

Optimasi Peramalan Tingkat Laju Inflasi Indonesia Melalui Pendekatan *Ensemble Bagging* Pada *Algoritma Support Vector Regression*

Fiqry Wahyu Diky Wicaksono^{1*}, Mula'ab², Abdullah Basuki Rahmat³

^{1,2,3}*Teknik Informatika, Fakultas Teknik, Universitas Trunojoyo Madura*

*Email: fiqridiky01@gmail.com

Abstract

Inflation rate is often used as an indicator of a country's economic growth. In Indonesia, social challenges in the economic sector require better control. The inflation rate in Indonesia experiences unstable fluctuations every month. High inflation can cause various problems, including increased poverty, higher unemployment rates, economic growth obstacles, and a decline in the value of the rupiah. Therefore, forecasting the future inflation rate is crucial for formulating policies and maintaining economic stability. This study aims to analyze the impact of parameter variation on prediction error in inflation forecasting, as well as to evaluate the effectiveness of the Bagging method in improving prediction accuracy. Additionally, the research explores the optimal data splitting proportion to enhance model performance. Support Vector Regression (SVR) is the base model used, combined with the Ensemble Bagging approach to obtain accurate predictions. Grid search optimization with variations in Kernel (RBF, Sigmoid, Polynomial, Linear), C (0.1, 1, 100, 200), Gamma (0.1, 0.5, 1), Epsilon (0.01, 0.1, 1), Degree (1, 2, 3), and n_estimator (5, 25, 100) values is conducted to find the best parameters. Testing is also carried out with different data splitting ratios, namely 80:20, 70:30, and 60:40. The results show the best splitting ratio is 70:30, and the best parameters are Kernel = Linear, C = 200, Gamma = 0.1, Epsilon = 0.01, and n_estimators = 100. With a MAPE value of 9.297% and RMSE of 0.258, the results indicate the model is quite good for predicting Indonesia's inflation.

Keywords: Ensemble Bagging, Forecasting, Inflation, Support Vector Regression, Time Series.

Abstrak

Tingkat inflasi sering digunakan sebagai indikator pertumbuhan ekonomi suatu negara. Di Indonesia, tantangan sosial di sektor ekonomi membutuhkan pengendalian yang lebih baik. Tingkat inflasi di Indonesia mengalami fluktuasi yang tidak stabil setiap bulannya. Inflasi yang tinggi dapat menimbulkan berbagai masalah, antara lain meningkatnya angka kemiskinan, tingkat pengangguran yang semakin tinggi, terhambatnya pertumbuhan ekonomi, dan menurunnya nilai rupiah. Oleh karena itu, peramalan tingkat inflasi di masa depan sangat penting untuk merumuskan kebijakan dan menjaga stabilitas ekonomi. Penelitian ini bertujuan untuk menganalisis pengaruh variasi parameter terhadap tingkat kesalahan dalam peramalan inflasi, serta mengevaluasi efektivitas metode Bagging dalam meningkatkan akurasi prediksi. Selain itu, penelitian ini juga mengeksplorasi proporsi pembagian data yang optimal untuk meningkatkan performa model. *Support Vector Regression* (SVR) merupakan model dasar yang digunakan, dikombinasikan dengan pendekatan *Ensemble Bagging* untuk mendapatkan prediksi yang akurat. Optimasi *grid search* dengan variasi nilai *Kernel* (RBF, Sigmoid, Polynomial, Linier), C (0.1, 1, 100, 200), Gamma (0.1, 0.5, 1), Epsilon (0.01, 0.1, 1), Derajat (1, 2, 3), dan *n_estimator* (5, 25, 100) dilakukan untuk mencari parameter terbaik. Pengujian juga dilakukan dengan rasio pemisahan data yang berbeda, yaitu 80:20, 70:30, dan 60:40. Hasilnya menunjukkan rasio *splitting* terbaik adalah 70:30, dan parameter terbaik adalah *Kernel* = Linear, C = 200, Gamma = 0.1, Epsilon = 0.01, dan *n_estimator* = 100. Dengan nilai MAPE sebesar 9,297% dan RMSE sebesar 0,258, hasil tersebut mengindikasikan model cukup baik untuk memprediksi inflasi Indonesia.

Kata kunci: Ensemble Bagging, Peramalan, Inflasi, Support Vector Regression, Time Series.

1. Pendahuluan

Indonesia, sebagai negara berkembang dengan jumlah penduduk yang besar, menghadapi berbagai masalah sosial, terutama masalah ekonomi. Salah satu masalah ekonomi yang utama adalah inflasi, yang merupakan salah satu indikator penting dalam perekonomian[1]. Inflasi adalah suatu keadaan dimana terjadi kenaikan harga barang dan jasa secara umum dan terus menerus dalam jangka waktu yang cukup lama[2]. Tingkat inflasi yang merupakan persentase kenaikan harga barang dan jasa diupayakan stabil untuk menjaga kestabilan ekonomi[3],[4]. Inflasi yang tinggi mempengaruhi tingkat kemiskinan karena kenaikan harga barang dan jasa[5]. Inflasi berkontribusi sebesar 11,56% terhadap tingkat kemiskinan di Indonesia, yang menunjukkan adanya hubungan antara inflasi dan kemiskinan[6].

Selain itu, inflasi yang tinggi juga dapat menghambat pertumbuhan ekonomi[7]. Inflasi tinggi juga mempengaruhi tingkat pengangguran[8]. Selain itu, perubahan nilai tukar mata uang juga penting, kenaikan nilai dolar terhadap rupiah dapat menurunkan harga barang impor, meningkatkan daya beli konsumen, namun juga dapat mempengaruhi persaingan produk lokal. Perubahan nilai tukar mata uang memiliki implikasi penting bagi perekonomian, mempengaruhi daya beli masyarakat dan sektor riil[9]. Untuk mengatasi kompleksitas inflasi, sistem pemantauan yang akurat sangat penting untuk mencegah inflasi membahayakan perekonomian dan menjaga stabilitas ekonomi Indonesia. Salah satu pendekatannya adalah peramalan inflasi, yang memprediksi kejadian masa depan berdasarkan informasi masa lalu dan saat ini. Tujuannya adalah meminimalisir kesalahan antara kenyataan dan hasil peramalan[10].


Beberapa penelitian telah melakukan peramalan laju inflasi Indonesia. Penelitian menggunakan metode *Autoregressive Moving Average* (ARMA) mendapatkan *Root Mean Square Error* (RMSE) 0.196. Penelitian dengan metode *Seasonal Auto Regressive Integrated Moving Average* (SARIMA)

menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 4.67426. Selain itu, *Support Vector Machine* (SVM), yang dalam regresi disebut *Support Vector Regression* (SVR), juga digunakan untuk peramalan inflasi dengan kernel Radial Basis Function (RBF) dan menghasilkan RMSE 0.0020[11]. Kelebihan utama SVM adalah kemampuannya menangani kompleksitas dan ketidaklinieran data melalui penggunaan fungsi kernel. Ini memungkinkan SVM memetakan data ke dimensi yang lebih tinggi, sehingga dapat mengatasi pola *non-linier* dengan memberikan prediksi yang akurat dan andal. Selain itu, SVR tidak memerlukan data untuk bersifat stasioner seperti yang dibutuhkan oleh model ARIMA[12].

Untuk memberikan tingkat keakuratan prediksi, solusi yang dapat diambil adalah mengintegrasikan teknik *Ensemble*, di antaranya menggunakan metode Bagging[13]. Teknik *Ensemble* seperti *Bootstrap Aggregating* (*Bagging*), sering kali diterapkan dalam algoritma *random forest*. Penelitian ini bertujuan untuk menganalisis pengaruh penentuan parameter terhadap tingkat kesalahan (*error*) yang dihasilkan dalam peramalan tingkat inflasi di Indonesia menggunakan metode *Ensemble Bagging Support Vector Regression*, dengan penekanan pada hasil *grid search*. Selain itu, penelitian ini juga bertujuan untuk mengetahui proporsi pembagian data terbaik yang diimplementasikan dalam metode tersebut guna meningkatkan akurasi prediksi laju inflasi Indonesia.

2. Metode Penelitian

Tahapan penelitian dijelaskan pada Gambar 1 sebagai panduan untuk pelaksanaan penelitian.




Gambar 1. Flowchart Penelitian

Dalam penelitian ini, langkah pertama adalah pengumpulan data, diikuti dengan preprocessing untuk memastikan data siap dianalisis. Data kemudian dibagi menjadi dua set: data latih dan data uji. Model dibangun menggunakan data latih, sedangkan data uji digunakan untuk mengevaluasi kinerja model. Evaluasi menyeluruh pada tahap pengujian menentukan model terbaik.

2.1. Pengumpulan Data

Pada penelitian ini, dataset yang digunakan adalah data sekunder yang diperoleh dari situs resmi Bank Indonesia (BI)[14]. Dataset ini berupa data time series bulanan, yang diambil mulai dari rekapan bulan Januari 2003 hingga Mei 2024. Dengan demikian, total data yang diperoleh sebanyak 257 data. Data yang diperoleh dapat dilihat pada Gambar 2 sebagai berikut.



Gambar 2. Data Inflasi

2.2. Preprocessing Data

Preprocessing adalah teknik untuk mengubah data mentah menjadi data yang

lebih terstruktur dan siap diproses pada tahap selanjutnya, sehingga lebih mudah dipahami oleh mesin[15]. Berikut beberapa tahapan untuk preprocessing data.

2.2.1. Normalisasi Data

Normalisasi adalah proses penyesuaian nilai data agar berada dalam rentang yang sama[16]. Metode *Min-max Normalisasi* digunakan untuk mengatur nilai-nilai dalam dataset agar berada dalam rentang yang lebih kecil, biasanya antara 0 hingga 1. Persamaan 1 merupakan formula untuk menghitung *min-max scallar*[17].

$$x_i = \frac{x - \min(x)}{\max(x) - \min(x)} \tag{1}$$

Contoh hasil dari normalisasi data dapat dilihat pada Gambar 3 sebagai berikut.

	date	t
0	2003-01-01	0.431419
1	2003-02-01	0.368113
2	2003-03-01	0.342907
3	2003-04-01	0.369285
4	2003-05-01	0.341735
...
252	2024-01-01	0.073271
253	2024-02-01	0.083822
254	2024-03-01	0.101407
255	2024-04-01	0.098476
256	2024-05-01	0.089097

257 rows x 2 columns

Gambar 3. Hasil Normalisasi

2.2.2. Penentuan input dan output

Sebelum data diproses menggunakan model *Bagging-SVR*, dilakukan penentuan nilai *input* dan *output*. Penentuan ini dilakukan dengan menganalisis Partial Autocorrelation Function (PACF) untuk menentukan time-lag yang akan digunakan. Untuk formula PACF pada persamaan 2 berikut.

$$\phi_{kk} = \frac{r_k - \sum_{j=1}^{k-1} \phi_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} r_j} \tag{2}$$

Hasil penentuan *input* dan *output* dapat dilihat pada Gambar 4 sebagai berikut.

	date	t	t-1	t-2	t-4	t-8	t-13
13	2004-02-01	0.192263	0.205158	0.225088	0.302462	0.331770	0.431419
14	2004-03-01	0.222157	0.192263	0.205158	0.246776	0.290152	0.368113
15	2004-04-01	0.269637	0.222157	0.192263	0.225088	0.304220	0.342907
16	2004-05-01	0.301876	0.269637	0.222157	0.205158	0.293669	0.369285
17	2004-06-01	0.322978	0.301876	0.269637	0.192263	0.302462	0.341735
...
252	2024-01-01	0.073271	0.075615	0.090270	0.056272	0.157093	0.245604
253	2024-02-01	0.083822	0.073271	0.075615	0.072685	0.128957	0.232122
254	2024-03-01	0.101407	0.083822	0.073271	0.090270	0.103165	0.243259
255	2024-04-01	0.098476	0.101407	0.083822	0.075615	0.114302	0.213951
256	2024-05-01	0.089097	0.098476	0.101407	0.073271	0.056272	0.176436

244 rows x 7 columns

Gambar 4. Input Output

Pada gambar Gambar 4 terlihat terdapat beberapa kolom untuk kolom t akan digunakan sebagai *output* dan kolom t-1, t-2, t-4, t-8, dan t-13 digunakan sebagai *input* pada model.


2.3. Pembagian Data

Tahapan selanjutnya adalah membagi data menjadi data training dan data testing. Data training digunakan untuk membangun model, sementara data testing digunakan untuk menguji kinerja dan akurasi model tersebut. Pembagian data dilakukan dengan rasio 80:20, 70:30, dan 60:40. Untuk jumlah data yang digunakan dapat dilihat pada tabel 1.

Rasio Data	Train	Test
80:20	195	49
70:30	170	74
60:40	146	98

2.4. Perancangan Model *Bagging-SVR*

Bagging (Bootstrap Aggregating) adalah teknik dalam *Ensemble Learning* yang menggunakan satu jenis model dasar. SVR adalah varian dari SVM yang digunakan untuk regresi, menghasilkan *output* berupa nilai riil atau kontinu[11]. Pada penelitian ini, SVR akan digunakan sebagai model dasar (*base learning*) dalam pembuatan model. Terdapat parameter-parameter penting seperti *C*, *epsilon*, *gamma*, *degre*, *kernel* pada SVR dan *n_estimator* pada *Bagging* akan dioptimalkan untuk meningkatkan kinerja model. Untuk arsitektur dari *Bagging-SVR* dapat dilihat pada Gambar 5.



Gambar 5. Arsitektur *Bagging-SVR*

2.5. Pengujian Model

Pengujian model dilakukan dengan menggunakan data uji yang terpisah dari data pelatihan untuk mengevaluasi kinerja model *Bagging-SVR*. Model yang telah dilatih diujikan terhadap data uji dan hasil prediksi dibandingkan dengan nilai aktual.

2.6. Evaluasi

Dalam penelitian ini, evaluasi kinerja model dilakukan dengan menggunakan metrik MAPE. MAPE dihitung dengan membandingkan hasil prediksi model dengan nilai aktual dari data uji, dan mengukur persentase kesalahan absolut rata-rata dari prediksi tersebut[18]. Untuk formula dari MAPE dapat dilihat pada persamaan 3 berikut.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \times 100\% \tag{3}$$

2.7. Skenario Pengujian

Pada bagian ini akan dijelaskan skenario pengujian yang akan diterapkan. Skenario pengujian dapat dilihat pada Tabel 2.

Skenario	Keterangan
Splitting Data	80% train : 20% test,
	70% train : 30% test,
	60% train : 40% test
Kernel	RBF, Sigmoid, <i>Linear</i> , Poly
C	0.1, 1, 100, 200
Gamma	0.1, 0.5, 1
Epsilon	0.01, 0.1, 1
Degree	1,2,3
n_estimators	5,25,100

3. Hasil dan Pembahasan

Dalam penelitian ini, pengujian dilakukan menggunakan metode *grid search* untuk mengevaluasi berbagai kombinasi parameter yang digunakan. Proses ini bertujuan untuk menemukan konfigurasi parameter yang optimal guna meningkatkan akurasi model dalam memprediksi inflasi. Hasil peramalan dengan berbagai rasio pembagian data, yaitu 80:20, 70:30, dan 60:40 dapat dilihat pada Tabel 3 sebagai berikut.


Tabel 3. Parameter Hasil *Grid search*

Rasio split Data	Parameter Terbaik						Evaluasi MAPE(%)
	kernel	C	γ	ϵ	d	n	
80:20	Linear	100	0.1	0.01	-	5	10.33
70:30	Linear	200	0.1	0.01	-	100	9.29
60:40	Poly	100	0.5	0.01	1	100	9.64

Tabel 3 menunjukkan hasil *grid search* menyatakan bahwa model dengan rasio data 70:30 dan parameter terbaik yaitu *kernel linear* dengan C sebesar 200, γ sebesar 0.1, ϵ sebesar 0.01, dan $n_{estimators}$ sebesar 100 merupakan model yang terbaik sehingga menghasilkan MAPE sebesar 9.29%. Hal ini menunjukkan bahwa model ini memiliki tingkat kesalahan prediksi yang paling rendah dibandingkan dengan *rasio split* data lainnya. Selanjutnya, rasio 60:40 dengan parameter *kernel polinomial* ($C=100$, $\gamma=0.5$, $\epsilon=0.01$, $d=1$, $n=100$) menghasilkan MAPE sebesar 9.64%, Sedangkan rasio 80:20 dengan parameter *kernel linear* ($C=100$, $\gamma=0.1$, $\epsilon=0.01$, $n=5$) menghasilkan MAPE sebesar 10.33%. Hasil ini menunjukkan bahwa rasio split data 70:30 dengan parameter yang disebutkan memberikan kinerja prediksi terbaik, diikuti oleh rasio 60:40, dan terakhir rasio 80:20.


Gambar 6 menunjukkan perbandingan antara nilai aktual dan nilai prediksi menggunakan rasio split data 80:20. Grafik ini memvisualisasikan performa model dalam memprediksi nilai yang sebenarnya, dimana garis merah merepresentasikan nilai aktual dan garis hijau putus-putus merepresentasikan nilai prediksi. Dengan melihat kesesuaian antara kedua garis tersebut, kita dapat mengevaluasi

sejauh mana model dapat mengikuti pola dari data aktual, seperti yang dapat dilihat pada Gambar 6.



Gambar 6. Grafik 80:20


Perbandingan antara nilai aktual dan nilai prediksi menggunakan rasio split data 70:30 ditampilkan pada Gambar 7. Grafik ini, seperti pada Gambar 6, memvisualisasikan performa model dalam memprediksi nilai yang sebenarnya. Garis merah merepresentasikan nilai aktual, sementara garis hijau putus-putus merepresentasikan nilai prediksi. Kesesuaian antara kedua garis tersebut membantu kita mengevaluasi sejauh mana model dapat mengikuti pola dari data aktual, seperti yang dapat dilihat pada Gambar 7.



Gambar 7. Grafik 70:30

Perbandingan antara nilai aktual dan nilai prediksi menggunakan rasio split data 60:40 ditampilkan dalam Gambar 8. Grafik ini, seperti grafik sebelumnya, memvisualisasikan performa model dalam memprediksi nilai yang sebenarnya. Garis merah merepresentasikan nilai aktual, sementara garis hijau putus-putus merepresentasikan nilai prediksi. Kesesuaian antara kedua garis tersebut membantu kita

menevaluasi sejauh mana model dapat mengikuti pola dari data aktual, seperti yang dapat dilihat dalam Gambar 8.



Gambar 8. Grafik 60:40

4. Kesimpulan

Penelitian ini berhasil menunjukkan bahwa pengaturan parameter dalam model *Ensemble Bagging Support Vector Regression* memiliki pengaruh signifikan terhadap keakuratan peramalan tingkat inflasi di Indonesia. Parameter terbaik yang ditemukan dalam penelitian ini adalah $C = 200$, $\gamma = 0.1$, $\epsilon = 0.01$, penggunaan kernel linear, dan $n_estimator = 100$. Kombinasi parameter ini menghasilkan MAPE sebesar 9.297% yang menunjukkan tingkat akurasi prediksi yang tinggi.

Selain pengaturan parameter, proporsi pembagian data antara pelatihan dan pengujian juga berdampak pada tingkat kesalahan model. Proporsi 70% untuk pelatihan dan 30% untuk pengujian terbukti optimal dalam penelitian ini, memungkinkan model untuk belajar secara efektif dari data yang tersedia dan memberikan performa prediksi yang baik pada data yang belum pernah dilihat. Pengurangan data pelatihan secara bertahap tidak menunjukkan peningkatan akurasi, yang menegaskan pentingnya mempertahankan data pelatihan yang relevan untuk memastikan kualitas model yang optimal.

5. Saran

Untuk penelitian selanjutnya disarankan untuk melakukan analisis mendalam pada dataset, termasuk strategi penanganan outlier yang efektif seperti *Local Outlier Factor* (LOF) atau Z-Score, guna mengurangi potensi

kesalahan dalam prediksi dan memperbaiki kualitas data serta keakuratan model. Selain itu, menambah ukuran dataset dengan data terbaru akan memberikan variasi yang lebih baik, memungkinkan model untuk mempelajari tren dan pola yang lebih aktual sehingga dapat meningkatkan akurasi prediksi.

6. Daftar Pustaka

- [1] Samuel Banurea, "Ekonomi Indonesia dan Permasalahannya," *Jurnal Akuntansi Manajemen Madani*, vol. 7, no. 1, pp. 16–41, Mar. 2021, doi: 10.51882/jamm.v7i1.19.
- [2] A. Kristin and I. B. Darsana, "Pengaruh Inflasi Dan Pertumbuhan Ekonomi Terhadap Tingkat Kemiskinan di Indonesia," *Jurnal EP Unud*, vol. 9, no. 6, pp. 1373–1401.
- [3] A. Salim and A. Purnamasari, "Pengaruh Inflasi Terhadap Pertumbuhan Ekonomi Indonesia," *Ekonomica Sharia*, vol. 7, no. 1, pp. 17–28, Agustus 2021.
- [4] A. D. Ambarwati, I. M. Sara, and I. S. A. Aziz, "Pengaruh Jumlah Uang Beredar (JUB), BI Rate dan Inflasi Terhadap Pertumbuhan Ekonomi di Indonesia Periode 2009-2018," *WEDJ*, vol. 4, no. 1, pp. 21–27, Apr. 2021, doi: 10.22225/wedj.4.1.3144.21-27.
- [5] I. P. S. Sembiring, S. Simanjuntak, and V. A. Sitepu, "Pengaruh Inflasi dan Pengangguran terhadap Penduduk Miskin di Sumatera Utara Tahun 2006–2020," *JISMAB*, vol. 2, no. 2, pp. 1–13, May 2021, doi: 10.47747/jismab.v2i2.247.
- [6] R. Susanto and I. Pangesti, "PENGARUH INFLASI DAN PERTUMBUHAN EKONOMI TERHADAP TINGKAT KEMISKINAN DI INDONESIA," *jabe*, vol. 7, no. 2, pp. 271–278, Jan. 2021, doi: 10.30998/jabe.v7i2.7653.
- [7] M. H. M. Saefulloh and M. R. Fahlevi, "Pengaruh Inflasi Terhadap Pertumbuhan Ekonomi: Perspektif Indonesia," *Jurnal Keuangan Negara dan Kebijakan Publik*, vol. 3, no. 1, 2023.
- [8] R. F. Putri, "Analisis Pengaruh Inflasi, Pertumbuhan Ekonomi dan Upah Terhadap Pengangguran Terdidik," *Economics Development Analysis Journal*, vol. 4, no. 2, pp. 175–181, 2015.

- [9] M. Faizin, "Analisis Hubungan Kurs terhadap Inflasi," *AKUNTABEL*, vol. 17, no. 2, pp. 314–319, 2020.
- [10] M. Kafil, "Penerapan Metode K-Nearest Neighbors Untuk Prediksi Penjualan Berbasis Web Pada Boutiq Dealove Bondowoso," *jati*, vol. 3, no. 2, pp. 59–66, Sep. 2019, doi: 10.36040/jati.v3i2.860.
- [11] I. R. Sudarmin, and Z. Rais, "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*, vol. 4, no. 1, pp. 30–38, 2022.
- [12] D. I. Purnama and S. Setianingsih, "Support vector regression (SVR) model for forecasting number of passengers on domestic flights at Sultan Hasanudin airport Makassar," *JMSK*, vol. 16, no. 3, p. 391, Apr. 2020, doi: 10.20956/jmsk.v16i3.9176.
- [13] A. Ara, M. Maia, F. Louzada, and S. Macêdo, "Regression random machines: An ensemble support vector regression model with free kernel choice," *Expert Systems with Applications*, vol. 202, p. 117107, Sep. 2022, doi: 10.1016/j.eswa.2022.117107.
- [14] "Data Inflasi." Accessed: Sep. 04, 2024. [Online]. Available: <https://www.bi.go.id/id/statistik/indikator/da-ta-inflasi.aspx>.
- [15] L. A. Andika, P. A. N. Azizah, and R. Respatiwan, "Analisis Sentimen Masyarakat terhadap Hasil Quick Count Pemilihan Presiden Indonesia 2019 pada Media Sosial Twitter Menggunakan Metode Naive Bayes Classifier," *IJAS*, vol. 2, no. 1, p. 34, Jul. 2019, doi: 10.13057/ijas.v2i1.29998.
- [16] D. A. Nasution, H. H. Khotimah, and N. Chamidah, "Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN," *Com, Engine, Sys, Sci*, vol. 4, no. 1, p. 78, Jan. 2019, doi: 10.24114/cess.v4i1.11458.
- [17] D. A. Mardhika, B. D. Setiawan, and R. C. Wihandika, "Penerapan Algoritma Support Vector Regression Pada Peramalan Hasil Panen Padi Studi Kasus Kabupaten Malang".
- [18] I. Nabillah and I. Ranggadara, "Mean Absolute Percentage Error untuk Evaluasi Hasil Prediksi Komoditas Laut," *J Inform Syst*, vol. 5, no. 2, pp. 250–255, Nov. 2020, doi: 10.33633/joins.v5i2.3900.