moving Average (SARIMA) and Support Vector Regression (SVR) methods. The M1 Money data is divided into two, 80% training data from January 2010 to February 2021 and 20% testing data from March 2021 to December 2023. SARIMA and SVR modeling were carried out separately and then the best model was selected based on the smallest Mean Absolute Percentage Error (MAPE). The results of the study found that the best SARIMA model is SARIMA (1,1,0)(1,1,0)₁₂ with a MAPE of 2,250%, while the best SVR model uses a linear kernel with optimal hyperparameters $C=100$; $\epsilon=0,001$; and $\gamma=0,001$ resulting in a MAPE of 2,254%. Thus, the SARIMA model has a better level of accuracy in predicting M1 money in Indonesia. The application of this model in predicting is expected to help related parties in evaluating the direction of monetary policy and understanding economic conditions.

Keywords: M1 Money; Seasonal Autoregressive Integrated Moving Average; Support Vector Regression; Mean Absolute Percentage Error; Hyperparameter

1. PENDAHULUAN

Perkembangan uang beredar dalam arti sempit (M1) di Indonesia penting untuk memahami dinamika ekonomi makro. Fokus utamanya meliputi konsumsi rumah tangga, inflasi, dan efektivitas kebijakan moneter. Uang M1 terdiri atas uang kartal dan giral yang mencerminkan likuiditas tertinggi (Ambarwati et al., 2021). Hal tersebut karena seluruh komponennya dapat langsung digunakan masyarakat untuk transaksi ekonomi sehari-hari. Data Badan Busat Statistik (BPS) pada tahun 2023 menunjukkan bahwa fluktuasi uang M1 sebagai penyumbang komponen terbesar dalam jumlah uang beredar sejalan dengan uang M2. Perkembangan uang M1 yang beredar setiap bulan di tahun 2023 menunjukkan tren yang meningkat setiap bulannya. Tren kenaikan ini dapat berkontribusi positif terhadap pertumbuhan ekonomi namun juga berpotensi menimbulkan tekanan inflasi apabila tidak dikendalikan dengan baik.

Fluktuasi jumlah uang M1 berdampak langsung terhadap daya beli masyarakat. Daya beli meningkat saat pendapatan masyarakat naik dan harga barang relatif stabil. Daya beli akan menurun jika harga barang naik tetapi tidak diiringi pertumbuhan pendapatan (Fadilah et al., 2024). Peramalan uang M1 penting karena dapat memberikan gambaran awal mengenai arah pergerakan likuiditas dalam perekonomian. Akurasi prediksi mendukung pengambilan keputusan yang tepat dalam perumusan kebijakan moneter, pengendalian inflasi, dan perencanaan ekonomi. Bank Indonesia memiliki peran strategis mengelola jumlah uang beredar melalui kebijakan moneter. Penurunan suku bunga akan meningkatkan likuiditas perekonomian. Kondisi ini mendorong pertumbuhan M1 karena masyarakat lebih terdorong melakukan konsumsi dan investasi. Kebijakan moneter kontraktif menekan pertumbuhan M1 melalui pembatasan likuiditas. Oleh karena itu, peramalan yang akurat terhadap pergerakan M1 sangat penting sebagai alat bantu dalam mengevaluasi arah dan efektivitas kebijakan moneter yang diterapkan (Isnaeni et al., 2022).


Penelitian terdahulu yang secara spesifik melakukan peramalan uang M1 di Indonesia dengan pendekatan statistik klasik dan *machine learning* masih terbatas. Akurasi prediksi terhadap uang M1 sangat menentukan ketepatan kebijakan pengendalian inflasi dan kestabilan sistem keuangan secara umum. Oleh karena itu, diperlukan metode peramalan yang akurat dan andal dalam menghadapi dinamika jumlah uang M1 yang terus berubah di tengah kompleksitas ekonomi global dan domestik. Salah satu pendekatan statistik klasik yang banyak digunakan dalam peramalan data runtun waktu adalah metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA). SARIMA

merupakan pengembangan metode ARIMA untuk data runtun waktu berpola musiman. Metode ini sangat cocok untuk menganalisis data ekonomi berpola musiman seperti uang M1. Kelebihan dari metode SARIMA adalah semua pola data runtun waktu dapat dianalisis dengan syarat data harus distasionerkan terlebih dahulu sebelum dianalisis (Dimashanti & Sugiman, 2021). SARIMA memiliki keterbatasan dalam menangani pola data nonlinear dan kompleks. Metode *Support Vector Regression* (SVR) hadir sebagai alternatif berbasis machine learning. Metode Support Vector Regression (SVR) mengadopsi prinsip Support Vector Machine (SVM) guna membangun model regresi yang menangkap pola nonlinear antara data *input* dan *output* (Habibi et al., 2025). Metode ini dikenal memiliki kemampuan generalisasi baik bahkan pada data *noise* tinggi. Kelebihan SVR tidak memerlukan asumsi data stasioner seperti SARIMA.

Penelitian menggunakan metode SARIMA dan SVR telah banyak dilakukan sebelumnya. (Ivanda & SZS, 2025) melakukan peramalan inflasi Indonesia dengan metode SARIMA. Model terbaik yang diperoleh adalah SARIMA (1,1,1) dengan nilai MAPE sebesar 2,04% (Ruliana et al., 2024) melakukan peramalan data bulanan inflasi di Kota Makassar dari bulan Januari 2014 hingga bulan Desember 2022 dengan metode SVR. Model terbaik yang didapat menggunakan kernel RBF dengan parameter optimalnya $\epsilon = 0,01$, $C = 100$, dan $\gamma = 10$. Nilai RMSE dari model terbaik tersebut sebesar 0,029. Berdasarkan dua penelitian sebelumnya diketahui bahwa metode SARIMA dan SVR tergolong baik untuk peramalan data *time series* ekonomi. Penelitian ini menggunakan dua metode, yaitu SARIMA dan SVR yang kemudian akan dibandingkan kinerjanya dalam meramalkan uang M1 di Indonesia. Penentuan metode terbaik dilihat berdasarkan nilai *Mean Absolute Percentage Error* (MAPE) yang lebih kecil.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan data sekunder yang diperoleh dari laman resmi Badan Pusat Statistik (BPS) berupa data bulanan uang M1 di Indonesia dari bulan Januari 2010 hingga bulan Desember 2023 (Badan Pusat Statistik, 2024). Peneliti membagi data menjadi dua, yaitu 80% data *training* dari bulan Januari 2010 hingga bulan Februari 2021 dan 20% data *testing* dari bulan Maret 2021 hingga bulan Desember 2023. Analisis data dalam penelitian ini menggunakan dua metode, yaitu metode SARIMA dan SVR yang dilakukan secara terpisah. Diagram alur penelitian dapat dilihat pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

2.1 Pemodelan data dengan metode SARIMA

Metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) merupakan pengembangan dari metode *Autoregressive Integrated Moving Average* (ARIMA) yang digunakan untuk menganalisis data runtun waktu berpola musiman (Kruba et al., 2025) (Rangkuti et al., 2025). Kelebihan dari metode SARIMA adalah semua pola data runtun waktu dapat dianalisis dengan syarat data harus stasioner (Junaedi et al., 2025).

- Membuat plot data *training* untuk mengidentifikasi karakteristik datanya.
- Mengidentifikasi kestasioneran data dalam variansi dan rata-rata. Data yang tidak stasioner terhadap variansi dapat dilakukan transformasi Box-Cox dengan parameter tunggal λ . Nilai λ dalam uji Box-Cox menunjukkan jenis transformasi yang tepat untuk membuat variansi data lebih stabil/konstan (Hayati & Agustina, 2024). Tabel 1 memuat beberapa penggunaan nilai λ beserta bentuk transformasinya.

Tabel 1. Transformasi Pangkat Box-Cox

Nilai λ	Transformasi
	1
-1	$\frac{1}{Y_t}$
	1
-0,5	$\sqrt{Y_t}$
0	$\ln Y_t$
0,5	$\sqrt{Y_t}$
1	Y_t

Data runtun waktu yang memiliki λ bernilai 1 tidak perlu dilakukan transformasi Box-Cox karena data runtun waktu berarti sudah stasioner terhadap variansi. Pengujian kestasioneran data yang kedua adalah uji stasioneritas dalam rata-rata yang dapat dilakukan dengan uji akar unit *Augmented Dickey-Fuller* (ADF). Data dikatakan



stasioner dalam rata-rata apabila $p\text{-value} < \alpha$. Selanjutnya, data runtun waktu yang tidak stasioner dalam rata-rata dilakukan proses *differencing*.

- c. Menentukan orde p, P, q, dan Q berdasarkan plot ACF dan PACF data *training* yang telah stasioner. Notasi umum dari model SARIMA adalah ARIMA(p, d, q)(P, D, Q)_s. p dan P adalah orde nonmusiman dan musiman AR, d dan D adalah banyaknya *differencing* nonmusiman dan musiman, q dan Q adalah orde nonmusiman dan musiman MA, serta S adalah periode musiman.
- d. Melakukan estimasi dan uji signifikansi parameter model SARIMA. Parameter yang signifikan memiliki $p\text{-value} > \alpha$. Selanjutnya, dilakukan uji asumsi residu berupa uji normalitas dengan menggunakan uji Kolmogorov-Smirnov dan uji *white noise* dengan menggunakan uji Ljung-Box. Residu model dikatakan memenuhi uji normalitas dan *white noise* apabila $p\text{-value} > \alpha$.
- e. Menentukan model SARIMA terbaik dengan melihat nilai MAPE terkecil.

2.2 Pemodelan data dengan metode SVR

Support Vector Regression (SVR) merupakan pengembangan dari metode *Support Vector Machine* (SVM) untuk regresi. Algoritma SVR bertujuan menemukan suatu fungsi yang mempunyai batasan ϵ paling besar sehingga didapatkan nilai target dari keseluruhan data *training* (Rizkiani et al., 2024). Tujuan lain dari algoritma SVR adalah menentukan *hyperplane* atau garis pembatas terbaik berupa fungsi regresi dengan kesalahan sekecil mungkin dalam batas toleransi tertentu (Almahdy & D, 2024) (Fadhil, 2025).

- a. Melakukan *scaling* data dengan normalisasi Min-Max yang dapat dihitung dengan Persamaan (1) (Pratama & Salam, 2025) (Allorerung et al., 2024).

$$y_{\text{scaled}} = \frac{y - y_{\text{min}}}{y_{\text{max}} - y_{\text{min}}} \tag{1}$$

- b. Melakukan pemodelan SVR pada data *training* dengan *trial* dan *error* nilai *timesteps* dari 2 hingga 12 serta menentukan nilai *hyperparameter* C, ϵ , γ , dan kernel yang digunakan dalam analisis dimana kombinasi *hyperparameter* optimalnya diperoleh dengan metode *grid search* yang dalam prosesnya dijalankan dengan menggunakan teknik *time series cross-validation*. *Cross-validation* pada data *time series* sangat memperhatikan urutan waktu, sehingga setiap bagian data yang digunakan untuk validasi terdiri dari titik-titik data yang berurutan (Deng, 2023). Kernel yang digunakan dalam analisis ini ada 2 jenis, yaitu kernel linear dan RBF dengan fungsi persamaannya terdapat pada Tabel 2 (Putri & Razi, 2024).

Tabel 2. Jenis Kernel

Nama Kernel	Fungsi
Linear	$K(x_i, x_j) = x_i \cdot x_j$
RBF	$K(x_i, x_j) = \exp(-\gamma(x_i - x_j)^2)$

- c. Menentukan model SVR terbaik dengan melihat nilai MAPE terkecil.

2.3 Menghitung nilai MAPE data *training* dan *testing* metode SARIMA dan SVR.

Pemilihan model peramalan terbaik dapat dilihat dari nilai *Mean Absolute Percentage Error* (MAPE) yang lebih kecil. Nilai MAPE digunakan untuk melihat ketepatan estimasi model pada data *training* dan menjadi gambaran ketepatan peramalan pada data *testing*. Nilai MAPE dalam peramalan dapat menjadi gambaran seberapa besar kesalahan model terbaik yang terpilih dibandingkan dengan data aktualnya (Ramadita et al., 2024). Nilai MAPE dapat dihitung dengan Persamaan (2) (Avinash et al., 2024).

$$MAPE = \left(\frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \right) \times 100\% \tag{2}$$

Kriteria kebaikan model peramalan sesuai dengan rentang nilai MAPE terdapat pada Tabel 3.


Tabel 3. Kriteria MAPE

Rentang	Kategori
< 10%	Peramalan Sangat Baik
10% – 20%	Peramalan Baik
20% – 50%	Peramalan Cukup
> 50%	Peramalan Tidak Baik

3. HASIL DAN PEMBAHASAN


3.1 Pemodelan SARIMA

Plot data *training* uang M1 di Indonesia dari bulan Januari 2010 sampai dengan bulan Februari 2021 dapat dilihat pada Gambar 1.




Gambar 2. Plot Runtun Waktu Data *Training*

Gambar 2 menunjukkan bahwa plot data *training* berpola tren naik dari waktu ke waktu yang berarti data belum stasioner. Sebelum dilakukan analisis dengan metode SARIMA, data harus stasioner dalam variansi maupun rata-rata. Identifikasi kestasioneran data dalam variansi dapat diketahui dengan melihat *rounded value* plot Box-Cox yang terdapat pada Gambar 3.




Gambar 3. Plot Box-Cox Data *Training*

Gambar 3 menunjukkan bahwa *rounded value* dari data *training* sebesar 0,00 yang artinya data belum stasioner dalam variansi sehingga perlu dilakukan transformasi Box-Cox. Transformasi yang digunakan adalah akar pangkat 0,21 dari data *training* atau dapat ditulis $^{0,21}\sqrt{y_t}$. Selanjutnya, dilakukan pengecekan *rounded value* plot Box-Cox pada data *training* setelah transformasi yang dapat dilihat pada Gambar 4.




Gambar 4. Plot Box-Cox Data *Training* setelah Transformasi

Gambar 4 menunjukkan bahwa *rounded value* sudah bernilai 1,00 setelah dilakukan transformasi yang artinya data *training* sudah stasioner dalam variansi. Selanjutnya, dilakukan identifikasi kestasioneran data dalam rata-rata dengan melihat plot ACF data *training* setelah transformasi yang hasilnya dapat dilihat pada Gambar 5.




Gambar 5. Plot ACF Data *Training* Transformasi 1

Gambar 5 menunjukkan bahwa data belum stasioner dalam rata-rata karena plot ACF turun secara perlahan mendekati nol dan sebelas lag awal melebihi batas kritis, sehingga perlu dilakukan *differencing* lag pertama pada data *training*. Plot ACF data setelah *differencing* lag pertama dapat dilihat pada Gambar 6.



Gambar 6. Plot ACF Data *Training* Differencing Lag 1


Gambar 6 menunjukkan bahwa lag 6, 12, dan 24 keluar dari batas kritis. Hal tersebut dapat disimpulkan bahwa data berpola musiman 12 atau tahunan. Selanjutnya, dilakukan *differencing* 12 untuk menangani efek musiman pada data. Plot data runtun waktu setelah *differencing* musiman lag 12 dapat dilihat pada Gambar 7.



Gambar 7. Plot Data *Training* Differencing Musiman Lag 12


Gambar 7 menunjukkan bahwa setelah *differencing* musiman lag 12 data *training* stasioner terhadap rata-rata, karena fluktuasi data konstan membentuk pola horizontal dan tidak adanya tren. Selanjutnya dilakukan uji *Augmented Dickey-Fuller* (ADF) untuk lebih memastikan kestasioneran data dalam rata-rata. Data *training* dikatakan stasioner dalam rata-rata apabila $p\text{-value} < \alpha = 0,05$. Hasil perhitungan dengan *software* R Studio diperoleh nilai $p\text{-value} = 0,01 < \alpha = 0,05$ yang artinya data sudah stasioner dalam rata-rata.

Data *training* yang sudah stasioner dalam variansi maupun rata-rata selanjutnya dapat dilakukan pengestimasian model sementara. Langkah pertama yang dilakukan yaitu dengan melihat plot ACF dan PACF data *training* setelah *differencing* musiman lag 12 untuk menentukan orde model SARIMA yang dapat digunakan. Plot ACF data *training* setelah *differencing* musiman lag 12 dapat dilihat pada Gambar 8.



Gambar 8. Plot ACF Data *Training Differencing Musiman Lag 12*

Gambar 8 menunjukkan bahwa lag 1 dan 3 keluar dari batas kritis sehingga orde q yang mungkin adalah 0, 1, 2, dan 3. Untuk orde Q kemungkinannya hanya 0 karena tidak ada lag musiman yang keluar dari batas kritis. Selanjutnya untuk menentukan orde p dan P yang mungkin dapat dilihat dari plot PACF data *training* setelah *differencing* musiman lag 12 yang hasilnya ditunjukkan pada Gambar 9.



Gambar 9. Plot PACF Data *Training Differencing Musiman Lag 12*

Gambar 9 menunjukkan bahwa lag 1, 3, 11, dan 12 keluar dari batas kritis sehingga orde p yang mungkin adalah 0, 1, 2, dan 3 serta orde Q yang mungkin adalah 0 dan 1. Parameter dikatakan signifikan apabila memiliki *p-value* yang lebih kecil dari $\alpha = 0,05$. Selanjutnya, dilakukan estimasi model SARIMA berdasarkan nilai p, P, q, Q dan didapatkan 4 model SARIMA yang semua parameternya signifikan dapat dilihat pada Tabel 4.

Tabel 4. Estimasi Model SARIMA dengan Parameter Signifikan

Model	Parameter	Koefisien	<i>P-value</i>	Keterangan
(1,1,0)(0,1,0) ₁₂	ϕ_1	-0,2902	0,001	Signifikan
(0,1,1)(0,1,0) ₁₂	θ_1	0,3907	0,000	Signifikan
(1,1,0)(1,1,0) ₁₂	ϕ_1	-0,3028	0,001	Signifikan
	Φ_1	-0,3700	0,000	Signifikan
(0,1,1)(1,1,0) ₁₂	θ_1	0,3794	0,000	Signifikan
	Φ_1	-0,3597	0,000	Signifikan

Selanjutnya, keempat model sementara yang terpilih dilakukan uji asumsi residu. Terdapat dua uji asumsi residu yang perlu dilakukan pada keempat model yang terpilih, yaitu uji normalitas dan *white noise* yang terdapat pada Tabel 5.

Tabel 5. Uji Asumsi Residu Model

Model	<i>P-value</i>	Keterangan	<i>P-value</i>	Keterangan
(1,1,0)(0,1,0) ₁₂	0,048	Tidak Berdistribusi Normal	0,030	Tidak <i>White Noise</i>
(0,1,1)(0,1,0) ₁₂	0,045	Tidak Berdistribusi Normal	0,070	<i>White Noise</i>
(1,1,0)(1,1,0) ₁₂	0,132	Berdistribusi Normal	0,054	<i>White Noise</i>
(0,1,1)(1,1,0) ₁₂	> 0,150	Berdistribusi Normal	0,143	<i>White Noise</i>


Residu model dikatakan berdistribusi normal dan *white noise* apabila *p-value* lebih dari $\alpha = 0,05$. Tabel 5 menunjukkan bahwa model SARIMA yang memenuhi kedua uji asumsi residu, yaitu model SARIMA (1,1,0)(1,1,0)₁₂ dan (0,1,1)(1,1,0)₁₂. Selanjutnya, dilakukan perbandingan nilai MAPE dari kedua model SARIMA terpilih untuk

mendapatkan model terbaik yang akan digunakan dalam peramalan data uang M1 di Indonesia yang hasilnya dapat dilihat pada Tabel 6.

Tabel 6. Perbandingan Nilai MAPE Model SARIMA

Model SARIMA	MAPE	
	Training	Testing
$(1,1,0)(1,1,0)_{12}$	1,903%	2,250%
$(0,1,1)(1,1,0)_{12}$	1,849%	2,374%

Tabel 7 menunjukkan bahwa model SARIMA terbaiknya adalah $(1,1,0)(1,1,0)_{12}$ dengan nilai MAPE pada data *testing* sebesar 2,250% lebih kecil daripada SARIMA $(0,1,1)(1,1,0)_{12}$ sebesar 2,374%. Hasil peramalan data *testing* dengan model SARIMA terbaik $(1,1,0)(1,1,0)_{12}$ dapat dilihat pada Gambar 10.



Gambar 10. Plot Data Aktual dan Peramalan SARIMA $(1,1,0)(1,1,0)_{12}$

Gambar 10 menunjukkan bahwa hasil peramalan data *testing* dengan model SARIMA $(1,1,0)(1,1,0)_{12}$ yang ditunjukkan dengan garis merah hampir sama dengan data aktual yang ditunjukkan dengan garis biru sehingga keakuratan peramalan dengan SARIMA $(1,1,0)(1,1,0)_{12}$ tergolong sangat baik.

3.2 Pemodelan SVR

Langkah awal dalam analisis SVR adalah *pre-processing* data dengan melakukan *scaling* data bulanan uang M1 di Indonesia menggunakan normalisasi Min-Max. Nilai *timesteps* yang digunakan dengan *trial* dan *error* dimulai dari 2 sampai dengan 12. Tipe kernel yang digunakan yaitu linear, RBF, dan sigmoid. Selain itu, ditentukan *hyperparameter* dalam penelitian ini yaitu C, ϵ , dan γ dengan nilainya dapat dilihat pada Tabel 7.

Tabel 7. Nilai Parameter Metode SVR

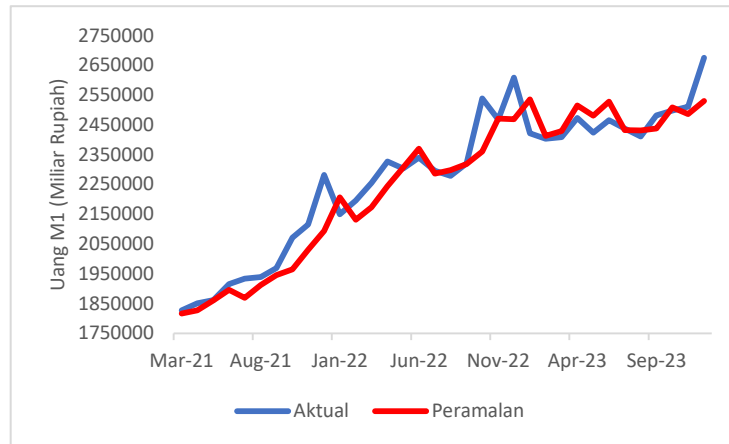
Parameter	Nilai Parameter
C	$10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 1, 10, 10^2, 10^3$
ϵ	$10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 1, 10, 10^2, 10^3$
γ	$10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 1, 10, 10^2, 10^3$

Setelah dilakukan pelatihan dan evaluasi masing-masing kombinasi parameter model SVR, diperoleh nilai MAPE pada masing-masing *timesteps* yang diujikan dapat dilihat pada Tabel 8.

Tabel 8. Nilai MAPE Data *Training* dan *Testing* Metode SVR

Timesteps	MAPE	
	Training	Testing
2	2,607%	2,341%
3	2,528%	2,493%
4	2,503%	2,386%
5	2,334%	2,594%
6	2,281%	2,407%
7	2,248%	2,264%
8	2,251%	2,254%
9	2,275%	2,293%
10	2,431%	2,917%
11	2,360%	3,153%
12	2,106%	3,361%

Tabel 8 menunjukkan bahwa peramalan data terbaik menggunakan metode SVR ($folds=5$) adalah $timesteps$ 8 dengan nilai MAPE pada data *training* 2,251% dan data *testing* 2,254%. Kombinasi *hyperparameter* optimalnya yaitu $C=100$; $\epsilon=0,001$; dan $\gamma=0,0001$ serta fungsi kernel linear. Hasil peramalan data *testing* dengan model SVR terbaik dapat dilihat pada Gambar 11.



Gambar 11. Plot Data Aktual dan Peramalan Metode SVR

Gambar 11 menunjukkan bahwa hasil peramalan data *testing* metode SVR dimana data hasil peramalan yang ditunjukkan dengan garis merah hampir sama dengan data aktual yang ditunjukkan dengan garis biru sehingga keakuratan peramalan dengan model SVR tergolong sangat baik.

3.3 Perbandingan Nilai MAPE Model SARIMA dan SVR

Setelah didapatkan model peramalan terbaik pada masing-masing metode, dilakukan perbandingan nilai MAPE untuk mengetahui metode terbaik dalam meramalkan data bulanan jumlah uang M1 di Indonesia pada beberapa periode mendatang. Perbandingan nilai MAPE kedua metode dapat dilihat pada Tabel 10.

Tabel 10. Perbandingan Nilai MAPE Metode SARIMA dan SVR

	MAPE SARIMA	MAPE SVR
Data <i>Training</i>	1,903%	2,251%
Data <i>Testing</i>	2,250%	2,254%

Tabel 10 menunjukkan bahwa nilai MAPE metode SARIMA pada data *training* sebesar 1,903% dan *testing* sebesar 2,250%. Nilai MAPE metode SVR pada data *training* sebesar 1,251% dan *testing* sebesar 2,254%. Oleh karena itu, metode SARIMA lebih baik daripada metode SVR dalam meramalkan uang M1 di Indonesia.

4. KESIMPULAN

Model SARIMA terbaik untuk peramalan data uang M1 di Indonesia yaitu SARIMA $(1,1,0)(1,1,0)_{12}$ dengan nilai MAPE pada data *training* 1,903% dan data *testing* 2,250%. Model SVR terbaik untuk peramalan data uang M1 di Indonesia diperoleh dengan bantuan *grid search* menggunakan *time series cross validation* sebanyak 5 *folds*, $timesteps$ 8, serta kombinasi *hyperparameter* optimalnya yaitu $C=100$; $\epsilon=0,001$; $\gamma=0,0001$; dan fungsi kernel linear dimana nilai MAPE pada data *training* 2,251% dan data *testing* 2,254%. Hasil perbandingan nilai MAPE kedua metode didapatkan bahwa metode SARIMA lebih baik daripada metode SVR untuk peramalan data uang M1 di Indonesia, karena memiliki nilai MAPE yang lebih kecil. Keterbatasan dari penelitian ini adalah pemilihan rentang yang sama nilainya pada setiap *hyperparameter* yang digunakan. Saran bagi peneliti selanjutnya adalah penentuan rentang *hyperparameter* yang digunakan dapat lebih bervariasi dan menyesuaikan dengan kebutuhan masing-masing *hyperparameter*, karena hal tersebut sangat berpengaruh terhadap performa hasil analisis dengan metode SVR.

REFERENCES

- Allorerung, P. P., Erna, A., Bagussahrir, M., & Alam, S. (2024). Analisis Performa Normalisasi Data untuk Klasifikasi K-Nearest Neighbor pada Dataset Penyakit. *JISKA (Jurnal Informatika Sunan Kalijaga)*, 9(3), 178–191. <https://doi.org/https://doi.org/10.14421/jiska.2024.9.3.178-191>
- Almahdy, R. F., & D, W. M. P. (2024). Prediksi Harga Rumah Di Kabupaten Bantul Menggunakan Algoritma Support Vector Regression. *Jurnal Teknik Informatika dan Sistem Informasi*, 11(2), 152–165. <https://doi.org/https://doi.org/10.35957/jatisi.v11i2.6001>
- Ambarwati, A. D., Sara, I. M., & Aziz, I. S. A. (2021). Pengaruh Jumlah Uang Beredar (JUB), BI Rate dan Inflasi Terhadap Pertumbuhan Ekonomi di Indonesia Periode 2009-2018. *Warmadewa Economic Development Journal*



- (WEDJ), 4(1), 21–27. <https://doi.org/https://doi.org/10.22225/wedj.4.1.3144.21-27>
- Avinash, A., Widjaja, A., & Karnalim, O. (2024). Analisis Perbandingan Algoritma Machine Learning Untuk Forecasting Persediaan Produk Barang Pokok. *JuTISI*, 10(2), 361–378. <https://doi.org/https://doi.org/10.28932/jutisi.v10i2.9357>
- Badan Pusat Statistik. (2024). *Uang Beredar (Milyar Rupiah)*. <https://www.bps.go.id/id/statistics-table/2/MTIzIzI=/uang-beredar.html>
- Deng, A. (2023). Time Series Cross Validation: Theoretical Properties and Empirical Performance. *Economics Letters*, 233, 111369. <https://doi.org/10.1016/j.econlet.2023.111369>
- Dimashanti, A. R., & Sugiman, S. (2021). Peramalan Indeks Harga Konsumen Kota Semarang Menggunakan SARIMA Berbantuan Software Minitab. *PRISMA, Prosiding Seminar Nasional Matematika*, 4, 565–576.
- Fadhil, N. (2025). Perbandingan akurasi algoritma xgboost dan svr dalam prediksi harga cryptocurrency. *Jurnal Ilmu Komputer dan Sistem Informasi*, 13(1), 1–6. <https://doi.org/https://doi.org/10.24912/jiksi.v13i1.32865>
- Fadilah, A. D., Adinda, N. T., Rahma, M. M., Lauda, R. S., & Suminar, L. (2024). Dampak kenaikan tarif PPN terhadap inflasi dan daya beli masyarakat Indonesia. *Media Akuntansi Perpajakan*, 9(2), 67–78. <https://doi.org/https://doi.org/10.52447/map.v9i2.7940>
- Habibi, M. S. A., Abdillah, A. H., Idhom, M., & Trimono, T. (2025). Perbandingan Kinerja Gru dan SVR untuk Prediksi Emas di Indonesia. *Informatika: Jurnal Teknik Informatika dan Multimedia*, 5(1), 141–150. <https://doi.org/https://doi.org/10.51903/informatika.v5i1.1105>
- Hayati, L. A., & Agustina, N. (2024). Aplikasi Model ARIMA dalam Peramalan Produk Domestik Regional Bruto (PDRB) Pertambangan dan Penggalan Kalimantan Selatan. *Seminar Nasional Official Statistics, 2024*(1), 2020–2024. <https://doi.org/https://doi.org/10.34123/semnasoffstat.v2024i1.2055>
- Isnaeni, R., Sudarmin, S., & Rais, Z. (2022). Analisis Support Vector Regression (Svr) Dengan Kernel Radial Basis Function (Rbf) Untuk Memprediksi Laju Inflasi Di Indonesia. *VARIANSI: Journal of Statistics and Its application on Teaching and Research*, 4(1), 30–38. <https://doi.org/https://doi.org/10.35580/variasiunm13>
- Ivanda, S. T., & SZS, J. A. (2025). Implementasi Metode Autoregressive Integrated Moving Average Untuk Analisis Peramalan Permintaan Kalibrasi Pada PT XYZ. *Jurnal Serambi Engineering*, 10(1), 12021–12028. <https://jse.serambimekkah.id/index.php/jse/article/view/661>
- Junaedi, L., Damastuti, N., Latipah, L., & Widodo, A. (2025). Penerapan Metode Seasonal ARIMA (SARIMA) untuk Peramalan Penjualan Barang dengan Pola Musiman Tahunan. *JISEM (Jurnal Informatika, Sistem Informasi, dan Elektro Modern)*, 1(01), 38–48. <https://doi.org/https://doi.org/10.33508/jisem.v1i01.7403>
- Kruba, R., Sofyan, H., Marshanda, D., Rahmadhania, & Syazana, N. (2025). Peramalan Saham Indofood Di Indonesia Menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA). *Jurnal Manajemen dan Keuangan*, 14(1), 102–117. <https://doi.org/https://doi.org/10.33059/jmk.v14i1.11501>
- Pratama, Y. D., & Salam, A. (2025). Comparison of Data Normalization Techniques on KNN Classification Performance for Pima Indians Diabetes Dataset. *Journal of Applied Informatics and Computing (JAIC)*, 9(3), 693–706. <https://doi.org/https://doi.org/10.30871/jaic.v9i3.9353>
- Putri, I., & Razi, A. (2024). Implementasi Metode SVM RBF (Radial Basis Function) Kernel Untuk Klasifikasi Status Gizi ada Balita. *Jurnal Teknologi Terapan dan Sains*, 5(2), 43–56. <https://doi.org/https://doi.org/10.29103/tts.v5i2.19156>
- Ramadita, M., Mahmudi, & Wijaya, M. Y. (2024). Prediksi Curah Hujandi Jakarta Menggunakan Model Hybrid (DWT-SVR-Prophet). *The Indonesian Journal of Computer Science*, 13(5), 8179–8194. <https://doi.org/https://doi.org/10.33022/ijcs.v13i5.4357>
- Rangkuti, S. P., Pratama, A., & Fhonna, R. P. (2025). Prediksi Produksi Beras Untuk Mendukung Ketahanan Pangan Di Kabupaten Aceh Utara Menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA). *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(4), 7136–7143. <https://doi.org/https://doi.org/10.36040/jati.v9i4.14456>
- Rizkiani, J. R., Zukhronah, E., & Respatiwan. (2024). Perbandingan peramalan nilai tukar rupiah terhadap dolar amerika serikat menggunakan singular spectrum analysis (ssa) dan support vector regression (svr). *Prosiding Seminar Nasional Sains dan Teknologi*, 1(2), 172–180. https://conference.ut.ac.id/index.php/saintek/article/view/2530#pkp_content_footer
- Ruliana, Rais, Z., Marni, & Saleh Ahmar, A. (2024). Implementation of the Support Vector Regression (SVR) Method in Inflation Prediction in Makassar City. *ARRUS Journal of Mathematics and Applied Science*, 4(1), 28–35. <https://doi.org/https://doi.org/10.35877/mathscience2608>