

Analisis Komparatif Ridge Regression dan Support Vector Regression pada Prediksi Inflasi Indonesia

Comparative Performance Analysis of Ridge Regression and Support Vector Regression in Indonesia's Inflation Forecasting

Afifah Faiqatuzzahra¹, Olivia Intan Puspita², Yasmine Alifita³, Diah Septiani^{*4}

^{1,2,3,4} Program Studi Sains Data, Telkom University

e-mail: ^{*1}faiqatuzzahra@student.telkomuniversity.ac.id

Abstrak - Inflasi merupakan indikator makroekonomi krusial yang mencerminkan stabilitas perekonomian, sehingga ketersediaan model prediksi yang akurat sangat penting sebagai pendukung pengambilan keputusan ekonomi. Penelitian ini bertujuan untuk membandingkan kinerja metode Ridge Regression dan Support Vector Regression (SVR) dalam memprediksi inflasi Month-to-Month (MtM) di Indonesia. Kedua metode diterapkan pada data deret waktu historis inflasi yang telah ditransformasikan menggunakan fitur lag untuk menangkap pola ketergantungan nilai masa lalu. Evaluasi dan perbandingan performa model dilakukan menggunakan metrik Mean Absolute Error (MAE), Mean Squared Error (MSE), dan Root Mean Squared Error (RMSE). Hasil penelitian menunjukkan bahwa SVR memberikan performa prediksi yang lebih baik dibandingkan Ridge Regression pada data pengujian, dengan penurunan tingkat kesalahan masing-masing sebesar 2,86% pada MAE, 6,98% pada MSE, dan 3,54% pada RMSE. Temuan ini menunjukkan bahwa SVR lebih efektif dalam mempelajari pola historis inflasi Indonesia sehingga menghasilkan tingkat akurasi prediksi yang lebih baik dibandingkan Ridge Regression pada dataset yang digunakan dalam penelitian ini.

Kata kunci – Inflasi, Time Series Forecasting, Ridge Regression, Support Vector Regression (SVR), Machine Learning

Abstract - Inflation is a crucial macroeconomic indicator that reflects the stability of an economy; therefore, the availability of accurate forecasting models is essential to support economic decision-making. This study aims to compare the performance of Ridge Regression and Support Vector Regression (SVR) in forecasting Month-to-Month (MtM) inflation in Indonesia. Both methods are applied to historical inflation time series data that has been transformed using lag features to capture temporal dependency patterns. Model evaluation and comparison are conducted using Mean Absolute Error (MAE), Mean Squared Error (MSE), and Root Mean Squared Error (RMSE) as performance metrics. The experimental results show that SVR outperforms Ridge Regression on the test data, achieving lower error rates with reductions of 2.86% in MAE, 6.98% in MSE, and 3.54% in RMSE. These findings indicate that SVR is more effective in learning the historical patterns of Indonesian inflation, resulting in higher predictive accuracy compared to Ridge Regression on the dataset used in this study. Overall, the results demonstrate that machine learning-based approaches, particularly SVR, can be effectively utilized for inflation forecasting in Indonesia.

Keywords – Inflation, Time Series Forecasting, Ridge Regression, Support Vector Regression (SVR), Machine Learning

I. PENDAHULUAN

Inflasi merupakan salah satu indikator makroekonomi yang mencerminkan stabilitas perekonomian suatu negara [1]. Perubahan tingkat inflasi tidak hanya memengaruhi harga barang dan jasa, tetapi juga berdampak pada daya beli masyarakat, aktivitas investasi, serta pertumbuhan ekonomi secara keseluruhan [2]. Sebagai salah satu sasaran utama kebijakan moneter, inflasi sering dikendalikan melalui penyesuaian suku bunga untuk menjaga stabilitas harga. Meskipun demikian, peningkatan suku bunga dapat mengurangi minat investasi dan konsumsi sehingga berpotensi memengaruhi kesejahteraan masyarakat [3]. Oleh karena itu, ketersediaan model prediksi inflasi yang akurat menjadi penting sebagai pendukung pengambilan keputusan ekonomi dan perumusan kebijakan yang berdampak langsung pada masyarakat.

Perkembangan machine learning telah mendorong pemanfaatan berbagai metode untuk meningkatkan akurasi prediksi inflasi. Support Vector Regression (SVR) merupakan salah satu metode yang banyak digunakan karena kemampuannya dalam memodelkan hubungan nonlinier pada data ekonomi [4]. Penerapan SVR pada prediksi inflasi Indonesia menunjukkan tingkat akurasi yang baik dengan menghasilkan nilai MAPE yang lebih rendah dibandingkan beberapa metode pembanding [5]. Pada model Ridge Regression, diperoleh performa terbaik dibandingkan model regresi terregularisasi lainnya, yaitu LASSO, Elastic Net, dan Ordinary Least Squares (OLS), yang ditunjukkan oleh nilai kesalahan prediksi paling rendah [6]. Kemampuan Ridge Regression dalam mengatasi multikolinearitas dan mengurangi risiko overfitting turut mendukung kinerjanya dalam peramalan data ekonomi. Temuan tersebut mengindikasikan bahwa baik SVR maupun Ridge Regression memiliki potensi yang kuat untuk digunakan dalam prediksi inflasi Indonesia.

Meskipun berbagai penelitian telah menerapkan SVR maupun Ridge Regression untuk prediksi inflasi, perbandingan langsung antara kedua metode tersebut pada data inflasi Indonesia masih terbatas. Kondisi ini menyebabkan belum adanya kesimpulan yang jelas mengenai model yang memiliki performa lebih baik dalam konteks prediksi inflasi Indonesia. Oleh karena itu, penelitian ini bertujuan membandingkan kinerja Ridge Regression dan Support Vector Regression menggunakan metrik MAE dan RMSE untuk mengidentifikasi model yang menghasilkan prediksi lebih akurat sebagai pendukung pengambilan keputusan ekonomi.

II. TINJAUAN TEORI

Penelitian ini didukung oleh tinjauan terhadap teori dan konsep yang berkaitan dengan objek penelitian serta metode prediksi yang digunakan.

2.1. Inflasi

Inflasi merupakan kondisi meningkatnya harga barang dan jasa secara umum dan terus menerus dalam suatu periode tertentu. Tingkat inflasi sering digunakan sebagai indikator stabilitas perekonomian karena berkaitan dengan daya beli masyarakat, aktivitas

investasi, konsumsi, dan kebijakan moneter. Pada penelitian [7], inflasi digunakan sebagai salah satu variabel prediktor dalam memprediksi pertumbuhan ekonomi Indonesia yang menunjukkan perannya dalam merepresentasikan kondisi makroekonomi. Selain itu, data inflasi termasuk data *time series* yang memiliki karakteristik ketergantungan terhadap nilai masa lalu (*persistence*), sehingga informasi historis inflasi dapat dimanfaatkan untuk meningkatkan akurasi prediksi melalui pembentukan fitur *lag* [8], [9]. Penelitian ini menggunakan inflasi *Month-to-Month* (MtM), yaitu persentase perubahan Indeks Harga Konsumen (IHK) pada bulan berjalan dibandingkan dengan bulan sebelumnya. Inflasi MtM dihitung menggunakan Persamaan (1),

$$Inflasi_{MtM} = \frac{IHK_t - IHK_{t-1}}{IHK_{t-1}} \times 100 \quad (1)$$

dengan IHK_t menyatakan Indeks Harga Konsumen pada bulan ke- t dan IHK_{t-1} menyatakan Indeks Harga Konsumen pada bulan sebelumnya. Nilai yang dihasilkan menunjukkan persentase perubahan harga dari satu bulan ke bulan berikutnya sehingga dapat menggambarkan dinamika inflasi jangka pendek secara lebih aktual.

2.2. Ridge Regression

Ridge Regression merupakan pengembangan dari regresi linear yang menerapkan regularisasi L2 untuk meningkatkan stabilitas model ketika variabel prediktor memiliki korelasi yang tinggi [10]. Pada penelitian ini, metode Ridge Regression digunakan untuk memprediksi inflasi Indonesia dengan memanfaatkan nilai inflasi periode sebelumnya sebagai variabel prediktor. Data inflasi bulanan ditransformasikan ke dalam bentuk supervised learning menggunakan fitur *lag*, sehingga setiap nilai inflasi diprediksi berdasarkan nilai inflasi pada beberapa periode sebelumnya. Sebagai contoh, jika data inflasi berturut-turut pada Januari hingga Juni 2007 adalah

Tabel 1. Data Inflasi

No	Tahun	Data Inflasi	
		Bulan	Nilai Inflasi
1	2007	Januari	1,04%
2	2007	Februari	0,62%
3	2007	Maret	0,24%
4	2007	April	-0,16%
5	2007	Mei	0,10%
6	2007	Juni	0,23%

maka untuk memprediksi inflasi bulan Juni 2007 ($y = 0,23$), model menggunakan nilai inflasi bulan Mei hingga Januari sebagai fitur *lag*, yaitu $X = [0,10, -0,16, 0,24, 0,62, 1,04]$. Pendekatan ini sejalan dengan penelitian [6] yang menggunakan lag inflasi sebagai prediktor untuk membangun model Ridge Regression dan menunjukkan bahwa Ridge menghasilkan RMSE dan MAE terkecil, yang merupakan kinerja terbaik di antara model regularized regression yang diuji.

Persamaan Ridge Regression dinyatakan sebagai:

$$\hat{\beta}_{Ridge}(\lambda) = \arg \min_{\beta} \{ \|y - X\beta\|_2^2 + \lambda \|\beta\|_2^2 \} \quad (2)$$

Pada persamaan (2), (y) merupakan nilai inflasi yang akan diprediksi, misalnya 0,23%, sedangkan (X) merupakan matriks prediktor yang berisi fitur lag inflasi, yaitu $[0,10; -0,16; 0,24; 0,62; 1,04]$. Adapun β merupakan koefisien regresi yang diestimasi oleh model dan λ merupakan parameter regularisasi yang mengontrol besarnya penalti terhadap koefisien model [11]. Semakin besar nilai λ , semakin besar pula proses penyusutan koefisien sehingga model menjadi lebih stabil terhadap multikolinearitas antar fitur lag.

2.3. Support Vector Regression

Pendekatan machine learning semakin banyak digunakan dalam permasalahan peramalan karena mampu mempelajari pola hubungan yang kompleks dari data historis [12]. Salah satu metode yang banyak diterapkan adalah Support Vector Regression (SVR), yaitu algoritma regresi yang dikembangkan dari Support Vector Machine untuk memprediksi nilai kontinu [13]. Melalui pemanfaatan fungsi kernel, SVR mampu menangkap pola linear maupun nonlinier pada data sehingga efektif digunakan pada data deret waktu yang memiliki karakteristik dinamis dan fluktuatif, seperti inflasi. Kemampuan tersebut memungkinkan model membentuk fungsi prediksi yang memiliki generalisasi yang baik terhadap data baru. Penelitian [5] menunjukkan bahwa model SVR dengan kernel linear mampu memberikan akurasi prediksi yang lebih baik dibandingkan metode Fourier Series Estimator pada prediksi inflasi Indonesia. Hasil penelitian tersebut menunjukkan nilai MAE dan RMSE yang lebih rendah dibandingkan metode pembandingan, sehingga SVR dinilai efektif dalam memodelkan pola inflasi Indonesia.

$$f(x) = \sum_{i=1}^n (\alpha_i^* - \alpha_i) K(x_i, x) + b \quad (3)$$

Pada persamaan (3), $f(x)$ merupakan fungsi prediksi yang digunakan untuk memperkirakan nilai target berdasarkan data masukan. Nilai α_i^* dan α_i merupakan koefisien yang diperoleh dari proses optimasi dan berperan dalam pembentukan model regresi. Fungsi $K(x_i, x)$ adalah fungsi kernel yang digunakan untuk memetakan data ke ruang fitur berdimensi lebih tinggi sehingga hubungan yang kompleks dapat direpresentasikan dengan lebih baik. Sementara itu, b merupakan bias atau konstanta yang berfungsi untuk menyesuaikan posisi fungsi regresi terhadap data [14]. Melalui kombinasi komponen tersebut, SVR mampu membangun fungsi prediksi yang memiliki kemampuan generalisasi yang baik pada data baru.

III. HASIL DAN PEMBAHASAN

Penelitian ini memanfaatkan data inflasi bulanan Indonesia yang ditransformasikan ke dalam bentuk supervised learning melalui pembentukan fitur lag. Dataset dibagi menjadi data latih (80%) dan data uji (20%) untuk mengukur kemampuan generalisasi model terhadap data yang

belum pernah diamati sebelumnya. Analisis diawali dengan eksplorasi karakteristik data, kemudian dilanjutkan dengan pembangunan model Ridge Regression dan Support Vector Regression (SVR). Kinerja kedua model dievaluasi menggunakan metrik Mean Absolute Error (MAE) dan Root Mean Squared Error (RMSE). Hasil evaluasi selanjutnya dianalisis untuk menjelaskan efektivitas masing-masing metode dalam memprediksi inflasi Indonesia, faktor-faktor yang memengaruhi perbedaan performa model, serta relevansinya terhadap penelitian terdahulu pada bidang peramalan inflasi. Data inflasi yang digunakan dalam penelitian ini bersumber dari publikasi resmi Badan Pusat Statistik [15] Indonesia melalui data inflasi bulanan Month-to-Month (MtM) Indonesia yang dapat diakses pada situs resmi.

3.1. Hasil Exploratory Data Analysis

3.1.1. Statistik Deskriptif

Analisis statistik deskriptif dilakukan untuk memperoleh gambaran umum mengenai karakteristik data inflasi yang digunakan dalam penelitian. Hasil statistik deskriptif ditunjukkan pada Tabel 2.

Tabel 2. Hasil Statistik Deskriptif

No	Hasil Statistik Deskriptif	
	Jenis	Nilai
1	Jumlah Data	233
2	Mean	0,3606%
3	Median	0,2600%
4	Std Dev	0,4902%
5	Min	-0,7600%
6	Max	3,2900%
7	IQR	0,5200%
8	Skewness	1,9126
9	Kurtosis	7,3505

Berdasarkan Tabel 1, data inflasi menunjukkan karakteristik fluktuatif dengan distribusi yang tidak normal, ditunjukkan oleh nilai skewness sebesar 1,9126 dan kurtosis sebesar 7,3505. Kondisi tersebut mengindikasikan bahwa data mengandung pola yang tidak sepenuhnya linear dan memiliki variasi yang cukup tinggi. Oleh karena itu, penelitian ini menggunakan Ridge Regression untuk mengatasi potensi ketidakstabilan model akibat hubungan antar fitur lag, serta Support Vector Regression (SVR) untuk menangkap pola hubungan yang lebih kompleks dalam data inflasi. Karakteristik data tersebut menjadi dasar untuk mengevaluasi kemampuan kedua metode dalam menghasilkan prediksi inflasi yang akurat.

3.1.2. Missing Value dan Duplikasi

Pemeriksaan kualitas data menunjukkan bahwa dataset yang digunakan tidak memiliki nilai hilang (*missing value*) maupun data duplikat. Ketidadaan *missing value* mengindikasikan bahwa seluruh observasi inflasi tersedia secara lengkap untuk setiap periode pengamatan, sehingga tidak diperlukan proses imputasi atau penghapusan

data. Selain itu, tidak ditemukannya data duplikat menunjukkan bahwa setiap observasi merepresentasikan periode waktu yang unik dan tidak terjadi pengulangan pencatatan data. Dengan demikian, dataset dinilai memiliki kualitas yang baik dan siap digunakan pada tahap pemodelan menggunakan Ridge Regression dan Support Vector Regression (SVR) tanpa memerlukan proses pembersihan data lebih lanjut.

3.1.3. Visualisasi Inflasi

Visualisasi data inflasi dilakukan untuk memahami pola pergerakan inflasi selama periode pengamatan sebelum proses pemodelan dilakukan. Hasil visualisasi menunjukkan bahwa inflasi Indonesia memiliki pola yang berfluktuasi dari waktu ke waktu dengan beberapa lonjakan pada periode tertentu. Meskipun demikian, sebagian besar nilai inflasi berada pada kisaran yang relatif rendah dan cenderung kembali ke tingkat normal setelah mengalami kenaikan. Pola fluktuatif tersebut mengindikasikan adanya dinamika yang dipengaruhi oleh nilai inflasi pada periode sebelumnya, sehingga informasi historis inflasi berpotensi dimanfaatkan sebagai variabel prediktor dalam pembentukan model prediksi. Periode pengamatan yang digunakan dalam penelitian ini mencakup data inflasi bulanan Indonesia tahun 2007 hingga Mei 2026 yang bersumber dari publikasi resmi statistik nasional Indonesia Badan Pusat Statistik.



Gambar 1. Pembagian Data Train dan Test

3.2. Hasil Pembentukan Fitur Lag

Data inflasi bulanan yang semula berbentuk deret waktu (*time series*) ditransformasikan ke dalam bentuk *supervised learning* melalui pembentukan fitur lag. Transformasi ini dilakukan agar nilai inflasi pada periode sebelumnya dapat digunakan sebagai variabel prediktor untuk memperkirakan nilai inflasi pada periode berikutnya. Pada penelitian ini digunakan tiga fitur lag, yaitu Lag-1, Lag-5, dan Lag-6, yang masing-masing merepresentasikan nilai inflasi satu, lima, dan enam bulan sebelumnya. Pemilihan ketiga fitur tersebut dilakukan berdasarkan proses seleksi fitur yang menunjukkan bahwa ketiga lag memiliki kontribusi yang paling relevan dalam memprediksi inflasi Indonesia.

Tabel 3. Pembentukan Lag

Pembentukan Lag			
Target	Lag-1	Lag-5	Lag-6
Inflasi Juli 2007	0,23	0,62	1,04

Berdasarkan Tabel 3, nilai inflasi bulan Juli 2007 digunakan sebagai variabel target, sedangkan nilai inflasi bulan Juni 2007, Februari 2007, dan Januari 2007 digunakan sebagai variabel prediktor yang masing-masing direpresentasikan oleh Lag-1, Lag-5, dan Lag-6. Pembentukan fitur lag memungkinkan model memanfaatkan informasi historis inflasi dari beberapa periode sebelumnya untuk memprediksi nilai inflasi pada periode berikutnya. Dataset hasil transformasi ini selanjutnya digunakan sebagai input pada model Ridge Regression dan Support Vector Regression (SVR) dalam proses pelatihan dan pengujian.

3.3. Hasil Pelatihan Model Ridge Regression

Pelatihan model Ridge Regression dilakukan menggunakan data yang telah distandardisasi untuk memastikan seluruh fitur berada pada skala yang sama sehingga proses regularisasi L2 dapat bekerja secara optimal. Pelatihan model Ridge Regression dilakukan menggunakan data yang telah distandardisasi untuk memastikan seluruh fitur berada pada skala yang sama sehingga proses regularisasi L2 dapat bekerja secara optimal. Tahapan Ridge Regression kemudian diimplementasikan berdasarkan Persamaan (2) menggunakan data latih yang telah diproses sebelumnya.

```
# Standardisasi fitur
scaler_ridge = StandardScaler()
X_train_sc_r = scaler_ridge.fit_transform(X_train)
X_test_sc_r = scaler_ridge.transform(X_test)
# Pelatihan model Ridge Regression
ridge_model = Ridge(alpha=best_alpha)
ridge_model.fit(X_train_sc_r, y_train)
# Prediksi
y_train_ridge = ridge_model.predict(X_train_sc_r)
y_test_ridge = ridge_model.predict(X_test_sc_r)
```

Penentuan parameter regularisasi (alpha) dilakukan melalui *grid search* dengan pendekatan Generalized Cross Validation (GCV) pada beberapa kandidat nilai alpha, dan diperoleh nilai optimal sebesar $\alpha = 10,0$ dengan nilai GCV minimum 0,1945. Model kemudian dilatih menggunakan tiga fitur lag, yaitu Lag-1, Lag-5, dan Lag-6, yang merepresentasikan ketergantungan jangka pendek dan menengah dari data inflasi bulanan Indonesia.

Tabel 4. Koefisien Model Ridge

Koefisien Model Ridge	
Parameter	Nilai
Intercept	0,3955
β Lag-1	0,1911
β Lag-5	0,0901
β Lag-6	0,0636

Kinerja model dievaluasi menggunakan data latih dan data uji untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah diamati sebelumnya. Pada data latih, model menghasilkan nilai MAE sebesar 0,3011, MSE sebesar 0,1885, dan RMSE sebesar 0,4342. Sementara itu, pada data uji diperoleh nilai MAE sebesar 0,3257, MSE sebesar 0,2149, dan RMSE sebesar 0,4636. Perbedaan nilai error antara data latih dan data uji yang relatif kecil menunjukkan bahwa model tidak mengalami overfitting yang signifikan dan mampu mempertahankan performa prediksi pada data baru. Namun demikian, besarnya nilai error yang masih cukup moderat mengindikasikan bahwa pola inflasi Indonesia memiliki komponen non-linear dan faktor eksternal yang tidak sepenuhnya dapat ditangkap oleh pendekatan linear seperti Ridge Regression.

3.4. Hasil Pelatihan Model SVR

Pelatihan model Support Vector Regression (SVR) dilakukan menggunakan data yang telah distandardisasi agar seluruh fitur memiliki skala yang seragam, sehingga model dapat bekerja secara optimal dalam membentuk hyperplane regresi. Tahapan implementasi SVR diadaptasi dari Persamaan (3) dengan menggunakan kernel linear untuk menangkap hubungan linier antara variabel lag dan inflasi.

```
# Standardisasi fitur
scaler_svr = StandardScaler()
X_train_sc = scaler_svr.fit_transform(X_train)
X_test_sc = scaler_svr.transform(X_test)
# Pelatihan model SVR
svr_model = SVR(
    kernel='linear',
    C=1.0,
    epsilon=0.1
)
svr_model.fit(X_train_sc, y_train)
# Prediksi
y_train_svr = svr_model.predict(X_train_sc)
y_test_svr = svr_model.predict(X_test_sc)
```

Model kemudian dievaluasi menggunakan data latih dan data uji, serta ditampilkan parameter model untuk memberikan interpretasi terhadap kontribusi masing-masing fitur lag terhadap prediksi inflasi.

Table 5. Koefisien Model SVR (Linear Kernel)

Koefisien Model SVR	
Parameter	Nilai
Intercept	0,3550
W Lag-1	0,1510
W Lag-5	0,0434
W Lag-6	0,1003

Kinerja model menunjukkan bahwa pada data latih diperoleh nilai MAE sebesar 0,2961, MSE sebesar 0,1942, dan RMSE sebesar 0,4407. Sementara itu, pada data uji diperoleh nilai MAE sebesar 0,3164, MSE sebesar 0,1999, dan RMSE sebesar 0,4472. Perbedaan nilai error antara data latih dan data uji relatif kecil, yang menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami overfitting yang signifikan. Namun demikian, nilai error yang masih cukup tinggi mengindikasikan bahwa meskipun hubungan linier dapat ditangkap oleh model SVR dengan kernel linear, terdapat kemungkinan adanya pola non-linear dan faktor eksternal yang tidak sepenuhnya terakomodasi dalam model.


3.5. Perbandingan Kinerja Model

Perbandingan kinerja model dilakukan berdasarkan data pengujian (test set) untuk mengevaluasi kemampuan generalisasi masing-masing model terhadap data yang belum pernah diamati sebelumnya. Evaluasi kinerja difokuskan pada tiga metrik utama, yaitu MAE, MSE, dan RMSE.

Table 6. Perbandingan Kinerja Model pada Data Uji

Kinerja Model pada Data Uji			
Model	MAE	MSE	RMSE
SVR (Linear Kernel)	0,3164	0,1999	0,4472
Ridge Regression ($\alpha = 10,0$)	0,3257	0,2149	0,4636

Hasil evaluasi menunjukkan bahwa model SVR (Linear Kernel) memiliki nilai error yang lebih rendah dibandingkan Ridge Regression pada seluruh metrik yang digunakan. Hal ini mengindikasikan bahwa SVR mampu menangkap pola hubungan antara variabel lag dan inflasi dengan sedikit lebih baik dibandingkan Ridge Regression pada data pengujian. Selain itu, analisis perbandingan antara kinerja pada data latih dan data uji menunjukkan bahwa selisih error pada kedua model relatif kecil. Kondisi ini mengindikasikan bahwa tidak terdapat indikasi overfitting yang signifikan, sehingga kedua model memiliki kemampuan generalisasi yang cukup baik dalam memprediksi data yang belum pernah diamati sebelumnya.



Gambar 2. Perbandingan Prediksi vs. Aktual Data Test

Gambar 2 menunjukkan hasil perbandingan antara nilai aktual inflasi dengan hasil prediksi dari model SVR (Linear Kernel) dan Ridge Regression pada data pengujian

periode 2022–2026. Pada visualisasi tersebut, garis abu-abu dengan penanda titik merepresentasikan data aktual inflasi, garis putus-putus merah merepresentasikan hasil prediksi model SVR, sedangkan garis putus-putus biru merepresentasikan hasil prediksi Ridge Regression. Model SVR terlihat lebih mampu mengikuti pola pergerakan data aktual dibandingkan Ridge Regression, terutama pada periode dengan fluktuasi tinggi. Hal ini sejalan dengan hasil evaluasi numerik, di mana SVR menghasilkan nilai MAE, MSE, dan RMSE yang lebih rendah dibandingkan Ridge Regression.

IV. KESIMPULAN

Metode Support Vector Regression (SVR) mampu memberikan performa prediksi inflasi Indonesia yang lebih baik dibandingkan Ridge Regression pada dataset yang digunakan. Berdasarkan hasil pengujian, SVR menghasilkan nilai MAE sebesar 0,3164, MSE sebesar 0,1999, dan RMSE sebesar 0,4472, sedangkan Ridge Regression memperoleh MAE sebesar 0,3257, MSE sebesar 0,2149, dan RMSE sebesar 0,4636. Perbandingan ini menunjukkan bahwa SVR mampu memberikan nilai error yang lebih rendah secara konsisten pada seluruh metrik evaluasi. Penurunan error yang dihasilkan SVR dibandingkan Ridge Regression yaitu sebesar 0,0093 pada MAE (2,86%), 0,0150 pada MSE (6,98%), dan 0,0164 pada RMSE (3,54%). Meskipun selisih tersebut relatif kecil, konsistensi penurunan pada seluruh metrik menunjukkan bahwa SVR memiliki kemampuan lebih baik dalam menangkap pola hubungan antara variabel lag (Lag-1, Lag-5, dan Lag-6) dengan inflasi aktual. Selain itu, karakteristik SVR yang lebih fleksibel dalam memaksimalkan margin kesalahan membuatnya lebih adaptif terhadap fluktuasi data inflasi bulanan dibandingkan Ridge Regression yang bersifat lebih linier.

V. DAFTAR PUSTAKA

- [1] T. O. Langoday, "Exploring the relationship between spatial factors and poverty in Indonesia based on macroeconomics: A look at Java Island," *E a M: Ekonomik a Management*, vol. 29, no. 2, pp. 32–44, 2026, doi: 10.15240/tul/001/2026-2-003.
- [2] Fitrawaty, M. Rinaldi, S. T. Wahyudi, M. F. Nasridha, and I. Maipita, "Exchange rate shocks and food security in Indonesia (1990–2024): evidence from a Vector Error Correction," *Cogent Economics and Finance*, vol. 14, no. 1, 2026, doi: 10.1080/23322039.2026.2644569.
- [3] T. Yangailo, "Evaluating the Impact of Foreign Exchange Restrictions on Economic Performance: A Comparative Analysis of Select Developing and Emerging Economies," *BRICS Journal of Economics*, vol. 7, no. 1, pp. 129–153, 2026, doi: 10.3897/brics-econ.7.e135199.
- [4] Z. F. Althobaiti, A. M. A. Aldawsari, P. Wiratchotisatian, A. I. Ishaq, and A. A. Suleiman, "A Novel Fréchet Distribution for Inflation Rate Modeling and Comparative Machine Learning Forecasting," *Journal of Mathematics*, vol. 2025, no. 1, 2025, doi: 10.1155/jom/5570060.
- [5] M. Fariz *et al.*, "Prediction of inflation rate in Indonesia using Fourier series estimator and support vector regression (SVR)." [Online]. Available: <https://www.bi.go.id/id/>
- [6] R. R. Saputra, A. Wintarti, and R. W. Romadhonia, "Rolling-Origin Evaluation of Lag-Based Regularized Regression Models for Indonesian Inflation Forecasting," *CAUCHY*:

- Jurnal Matematika Murni dan Aplikasi*, vol. 11, no. 1, pp. 1381–1397, May 2026, doi: 10.18860/cauchy.v11i1.41964.
- [7] F. Fauzi Abdulloh, A. Aminuddin, M. Rahardi, and F. Jari Harianto, "Evaluating Ensemble Learning Techniques for Economic Forecasting: A Comprehensive Analysis of Model Performance," 2025. [Online]. Available: www.joiv.org/index.php/joiv
- [8] Mustakim, Wahyu Eka Putra, and Hartono, "Implementation of Time Series Forecasting for Inflation Prediction in Indonesia," vol. 6, no. 2, pp. 865–874, 2026, doi: 10.57152/malcom.v6i2.2172.
- [9] R. Yotenka, M. Muhajir, Hermansah, and P. C. Rodrigues, "Comparative Analysis of Activation Functions in Recurrent Neural Network: An Application to Indonesian Inflation Forecasting," *Mathematical Modelling of Engineering Problems*, vol. 12, no. 3, pp. 754–762, 2025, doi: 10.18280/MMEP.120302.
- [10] L. Sun and Y. Zhao, "Forecasting Follies: Machine Learning from Human Errors," *Journal of Risk and Financial Management*, vol. 18, no. 2, Feb. 2025, doi: 10.3390/jrfm18020060.
- [11] H. H. Mohammad *et al.*, "New robust two-parameter estimator for overcoming outliers and multicollinearity in Poisson regression model," *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-025-12646-8.
- [12] P. Benavides-Herrera, G. Álvarez, R. Ruiz-Cruz, and J. D. Sánchez-Torres, "A Unified Family of Percentage-Error Support Vector Regression Models with Symmetric Kernel Extensions," *Mathematics*, vol. 14, no. 10, May 2026, doi: 10.3390/math14101679.
- [13] D. Kiss, "Event study methodology in politics - a systematic literature review," *Prague Economic Papers*, vol. 34, no. 4, pp. 592–623, Dec. 2025, doi: 10.18267/j.pep.899.
- [14] Z. F. Althobaiti, A. M. A. Aldawsari, P. Wiratchotisatian, A. I. Ishaq, and A. A. Suleiman, "A Novel Fréchet Distribution for Inflation Rate Modeling and Comparative Machine Learning Forecasting," *Journal of Mathematics*, vol. 2025, no. 1, 2025, doi: 10.1155/jom/5570060.
- [15] Badan Pusat Statistik, "Inflasi Bulanan (MtM)." Accessed: Jun. 12, 2026. [Online]. Available: <https://www.bps.go.id/id/query-builder>

