

Rice Production Prediction Using Support Vector Regression Based on Climate Variables and Production Factors

Wijayati Putri ^{1*}, Angga Pratama ^{2**}, Ananda Faridhatul Ulva ^{3*}, Sayed Fachrurrazi ^{4*}

^{1,2,3*} Program Studi Sistem Informasi, Fakultas Teknik, Universitas Malikussaleh, Lhokseumawe

wijayati.220180114@mhs.unimal.ac.id ¹, anggapratama@unimal.ac.id ², anandafulva@unimal.ac.id ³, sayed.fachrurrazi@unimal.ac.id ⁴

Article Info

Article history:

Received 2026-08-08

Revised 2026-09-11

Accepted 2026-10-18

Keyword:

Support Vector Regression,
Rice Production Prediction,
Machine Learning,
Climate Variables.

ABSTRACT

Rice production is an important indicator for supporting national food security; therefore, an accurate prediction model is essential to support decision making. Although various studies have applied machine learning methods to predict rice production, most have primarily focused on evaluating model performance without providing production projections for future periods. This study aims to develop a rice production prediction model using Support Vector Regression (SVR) based on rainfall, humidity, and harvested area variables, as well as to generate rice production projections for the 2026-2028 period. The study employed time series data from 2021 to 2025 obtained from the Central Bureau of Statistics (BPS) and Meteorological, Climatological, and Geophysical Agency (BMKG). The research procedure included data preprocessing, normalization using MinMaxScaler applied after data partitioning to prevent data leakage, hyperparameter optimization using GridSearchCV, model training with linear, Radial Basis Function (RBF), and polynomial kernels, and performance evaluation using the Root Mean Square Error (RMSE) and the Coefficient of Determination (R^2). The results indicate that the linear kernel achieved the best performance with an RMSE of 9,721.39 and an R^2 of 0.986182, outperforming both the RBF and polynomial kernels. The best-performing model was subsequently used to project rice production for the 2026-2028 period, providing an overview of future production trends across districts and municipalities in Aceh Province. These findings demonstrate that the optimized SVR model is capable of producing accurate predictions and has potential to support data-driven agricultural planning, although practical use for policy decision-making requires further validation with relevant stakeholders.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Sektor pertanian memiliki fungsi strategis untuk mendukung ketahanan pangan dan perekonomian Indonesia karena sebagian besar penduduk menggantungkan mata pencahariannya pada sektor ini [1]. Sebagai negara agraris beras adalah makanan pokok utama masyarakat [2]. Namun, produksi padi dipengaruhi oleh berbagai faktor, seperti kondisi iklim dan faktor produksi, sehingga menyebabkan fluktuasi hasil panen dari waktu ke waktu. Kondisi tersebut mendorong perlunya pemanfaatan teknologi berbasis data untuk menghasilkan informasi prediktif yang akurat sebagai dasar dalam mendukung pengambilan keputusan di sektor

pertanian. Salah satu pendekatan yang banyak digunakan adalah *data mining*, yaitu proses mengekstraksi pola dan hubungan dari data dalam jumlah besar untuk menghasilkan informasi yang bermanfaat [3]. Pendekatan tersebut berkembang melalui penerapan *machine learning*, yang mampu mempelajari pola dari data historis untuk menghasilkan prediksi terhadap kondisi pada masa mendatang [4]. Dalam penelitian ini, prediksi dimanfaatkan untuk memperkirakan produksi padi berdasarkan pola data historis sehingga dapat mendukung perencanaan produksi secara lebih efektif [5].

Perkembangan teknologi *machine learning* telah mendorong pemanfaatan berbagai algoritma prediksi untuk

membantu proses pengambilan keputusan di berbagai bidang, seperti sektor pertanian. Berbagai penelitian terdahulu telah menerapkan metode Regresi Linear Berganda [6] dan *Artificial Neural Network* (ANN) [7] untuk memprediksi produksi padi dengan hasil yang cukup baik. Seiring berkembangnya penelitian di bidang prediksi, *Support Vector Regression* (SVR) menjadi salah satu metode yang banyak digunakan karena memiliki kemampuan memodelkan hubungan linear maupun nonlinear, menghasilkan overfitting, sehingga sesuai untuk memodelkan data dengan pola yang kompleks maupun deret waktu (*time series*) [3]. Oleh karena itu, SVR dinilai sebagai salah satu metode yang berpotensi menghasilkan model prediksi produksi padi dengan tingkat akurasi yang tinggi.

Beberapa penelitian menunjukkan bahwa metode SVR mampu memberikan performa prediksi yang baik pada data produksi padi. Penelitian sebelumnya melaporkan bahwa SVR mampu mengidentifikasi variabel-variabel yang berpengaruh terhadap hasil panen, terutama luas panen dan produktivitas, sehingga menghasilkan tingkat akurasi prediksi yang tinggi [8]. Selain itu, penerapan berbagai jenis kernel, seperti kernel *linear*, *polynomial*, dan *Radial Basis Function* (RBF), memungkinkan model menyesuaikan karakteristik hubungan antarvariabel sehingga mampu meningkatkan kemampuan prediksi pada data yang memiliki pola linear maupun non linear [9]. Temuan-temuan tersebut menunjukkan bahwa SVR merupakan metode yang memiliki potensi besar untuk diterapkan dalam pemodelan produksi padi.

Meskipun berbagai penelitian mengkonfirmasi kemampuan metode *Support Vector Regression* (SVR) mampu menghasilkan performa prediksi yang baik terhadap produksi padi [8][9], Sebagian besar penelitian masi berfokus pada pengembangan model dan evaluasi tingkat akurasi berdasarkan data historis. Pemanfaatan model terbaik untuk menghasilkan prediksi produksi pada beberapa periode mendatang masi relative terbatas, demikian pula penggunaan kombinasi variabel iklim dan faktor produksi dalam satu model prediksi untuk memperoleh informasi yang lebih komprehensif. Kondisi tersebut menunjukkan bahwa masi terdapat ruang pengembangan dalam penerapan SVR, tidak hanya untuk memperoleh model dengan performa yang baik, tetapi juga menghasilkan informasi prediktif yang dapat dimanfaatkan sebagai dasar perencanaan sektor pertanian.

Sebagai contoh, studi [8] membandingkan performa SVR dengan beberapa algoritma *machine learning* lain menggunakan variabel curah hujan, kelembapan, suhu, kecepatan angin, dan lama penyinaran matahari sebagai prediktor, sedangkan studi [2] menerapkan SVR untuk meramalkan hasil panen padi berdasarkan pola data deret waktu tanpa melibatkan variabel iklim maupun faktor produksi. Penelitian ini melengkapi kesenjangan tersebut dengan membangun model SVR yang mengintegrasikan variabel curah hujan, kelembapan, dan luas panen sebagai variabel prediktor [10][11], mengoptimalkan tiga jenis kernel (*linear*, RBF, *polynomial*) menggunakan *GridSearchCV*

untuk memperoleh konfigurasi terbaik, serta menghasilkan prediksi produksi padi periode 2026-2028 untuk 23 kabupaten/kota di Provinsi Aceh. Model diimplementasikan menggunakan bahasa pemrograman Python, yang didukung oleh pustaka *pandas* dan *Numpy* yang banyak digunakan dalam pengolahan data serta pengembangan model *machine learning* [12][13]. Dengan demikian, kontribusi penelitian ini terletak pada integrasi variabel iklim dan faktor produksi dalam satu model prediksi SVR, optimasi dan perbandingan kernel SVR secara sistematis, dan penyediaan prediksi produksi multi-tahun berbasis wilayah yang dapat mendukung perencanaan pertanian ditingkat kabupaten/kota [14][15].

Tujuan dari penelitian ini adalah untuk membuat model prediksi produksi padi dengan menggunakan teknik *Support Vector Regression* (SVR), menentukan konfigurasi model terbaik berdasarkan hasil optimasi parameter, serta menghasilkan prediksi produksi padi di Provinsi Aceh periode 2026-2028. Kinerja model selanjutnya dievaluasi menggunakan *Root Mean Square Error* (RMSE) dan Koefisien determinasi (R^2) untuk mengukur tingkat akurasi model prediksi [1][16].

II. METODE

A. Jenis dan Pendekatan Penelitian

Penelitian ini merupakan penelitian kuantitatif yang menggunakan data numerik berupa curah hujan, kelembapan, luas panen, dan produksi padi untuk dianalisis secara statistik dan komputasional. Pendekatan yang diterapkan adalah pendekatan prediktif berbasis *machine learning*, yaitu membangun model *Support Vector Regression* (SVR) untuk memprediksi produksi padi berdasarkan variabel iklim dan faktor produksi.

B. Sumber Data dan Variabel

Data yang digunakan merupakan data sekunder yang diperoleh dari Badan Pusat Statistik (BPS) Provinsi Aceh dan Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Dataset mencakup periode 2021-2025 untuk 18 kabupaten dan 5 kota di Provinsi Aceh, sehingga secara keseluruhan terdapat 23 kabupaten/kota (5 tahun) = 115 observasi. Setelah proses pembersihan data (empat observasi dengan nilai luas panen kosong dan tiga observasi dengan nilai produksi kosong pada kota sabang periode 2021-2024), jumlah observasi yang digunakan menjadi 111 data, yang selanjutnya dibagi menjadi 88 data latih dan 23 data uji.


Variabel curah hujan (mm/tahun) dan kelembapan (%) diperoleh dari BMKG dalam resolusi bulanan pada Tingkat Provinsi Aceh, kemudian di agregasi menjadi nilai tahunan melalui penjumlahan (curah hujan) dan rata (kelembapan). Karena data iklim tersedia pada tingkat provinsi, nilai tahunan yang sama diterapkan pada seluruh kabupaten/kota untuk tahun observasi yang bersangkutan. Sementara itu, variabel luas panen (ha) dan produksi padi (ton) diperoleh dari BPS Provinsi Aceh secara spesifik untuk setiap kabupaten/kota.

Kedua sumber data digabungkan berdasarkan kesamaan tahun observasi untuk membentuk kesatuan dataset.

Penggunaan variabel iklim dan produksi pada tahun yang sama didasarkan pada karakteristik budi daya padi di Provinsi Aceh yang umumnya melibatkan lebih dari satu musim tanam dalam satu tahun, sehingga akumulasi curah hujan dan rata-rata kelembapan tahunan dapat mempresentasikan kondisi iklim yang memengaruhi keseluruhan siklus produksi pada tahun tersebut. Meskipun demikian, penelitian ini tidak secara eksplisit menguji pengaruh *time lag* antara variabel iklim dan produksi padi, mengingat keterbatasan jumlah periode data yang tersedia (lima tahun observasi). Pengujian struktur *lag* yang lebih rinci memerlukan data deret waktu dengan resolusi temporal lebih tinggi dan cakupan periode yang lebih panjang.

Model SVR dibangun sebagai satu model gabungan yang mencakup seluruh kabupaten/kota, bukan model terpisah per wilayah. Pendekatan ini dipilih mengingat keterbatasan jumlah observasi tahunan pada masing-masing kabupaten/kota, yang tidak mencukupi untuk membangun model prediksi individual secara statistik. Penggabungan data antarwilayah memungkinkan model mempelajari pola hubungan antara luas panen dan produksi padi dari variasi spasial (antarkabupaten/kota), sedangkan variabel iklim berkontribusi terutama melalui variasi temporal yang seragam di seluruh wilayah.

C. Flowchart atau Alur Penelitian



Gambar 1. Flowchart Metode SVR

Flowchart penelitian menggambarkan tahapan pengembangan model prediksi produksi padi menggunakan

metode *Support Vector Regression* (SVR). Tahapan penelitian meliputi pengumpulan data, preprocessing berupa pembersihan dan normalisasi data menggunakan *MinMaxScaler*, pembagian data menjadi data latih dan data uji, pelatihan model menggunakan kernel *linear*, *polynomial*, dan RBF, optimasi parameter menggunakan *GridSearchCV*, proses prediksi, serta evaluasi model menggunakan RMSE dan R^2 .

D. Metode SVR

Support Vector Regression (SVR) merupakan salah satu algoritma *machine learning* yang digunakan untuk menyelesaikan permasalahan regresi dengan membangun fungsi regresi yang memiliki tingkat kesalahan seminimal mungkin terhadap data pelatihan sehingga mampu menghasilkan kemampuan generalisasi yang baik [17]. Kemampuan tersebut menjadikan SVR efektif dalam memodelkan hubungan linear maupun nonlinear melalui pemanfaatan fungsi kernel. Pada penelitian ini digunakan tiga jenis kernel yaitu, *linear*, *polynomial*, dan RBF, yang selanjutnya dioptimalkan menggunakan *GridSearchCV* untuk memperoleh kombinasi parameter terbaik. Model yang dihasilkan kemudian digunakan untuk memprediksi produksi padi berdasarkan variabel curah hujan, kelembapan, dan luas panen [8][12].

E. Pengujian

Pengujian dilakukan untuk mengevaluasi kinerja model SVR dalam memprediksi produksi padi. Pembagian data dilakukan berdasarkan urutan waktu dengan rasio 80:20, menggunakan parameter *shuffle=False*, sehingga data latih terdiri atas observasi tahun 2021-2024 (88 data) dan data uji terdiri atas observasi tahun 2025 (23 data), Dimana data latih digunakan untuk membangun model, sedangkan data uji digunakan untuk mengukur kemampuan model dalam memprediksi data yang belum pernah dipelajari sebelumnya. Pendekatan ini dipilih agar evaluasi model mencerminkan kemampuan prediksi terhadap periode yang belum pernah dilihat model (*out of sample*), sesuai dengan tujuan penelitian untuk menghasilkan prediksi produksi padi periode mendatang. Proses normalisasi menggunakan *MinMaxScaler* dilakukan setelah pembagian data, di mana parameter penskalaan hanya diestimasi dari data latih, kemudian diterapkan pada data uji dan data prediksi 2026-2028 tanpa dilakukan pemasangan ulang, untuk mencegah kebocoran informasi (*data leakage*). Evaluasi model dilakukan menggunakan *Root Mean Square Error* (RMSE) dan Koefisien Determinasi (R^2). Nilai RMSE digunakan untuk mengukur kemampuan model dalam menjelaskan variasi data aktual. Model terbaik dipilih berdasarkan nilai RMSE yang paling rendah dan R^2 yang paling tinggi, setelah proses optimasi parameter menggunakan *GridSearchCV* dengan *cv=5* yang dijalankan sepenuhnya didalam data latih, sehingga tidak melibatkan data tahun 2025 dalam proses pemilihan hyperparameter.

III. HASIL DAN PEMBAHASAN

A. Analisis Data

Data penelitian diperoleh dari publikasi resmi Badan Pusat Statistik (BPS) Provinsi Aceh dan Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) selama periode 2021-2025. Data mencakup 18 kabupaten dan 5 kota di Provinsi Aceh. Variabel yang digunakan terdiri atas curah hujan, kelembapan, luas panen, dan produksi padi. Curah hujan, kelembapan, dan luas panen digunakan sebagai variabel independen, sedangkan produksi padi digunakan sebagai variabel dependen yang menjadi target prediksi.

Data yang diperoleh selanjutnya disusun berdasarkan kabupaten/kota dan tahun pengamatan untuk memudahkan proses pengolahan dan pemodelan. Contoh data penelitian disajikan pada tabel 1.

TABEL 1
DATA VARIABEL INDEPENDEN DAN DEPENDEN

Kab/ Kota	Tahun	Curah Hujan	Kelemb apan	Luas Panen	Produksi
Simeulue	2021	3872.9	79.58	5586,80	16728,21
Simeulue	2022	3369.5	81.67	6674,96	22185.88
Simeulue	2023	2190.5	77.28	6518.52	25805.55
Simeulue	2024	1324.2	76.58	6809.33	23304.21
Simeulue	2025	2488.2	78.005	7485	24754

B. Impor Pustaka dan Input Data

Tahap awal implementasi model prediksi dilakukan dengan mengimpor pustaka yang diperlukan dan memasukkan dataset kedalam program Python. Pustaka yang digunakan mendukung berbagai tahapan penelitian, mulai dari pengolahan dan visualisasi data, normalisasi, pembagian data, pemodelan SVR, optimasi parameter, hingga evaluasi kinerja model. Pustaka *Pandas* dan *Numpy* digunakan untuk pengolahan data, sedangkan *Matplotlib* dan *Seaborn* digunakan untuk visualisasi. Selanjutnya, *Scikit-learn* digunakan melalui beberapa modul, yaitu *MinMaxScaler* untuk normalisasi data, *train_test_split* untuk pembagian data, *SVR* untuk membangun model prediksi, *GridSearchCV* untuk optimasi parameter, serta *mean_squared_error* dan *r²_score* untuk mengevaluasi kinerja model.

Dataset penelitian disimpan dalam format Microsoft Excel dengan nama *DATA_Penelitian SKRIPSI.xlsx*. Dataset kemudian dibaca menggunakan fungsi *read_excel()* dari pustaka *pandas* dan disimpan dalam variabel data untuk digunakan pada tahapan pengolahan selanjutnya. Proses tersebut dilakukan untuk memasukkan seluruh data yang ada terdapat dalam file Excel ke dalam lingkungan Python sehingga dapat diproses pada tahapan analisis dan pemodelan

	Kabupaten	Tahun	Curah Hujan	Kelembapan	Luas Panen	Produksi
0	Simeulue	2021	3872.9	79.580	5586,80	16728,21
1	Aceh Singkil	2021	3872.9	79.580	647,32	3350,51
23	Simeulue	2022	3369.5	81.670	6674,96	22185.88
24	Aceh Singkil	2022	3369.5	81.670	395,20	2140.31
46	Simeulue	2023	2190.5	77.280	6518.52	25805.55
47	Aceh Singkil	2023	2190.5	77.280	540.15	2775.11
69	Simeulue	2024	1324.2	76.580	6809.33	23304.21
70	Aceh Singkil	2024	1324.2	76.580	477.29	1809.06
92	Simeulue	2025	2488.2	78.005	7485	24754
93	Aceh Singkil	2025	2488.2	78.005	291	1112

(115, 6)

(115, 6)

Gambar 2. Input Dataset

C. Pre-processing Data

1) Pembersihan Data

Pembersihan data dilakukan dengan memeriksa keberadaan *missing value* dan data duplikat pada dataset. Data yang memiliki nilai kosong dan data duplikat kemudian ditangani dengan fungsi *dropna()* dan *drop_duplicates()* pada Python. Hasil pemeriksaan menunjukkan bahwa variabel luas panen memiliki empat data kosong, sedangkan variabel produksi memiliki tiga data kosong. Sementara itu, variabel curah hujan dan kelembapan tidak memiliki *missing value*. Hasil pemeriksaan juga menunjukkan bahwa tidak terdapat data duplikat.

```
MISSING VALUE
Kabupaten      0
Tahun          0
Curah Hujan    0
Kelembapan     0
Luas Panen     4
Produksi       3
dtype: int64

DATA DUPLIKAT
0
```

Gambar 3. Missing Value dan Data Duplikat

2) Penentuan Variabel X dan Y

Setelah proses pembersihan data, dilakukan penentuan variabel input dan target yang digunakan dalam pemodelan SVR. Variabel independen (X) merupakan variabel yang digunakan sebagai masukan untuk menghasilkan prediksi, sedangkan variabel dependen (Y) merupakan target yang diprediksi oleh model. Dalam penelitian ini, variabel X terdiri atas curah hujan, kelembapan, dan luas panen, sedangkan variabel Y adalah produksi padi.

VARIABEL X			
	Curah Hujan	Kelembapan	Luas Panen
0	3872.9	79.58	5586,80
1	3872.9	79.58	647,32
2	3872.9	79.58	8930,58
3	3872.9	79.58	10644,51
4	3872.9	79.58	27425,19

VARIABEL Y	
0	16728,21
1	3350,51
2	44839,80
3	65559,88
4	138347,01

Name: Produksi, dtype: object

Gambar 4. Variabel Input dan Output

3) Pembagian Data

Sebelum dilakukan normalisasi, dataset terlebih dahulu dibagi menjadi data latih dan data uji untuk mencegah kebocoran data (*data leakage*) dari data uji kedalam proses penskalaan data. Pembagian data dilakukan berdasarkan urutan waktu menggunakan parameter *shuffle=False* dengan rasio 80:20, menghasilkan data latih yang mencakup periode 2021-2024 dan 23 data uji mencakup periode 2025.

DATA LATIH 10 baris pertama dari total 88 baris

Kabupaten	Tahun	Curah Hujan	Kelembapan	Luas Panen	Produksi
Simeulue	2021	3872.9	79.58	5586.80	16728.21
Aceh Singkil	2021	3872.9	79.58	647.32	3350.51
Aceh Selatan	2021	3872.9	79.58	8930.58	44839.80
Aceh Tenggara	2021	3872.9	79.58	10644.51	65559.88
Aceh Timur	2021	3872.9	79.58	27425.19	138347.01
Aceh Tengah	2021	3872.9	79.58	3171.42	14956.46
Aceh Barat	2021	3872.9	79.58	12522.87	64355.17
Aceh Besar	2021	3872.9	79.58	35118.23	201408.49
Pidie	2021	3872.9	79.58	35947.06	203344.76
Bireuen	2021	3872.9	79.58	24525.54	150400.84

Gambar 5. Data Latih

DATA UJI - seluruh 23 baris

Kabupaten	Tahun	Curah Hujan	Kelembapan	Luas Panen	Produksi
Simeulue	2025	2488.2	78.005	7485.0	24754.0
Aceh Singkil	2025	2488.2	78.005	291.0	1112.0
Aceh Selatan	2025	2488.2	78.005	8582.0	47494.0
Aceh Tenggara	2025	2488.2	78.005	10322.0	65112.0
Aceh Timur	2025	2488.2	78.005	29390.0	150040.0
Aceh Tengah	2025	2488.2	78.005	2486.0	15135.0
Aceh Barat	2025	2488.2	78.005	15155.0	81123.0
Aceh Besar	2025	2488.2	78.005	29943.0	165764.0
Pidie	2025	2488.2	78.005	43252.0	268134.0
Bireuen	2025	2488.2	78.005	21188.0	122708.0
Aceh Utara	2025	2488.2	78.005	52937.0	309151.0
Aceh Barat Daya	2025	2488.2	78.005	11895.0	79429.0
Gayo Lues	2025	2488.2	78.005	4695.0	23102.0
Aceh Tamiang	2025	2488.2	78.005	14338.0	71678.0

Gambar 6. Data Uji

4) Normalisasi Data

Normalisasi data dilakukan untuk menyamakan skala antarvariabel sehingga perbedaan rentang nilai tidak memengaruhi proses pemodelan. Penelitian ini menggunakan

metode *MinMax Normalization*, yang mengubah nilai setiap variabel ke dalam rentang 0 sampai 1. Untuk mencegah kebocoran informasi dari data uji, proses *fit* (estimasi nilai minimum dan maksimum) pada *MinMaxScaler* hanya dilakukan menggunakan data latih. Parameter penskalaan yang diperoleh kemudian diterapkan (*transform*) pada data latih dan data uji, tanpa dilakukan pemasangan ulang data uji.

HASIL NORMALISASI DATA TRAINING (10 baris pertama)

	Curah Hujan	Kelembapan	Luas Panen
0	1.0	0.589391	0.089306
1	1.0	0.589391	0.010204
2	1.0	0.589391	0.142854
3	1.0	0.589391	0.170301
4	1.0	0.589391	0.439031
5	1.0	0.589391	0.050626
6	1.0	0.589391	0.200382
7	1.0	0.589391	0.562230
8	1.0	0.589391	0.575503
9	1.0	0.589391	0.392596

Gambar 7. Dataset Hasil Normalisasi

D. Implementasi Algoritma Support Vector Regression

1) Pemilihan Kernel dan Optimasi Hiperparameter

Pada tahap ini, *GridSearchCV* dari pustaka *Scikit-learn* digunakan untuk memperoleh kombinasi *hyperparameter* terbaik pada model SVR. Tiga kernel yang dibandingkan meliputi kernel *linear*, RBF, dan *polynomial*. Parameter yang dioptimalkan terdiri atas C dan epsilon, sedangkan gamma digunakan pada kernel RBF dan degree digunakan pada kernel *polynomial*. Proses optimasi dilakukan menggunakan *cross-validation* sebanyak 5 fold (*cv=5*) dengan R^2 sebagai metrik evaluasi.

2) Pelatihan Model SVR

Setelah konfigurasi *hyperparameter* dilakukan, proses pelatihan dilakukan menggunakan data latih melalui fungsi *grid_search.fit(x_train, y_train)*. Proses tersebut memungkinkan *GridSearchCV* mengevaluasi kombinasi parameter yang telah dilakukan dan memilih konfigurasi untuk masing-masing kernel.


TABEL II
PARAMETER TERBAIK SETIAP KERNEL

Kernel	C	Gamma	Degree	Epsilon
Linear	10	-	-	0.01
RBF	100	0.01	-	0.01
Polynomial	10	-	2	0.01

Setelah konfigurasi terbaik diperoleh, masing-masing model menggunakan fungsi *predict(x_test)*. Untuk memprediksi data uji, hasil prediksi digunakan pada tahap evaluasi kinerja model.

TABEL III
DATA AKTUAL DAN HASIL PREDIKSI

Kab/Kota	Tahun	Aktual	Prediksi	Error (%)
Simeulue	2025	24754.0	39.182,93	58,29
Aceh Singkil	2025	1112.0	-2053.96	284,71
Aceh Selatan	2025	47494.0	45.471,07	4,26
Aceh Tenggara	2025	65112.0	55444.96	14.85
Aceh Timur	2025	150040	164745.06	9.80
Aceh Tengah	2025	15.135	10.528,05	30,44
Aceh Barat	2025	81123.0	83148.30	2.50
Aceh Besar	2025	165.764	167.914,92	1,30
Pidie	2025	268.134	244.203,73	8,92
Bireuen	2025	122.708	117.730,19	4,06
Aceh Utara	2025	309.151	299.719,33	3,05
Aceh Barat Daya	2025	79.429	64.461,59	18,84
Gayo Lues	2025	23.102	23.190,31	0,38
Aceh Tamiang	2025	71.678	78.465,16	9,47
Nagan Raya	2025	28.397	32.298,65	13,74
Aceh Jaya	2025	45.672	39.670,16	13.14
Bener Meriah	2025	1.457	-2.111,28	244,91
Pidie Jaya	2025	96.205	73.025,38	24,09
Banda Aceh	2025	83	-3.630,29	4.473,84
Sabang	2025	13	-3.704,81	28.598,52
Langsa	2025	9.912	7.656,26	22,76
Lhokseumawe	2025	8.020	5.162,79	35,63
Sabulussalam	2025	704	-2.908,04	513,07



Gambar 8. Visualisasi Perbandingan Data Aktual dan Hasil Prediksi

Berdasarkan gambar 8 terlihat bahwa pola hasil prediksi *Support Vector Regression* secara umum mengikuti pola data aktual pada data *testing*. Hasil ini ditunjukkan oleh garis hasil prediksi yang memiliki kecenderungan naik dan turun secara garis data aktual pada sebagian besar titik pengamatan. Meskipun masi terdapat beberapa perbedaan nilai antara hasil prediksi dan data aktual pada beberapa titik, pola perubahan yang dihasilkan model tetap menunjukkan kecenderungan yang serupa dengan data sebenarnya.

Analisis lebih lanjut terhadap table 3 menunjukkan bahwa performa model bervariasi secara signifikan anatarwilayah. Pada kabupaten dengan skala produksi besar seperti Aceh Besar, Aceh Barat, Gayo Lues, dan Bireuen, model

menghasilkn kesalahan prediksi yang sangat kecil (di bawah 5%). Sebaliknya, pada wilayah dengan skala produksi kecil terutama wilayah kota seperti Sabang, Banda Aceh, Sabulussalam, dan Lhokseumawe, serta kabupaten Aceh Singkil dan Bener Meriah model menghasilkan kesalahan prediksi yang sangat besar, bahkan menghasilkan nilai prediksi negatif yang secara praktis tidak bermakna. Pola ini mengindikasikan bahwa model memiliki keterbatasan dalam memprediksi wilayah dengan skala produksi rendah, kemungkinan karena data pelatihan didominasi oleh kabupaten dengan skala produksi besar, sehingga model kurang mampu menggeneralisasi pola pada rentang nilai yang jauh lebih kecil. Temuan ini menegaskan bahwa metrik evaluasi agregat (RMSE, R^2) dapat menutupi variasi performa yang signifikan pada Tingkat wilayah individual, dan perlu menjadi perhatian dalam penerapan praktis hasil penelitian ini, khususnya pada wilayah dengan skala produksi kecil.

3) Evaluasi Model

Evaluasi model dilakukan untuk membandingkan kemampuan masing-masing kernel dalam memprediksi produksi padi. Hasil prediksi yang masi berada dalam skala normalisasi dikembalikan ke skala data awal menggunakan fungsi *inverse_transform()*. Selanjutnya, kinerja setiap model dievaluasi menggunakan RMSE dan R^2 .

RMSE digunakan untuk mengukur besarnya kesalahan prediksi, sedangkan R^2 digunakan untuk mengukur kemampuan model untuk menjelaskan variasi nilai produksi padi. Model dengan nilai RMSE yang lebih rendah dan R^2 yang lebih tinggi menunjukkan kinerja prediksi yang lebih baik.

TABEL IV
NILAI RMSE DAN R^2 MODEL SVR

Kernel	RMSE	R^2 Score
Linear	9721.39	0.986182
RBF	10246.39	0.984649
Polynomial	29064.22	0.876486

Hasil pada tabel 4 menunjukkan adanya perbedaan kinerja di antara ketiga kernel yang diuji. Kernel *linear* menghasilkan kinerja terbaik dengan nilai RMSE sebesar 9.721,39 dan R^2 sebesar 0,986182. Nilai tersebut menunjukkan bahwa kernel *linear* menghasilkan kesalahan prediksi paling rendah sekaligus kemampuan menjelaskan variasi produksi padi paling tinggi dibandingkan kernel lainnya.

Kernel RBF menghasilkan RMSE sebesar 10.246,39 dan R^2 sebesar 0.984649. Hasil tersebut menunjukkan kinerja yang mendekati kernel *linear*, tetapi masih berada di bawahnya berdasarkan kedua metrik evaluasi. Sementara itu, kernel *polynomial* menghasilkan RMSE sebesar 29.064,22 dan R^2 sebesar 0.876486, sehingga memiliki kinerja paling rendah di antara ketiga kernel. Perbandingan tersebut menunjukkan bahwa pemilihan kernel merupakan bagian penting dalam penerapan SVR karena setiap kernel memberikan hasil yang berbeda pada dataset penelitian.

Meskipun RBF dan *polynomial* memiliki kemampuan dalam memodelkan hubungan nonlinear, hasil pengujian menunjukkan bahwa kernel *linear* memberikan kinerja yang lebih baik pada data penelitian. Dengan demikian, pemilihan model tidak hanya didasarkan pada penggunaan algoritma SVR, tetapi juga pada hasil perbandingan dan optimasi konfigurasi kernel berdasarkan karakteristik data.

Tingginya performa kernel *linear* mengindikasikan bahwa hubungan antara variabel curah hujan, kelembapan, luas panen, dan produksi padi pada dataset ini cenderung bersifat linear. Hal ini didukung oleh koefisien model SVR *linear*, yang menunjukkan bahwa variabel luas panen memiliki koefisien sebesar 0,993, jauh lebih besar dibandingkan curah hujan (0,0006) dan kelembapan (0,0006). Hasil ini mengindikasikan bahwa luas panen merupakan prediktor dominan yang memiliki hubungan hampir proposional terhadap produksi padi, sedangkan kontribusi curah hujan dan kelembapan relatif kecil pada model ini. Kernel RBF dan *polynomial*, yang dirancang untuk menangkap pola nonlinear, tidak memberikan peningkatan performa karena kompleksitas tambahan yang ditawarkan tidak diperlukan pada struktur hubungan data yang relatif linear ini, sekaligus berisiko *overfitting* pada jumlah data yang terbatas.

Nilai RMSE sebesar 9.721,39 ton perlu dimaknai relatif terhadap skala produksi padi pada dataset ini, yang secara rata-rata mencapai 70.226,04 ton per kabupaten/kota per tahun. Dengan demikian, RMSE tersebut setara dengan sekitar 13,84% dari rata-rata produksi, yang mengindikasikan tingkat kesalahan yang moderat. Nilai *Mean Absolute Error* (MAE) sebesar 7.207,10 ton menunjukkan rata-rata deviasi absolut antara produksi aktual dan hasil prediksi. Perhitungan *Mean Absolute Percentage Error* (MAPE) menghasilkan nilai yang sangat tinggi (1.495%) akibat adanya satu observasi dengan nilai produksi aktual yang sangat kecil (Kabupaten Aceh Singkil, 1.112 ton), sehingga kesalahan absolut yang relatif kecil menghasilkan persentase kesalahan yang sangat besar. Kondisi ini menunjukkan keterbatasan metrik MAPE pada kasus dengan variasi skala produksi yang besar antarwilayah, dan mengindikasikan bahwa model masih memiliki keterbatasan dalam memprediksi secara akurat pada wilayah dengan skala produksi kecil.

E. Hasil Prediksi Support Vector Regression

Perlu ditegaskan bahwa terdapat perbedaan mendasar antara prediksi dan proyeksi dalam konteks penelitian ini. Hasil pengujian model pada tahun 2025 merupakan prediksi dalam pengertian sebenarnya, karena menggunakan nilai variabel input yang bersifat actual untuk periode tersebut. Sebaliknya, estimasi produksi padi untuk periode 2026-2028 lebih tepat disebut sebagai proyeksi, karena nilai variabel input pada periode tersebut belum tersedia secara aktual dan diperoleh melalui asumsi serta ekstrapolasi, sebagaimana dijelaskan berikut ini.

Model SVR terpilih digunakan untuk memproyeksi produksi padi pada periode 2026-2028. Proses proyeksi menggunakan data historis hingga tahun 2025 sebagai dasar.

Variabel luas panen diproyeksikan menggunakan rata-rata persentase perubahan tahunan berdasarkan data historis 2021-2025 pada masing-masing kabupaten/kota, dengan pembatasan perubahan maksimum $\pm 15\%$ per tahun untuk menghindari proyeksi yang tidak realistis. Sementara itu, variabel curah hujan dan kelembapan pada periode proyeksi diasumsikan konstan setara dengan nilai tahun 2025, mengingat keterbatasan data iklim historis yang tidak memungkinkan pembangunan model peramalan iklim yang andal secara terpisah. Asumsi ini merupakan penyederhanaan yang perlu dipertimbangkan dalam menginterpretasikan hasil proyeksi, karena kondisi iklim aktual pada 2026-2028 dapat berbeda dari tahun 2025.

Nilai variabel input hasil proyeksi kemudian di transformasikan menggunakan parameter *MinMaxScaler* yang telah diperoleh dari data latih, agar konsisten dengan skala yang digunakan sebagai masukan pada model SVR untuk menghasilkan proyeksi produksi. Kemudian fungsi *inverse_transform()* digunakan untuk mengembalikan hasil proyeksi ke skala data asli.

TABEL V
HASIL PROYEKSI PRODUKSI PADI 2026-2028


Kabupaten	Tahun	Prediksi Produksi
Simeulue	2026	42563.59
Aceh Selatan	2026	46089.55
Aceh Timur	2026	171084.04
...	...	...
Aceh Tenggara	2027	54977.16
Aceh Tengah	2027	8952.19
Bireuen	2027	111568.98
...	...	...
Aceh Singkil	2028	0.00
Bener Meriah	2028	0.00
Sabang	2028	0.00

Hasil proyeksi menunjukkan adanya variasi nilai produksi antar kabupaten/kota selama periode 2026-2028. Beberapa wilayah menunjukkan kecenderungan peningkatan, antara lain Simeulue, Aceh Selatan, Aceh Timur, Aceh Barat, Pidie, Gayo Lues, Aceh Tamiang, dan Langsa. Sebaliknya, Aceh Tenggara, Aceh Tengah, Aceh Besar, Bireuen, Aceh Utara, Aceh Barat Daya, Nagan Raya, Aceh Jaya, Pidie Jaya, dan Lhokseumawe menunjukkan kecenderungan penurunan. Perbedaan tersebut menggambarkan variasi hasil proyeksi berdasarkan pola historis dan variabel prediktor yang digunakan dalam pemodelan.


Beberapa wilayah, yaitu Aceh Singkil, Bener Meriah, Banda Aceh, Sabang, dan Sabulussalam, menghasilkan nilai proyeksi 0 pada periode 2026-2028. Nilai tersebut merupakan hasil *post processing* terhadap keluaran prediksi negatif dengan menetapkan nilai yang lebih kecil dari nol menjadi 0. Penyesuaian dilakukan karena produksi padi secara substantif tidak dapat bernilai negatif.

Untuk memperjelas pola perubahan hasil proyeksi, dilakukan visualisasi menggunakan grafik garis (*line plot*).

Sumbu horizontal menunjukkan tahun prediksi, sedangkan sumbu vertical menunjukkan jumlah produksi padi.



Gambar 9. Grafik Tren Proyeksi Simeulue 2021-2028



Gambar 10. Grafik Tren Proyeksi Aceh Timur 2021-2028




Gambar 11. Grafik Tren Proyeksi Aceh Tenggara 2021-2028



Gambar 12. Grafik Tren Proyeksi Aceh Tengah 2021-2028



Gambar 13. Grafik Tren Proyeksi Aceh Singkil 2021-2028



Gambar 14. Grafik Tren Proyeksi Sabang 2021-2028

Perbedaan pola tersebut menunjukkan bahwa model menghasilkan prediksi bervariasi antar kabupaten/kota berdasarkan karakteristik data historis dan variabel input yang digunakan. Hasil proyeksi periode 2026-2028 menjadi keluaran penting penelitian karena memberikan estimasi produksi pada periode mendatang yang dapat digunakan sebagai informasi pendukung dalam perencanaan produksi pertanian berbasis data.

F. Analisis Tambahan Model

Untuk mengevaluasi manfaat prediktif model SVR dibandingkan pendekatan yang lebih sederhana, dilakukan perbandingan dengan tiga model *baseline*, *naïve forecast*, *Linear Regression*, dan *Random Forest*, menggunakan pembagian data latih-uji yang identik dengan model SVR. Hasil perbandingan disajikan pada table 6.

TABEL VI
PERBANDINGAN MODEL SVR DENGAN BASELINE

Model	RMSE	R ²
Naïve Forecast	13.940,92	0,971898
Linear Regression	9.427,82	0,987004
Random Forest	10.945,59	0,982482
SVR	9.721,39	0,986182

Model SVR menghasilkan performa yang jauh lebih baik dibandingkan *naïve forecast* dan *Random Forest*, menunjukkan bahwa integrasi variabel iklim dan luas panen dalam model memberikan manfaat prediktif dibandingkan pendekatan sederhana. Namun demikian, performa SVR relatif setara dengan *linear Regression*, dengan selisih RMSE yang tidak signifikan secara praktis. Temuan ini konsisten

dengan hasil pada bagian sebelumnya yang menunjukkan bahwa hubungan antara variabel input dan produksi padi pada dataset ini cenderung bersifat linear, sehingga kernel SVR nonlinear (RBF, *Polynomial*) maupun model kernel *trick* SVR secara umum tidak memberikan keunggulan signifikan dibandingkan model regresi linear konvensional pada kasus ini.

Analisis autokorelasi terhadap data produksi padi menunjukkan korelasi yang tinggi antara produksi tahun berjalan dengan produksi tahun sebelumnya pada kabupaten/kota yang sama ($r=0,970$), mengindikasikan adanya pola persistensi temporal yang kuat dalam data produksi padi. Namun demikian, analisis tren linear terhadap total produksi padi di Provinsi Aceh periode 2021-2025 tidak menunjukkan tren yang signifikan secara statistik, sehingga fluktuasi produksi antartahun lebih mencerminkan variasi tahunan dibandingkan tren jangka panjang yang konsisten.

Model SVR pada penelitian ini tidak secara eksplisit memasukkan variabel lag produksi sebagai prediktor. Namun demikian, variabel luas panen yang terbukti menjadi prediktor dominan dalam model secara tidak langsung mempresentasikan sebagian pola persistensi tersebut, mengingat luas panen antartahun pada kabupaten/kota yang sama cenderung tidak berubah secara drastis. Meskipun demikian, penambahan variabel lag produksi secara eksplisit berpotensi meningkatkan akurasi model. Hal ini belum dapat diuji secara memadai pada penelitian ini mengingat keterbatasan jumlah periode data, karena penambahan fitur lag akan mengurangi jumlah data latih yang sudah terbatas. Penelitian selanjutnya dengan cakupan periode data yang lebih panjang disarankan mempertimbangkan variabel lag produksi secara eksplisit.

Untuk mengevaluasi kemungkinan multikolinearitas antar variabel prediktor, dilakukan analisis korelasi dan *variance inflation* (VIF). Hasil analisis menunjukkan korelasi yang cukup tinggi antara curah hujan dan kelembapan ($r = 0,833$), dengan nilai VIF masing-masing sebesar 3,27, mengindikasikan multikolinearitas pada Tingkat moderat. Hal ini dapat dijelaskan oleh sifat kedua variabel yang berasal dari data iklim Tingkat provinsi yang sama, sehingga keduanya bervariasi mengikuti pola tahunan yang serupa. Sebaliknya, variabel luas panen tidak menunjukkan korelasi yang berarti dengan kedua variabel iklim tersebut ($r < 0,01$) dan memiliki nilai VIF sebesar 1,00, sehingga tidak berkontribusi terhadap masalah multikolinearitas.

Analisis lebih lanjut menunjukkan korelasi yang sangat tinggi antara luas panen dan produksi padi ($r = 0,994$). Temuan ini, dikombinasikan dengan koefisien model SVR *linear* yang menunjukkan dominasi luas panen, mengindikasikan bahwa performa tinggi model ($R^2 = 0,986$) sebagian besar didorong oleh hubungan yang kuat antara luas panen dan produksi, sementara kontribusi curah hujan dan kelembapan terhadap prediksi relatif kecil pada dataset ini. Hasil analisis *feature importance* ini penting untuk diinterpretasikan secara hati-hati, karena tingginya akurasi model tidak serta merta mencerminkan kemampuan model

dalam menangkap pengaruh iklim terhadap produksi padi, melainkan lebih banyak dipengaruhi oleh prediktor luas panen.

Meskipun nilai R^2 yang tinggi sebagian besar dipengaruhi oleh kuatnya hubungan antara luas panen dan produksi padi, perlu dicatat bahwa evaluasi ini dilakukan pada data uji tahun 2025 yang tidak dilibatkan sama sekali dalam proses pelatihan model, sehingga R^2 tersebut tetap mencerminkan kemampuan generalisasi model pada periode *out of sample* yang sesungguhnya, bukan sekadar kecocokan pada data latih. Meskipun demikian, kemampuan model dalam menghasilkan prediksi yang akurat pada periode mendatang tetap bergantung pada proyeksi variabel luas panen itu sendiri, mengingat perannya yang dominan dalam model. Ketidakpastian pada proyeksi luas panen dengan demikian berpotensi memberikan pengaruh yang lebih besar terhadap akurasi hasil proyeksi produksi dibandingkan ketidakpastian pada variabel iklim.

G. Keterbatasan

Penelitian ini memiliki beberapa keterbatasan. Data curah hujan dan kelembapan berada pada resolusi tingkat provinsi dan digunakan dalam satu model gabungan untuk seluruh wilayah, sehingga variasi iklim mikro antarwilayah belum tertangkap. Penelitian ini juga belum mempertimbangkan *time lag* iklim produksi maupun variabel *lag* produksi secara eksplisit, meskipun ditemukan autokorelasi tinggi ($r = 0,970$) pada data produksi, akibat keterbatasan jumlah periode data. Proyeksi 2026-2028 mengasumsikan curah hujan dan kelembapan konstan setara tahun 2025 sehingga lebih tepat dimaknai sebagai skenario, bukan prediksi pasti. Selain itu, model menunjukkan performa yang tidak konsisten antarwilayah, dengan kesalahan lebih besar pada wilayah berskala produksi kecil. Penelitian selanjutnya disarankan menggunakan data iklim beresolusi kabupaten/kota, mempertimbangkan variabel lag, serta memperpanjang cakupan periode data.

IV. KESIMPULAN

Dalam penelitian ini, metode *Support Vector Regression* (SVR) berhasil memprediksi produksi padi berdasarkan variabel curah hujan, kelembapan, dan luas panen. Hasil pengujian terhadap kernel *linear*, RBF, dan *polynomial*, menunjukkan bahwa kernel linear merupakan model terbaik dengan nilai RMSE sebesar 9.721,39 dan R^2 sebesar 0,986182. Model tersebut selanjutnya digunakan untuk menghasilkan proyeksi produksi padi periode 2026-2028 pada kabupaten/ kota di Provinsi Aceh, dengan asumsi kondisi iklim yang relatif konstan.

Hasil proyeksi menunjukkan adanya variasi kecenderungan produksi antar kabupaten/kota, berupa peningkatan, penurunan, maupun kondisi yang relatif stabil. Temuan ini menunjukkan bahwa SVR dapat dimanfaatkan tidak hanya untuk mengevaluasi pola produksi berdasarkan data historis, tetapi juga untuk menghasilkan informasi prediktif pada periode mendatang. Kontribusi penelitian

terletak pada integrasi variabel iklim dan faktor produksi dalam pemodelan SVR, optimasi dan perbandingan beberapa kernel untuk memperoleh model terbaik, serta pemanfaatan model terpilih untuk menghasilkan proyeksi produksi padi tiga tahun mendatang. Informasi tersebut berpotensi menjadi salah satu bahan pertimbangan awal dalam perencanaan produksi padi berbasis data. Namun demikian, pemanfaatannya secara langsung dalam pengambilan keputusan kebijakan pertanian atau ketahanan pangan memerlukan validasi lebih lanjut bersama pemangku kepentingan terkait, serta mempertimbangkan keterbatasan penelitian, khususnya pada resolusi data iklim dan konsistensi performa model antarwilayah.

DAFTAR PUSTAKA

- [1] I. K. Sukhna, B. Miftahurrohman, C. Wulandari, and P. Amelia, "Imputasi Data Temperatur Maksimum Menggunakan Metode Support Vector Regression," *JISKA (Jurnal Inform. Sunan Kalijaga)*, vol. 10, no. 2, pp. 171–185, 2025, doi: 10.14421/jiska.2025.10.2.171-185.
- [2] D. Rosa, D. R. Anamisa, B. K. Khotimah, and M. Y. Hariyawan, "Forecasting of Rice Harvest Results Using SVR Modeling Techniques Forecasting of Rice Harvest Results Using SVR Modeling Techniques," *JAMBURA J. Math.*, vol. 7, no. 1, pp. 84–91, 2025, doi: 10.37905/jjom.v7i1.30592.
- [3] A. Widiarni, "Penerapan Algoritma Support Vector Regression dalam Memprediksi Produksi dan Produktivitas Kelapa Sawit," *J. MEDIA Inform. BUDIDARMA*, vol. 7, no. April, pp. 864–872, 2023, doi: 10.30865/mib.v7i2.6089.
- [4] N. Nuris, "Analisis Prediksi Harga Rumah Pada Machine Learning Menggunakan Metode Regresi Linear," *Explor. J. Inform. Komput.*, vol. 14, no. 2, pp. 108–112, 2024, doi: 10.35200/ex.v14i2.123.
- [5] C. A. Rahayu, R. Hartono, and A. Sudiarjo, "Prediksi Penderita Diabetes Menggunakan Metode Naive Bayes," *JITET (Jurnal Inform. daan Tek. Elektro Ter.)*, vol. 11, no. 3, 2023, doi: 10.23960/jitet.v11i3.3055.
- [6] A. S. Budi, P. H. Susilo, and C. Author, "SVM ALGORITHM FOR PREDICTING RICE YIELDS," *J. Teknol. Inf. dan Pendidik.*, vol. 13, no. 341, 2020, doi: 10.24036/tp.v13i2.
- [7] H. Putra and N. Ulfa, "Penerapan Prediksi Produksi Padi Menggunakan Artificial Neural Network Algoritma Backpropagation," *J. Nas. Teknol. dan Sist. Inf.*, vol. 02, pp. 100–107, 2020, doi: 10.25077/TEKNOSI.v6i2.2020.100-107.
- [8] R. Yunis and I. A. Pardosi, "Enhancing Rice Production Prediction : A Comparative Machine Learning Analysis Of Climate Variables Jurnal Nasional Pendidikan Teknik Informatika : JANAPATI | 92," *J. Nas. Pendidik. Tek. Inform. JANAPATI*, vol. 13, no. 1, pp. 91–104, 2024, doi: 10.23887/janapati.v13i1.71527.
- [9] E. Suryani, I. Septiawati, E. Budianita, F. Insani, and L. Oktavia, "Prediksi Jumlah Perceraian Menggunakan Metode Support Vector Regression (SVR)," *J. Comput. Syst. Informatics*, vol. 5, no. 1, pp. 208–217, 2023, doi: 10.47065/josyc.v5i1.4613.
- [10] V. No, A. Syahreza, N. K. Ningrum, and M. A. Syahrasy, "Perbandingan Kinerja Model Prediksi Cuaca : Random Forest , Support Vector Regression , dan XGBoost," *Edumatic J. Pendidik. Inform.*, vol. 8, no. 2, pp. 526–534, 2024, doi: 10.29408/edumatic.v8i2.27640.
- [11] A. C. Adi Nugroho, Aditya Pramada Wicaksono, "Analysis and Prediction of Relative Humidity Level using Generalized Linear Model," *JITE (J. Informatics Telecommun. Eng.)*, vol. 7, no. July, pp. 221–232, 2023, doi: 10.31289/jite.v7i1.9896.
- [12] I. F. Riziq, A. R. Dzikkillah, and T. Informatika, "Implemmentasi Algoritma LSTM Dan SVR Untuk Prediksi Harga Bitcoin Menggunakan Data Yahoo Finance," *METIK J.*, vol. 9, pp. 284–291, 2025, doi: 10.47002/metik.v9i2.1077.
- [13] D. Abdulrachman, V. Yasin, and A. B. Yulianto, "Dashboard sebaran kartu kmiln/diaspora dengan menggunakan python library pandas, numpy, matplotlib dan gradio 1)," *RABIT J. Teknol. dan Sist. Inf. Univrab*, vol. 11, no. 1, pp. 837–846, 2026, doi: 10.36341/rabit.v11i1.7140.
- [14] E. Lianita, A. Pratama, and A. F. Ulva, "Penerapan Metode K-Means Clustering Untuk Pemetaan Produktivitas Sayur-Sayuran Berbasis Sistem Informasi Geografis Application Of The K-Means Clustering Method For Mapping Vegetable Productivity Based On Geographic Information Systems In North Sumatra Pro," *Justin J. Sist. dan Teknol. Inf.*, vol. 12, no. 2, 2024, doi: 10.26418/justin.v12i2.72934.
- [15] A. Herdiyanti, A. Pratama, and I. Sahputra, "Prediksi Hasil Produksi Minyak Kelapa Sawit dengan Metode Fuzzy Time Series (Studi Kasus : PT . Langkat Nusantara Kepong PKS Kebun Tanjung Keliling)," *Justin J. Sist. dan Teknol. Inf.*, vol. 12, no. 1, pp. 169–174, 2024, doi: 10.26418/justin.v12i1.72373.
- [16] B. F. Yusuf, "Implementasi Algoritma Support Vector Regression Dalam Memprediksi Harga Sayuran Komoditas (Studi Kasus : Desa Hegarmanah)," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 5, pp. 10608–10614, 2024, doi: 10.36040/jati.v8i5.11034.
- [17] A. A. Suyono and R. Arief, "Prediksi Indeks Harga Konsumen Komoditas Makanan di Kota Surabaya menggunakan Support Vector Regression," *METIK J.*, vol. 6, no. 1, 2022, doi: 10.47002/metik.v6i1.339.