



Prediction Model for the Impact of Climate Change on Food Security Using the Support Vector Machine and K-Nearest Neighbors Algorithms

Model Prediksi Dampak Perubahan Iklim pada Ketahanan Pangan Menggunakan Algoritma Support Vector Machine and K-Nearest Neighbors

**Devi Puspita Sari^{1*}, Risman², Fitra Maulana³,
Lusiana Efrizoni⁴, Rahmaddeni⁵**

^{1,2,3,4,5}Program Studi Teknik Informatika, Universitas Sains dan Teknologi Indonesia, Indonesia

Email: ¹2210031802018@sar.ac.id, ²2210031802103@sar.ac.id, ³2210031802112@sar.ac.id
⁴lusiana@stmik-amik-riau.ac.id, ⁵rahmaddeni@usti.ac.id

Received Feb 12th 2025; Revised May 20th 2025; Accepted Jun 06th 2025; Available Online Jun 23th 2025, Published Jun 23th 2025
Corresponding Author: Devi Puspita Sari
Copyright © 2025 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Climate change has a significant impact on global food security, especially in regions that are highly dependent on the agricultural sector. Phenomena such as extreme rainfall, rising temperatures, and changing wind patterns have significantly affected agricultural productivity. The urgency of this research lies in the need for predictive data-driven models to anticipate the effects of climate change on food systems, enabling policymakers to develop timely adaptation strategies. This study aims to develop a predictive model for the impact of climate change on food security using Support Vector Machine (SVM) and K-Nearest Neighbors (K-NN) algorithms. The dataset includes daily meteorological data such as precipitation, maximum temperature, minimum temperature, and wind speed, obtained from Kaggle (Seattle weather). The SVM model is applied to capture the non-linear relationship between climate parameters and food security indicators, while K-NN is used to analyze similar patterns in historical data. The results show that SVM achieves a prediction accuracy of 78%, outperforming K-NN, which achieves 74%. These findings confirm that SVM is more effective in modeling the complex relationship between climate variability and food security. Thus, the research successfully meets its objectives and contributes to the development of machine learning-based prediction systems to support adaptive food policy planning in the face of climate change.

Keywords: Agriculture, Climate Change, Food Security, K-Nearest Neighbors, Support Vector Machine

Abstrak

Perubahan iklim memberikan dampak signifikan terhadap ketahanan pangan global, terutama di wilayah yang sangat bergantung pada sektor agrikultur. Fenomena seperti curah hujan ekstrem, kenaikan suhu, dan perubahan pola angin telah memengaruhi produktivitas pertanian secara signifikan. Urgensi penelitian ini terletak pada pentingnya pengembangan model prediktif berbasis data untuk mengantisipasi dampak perubahan iklim terhadap ketahanan pangan, sehingga strategi adaptasi dapat dirancang secara tepat oleh pembuat kebijakan. Penelitian ini bertujuan mengembangkan model prediksi dampak perubahan iklim terhadap ketahanan pangan dengan memanfaatkan algoritma Support Vector Machine (SVM) dan K-Nearest Neighbors (K-NN). Dataset yang digunakan meliputi data meteorologi harian, seperti curah hujan (*precipitation*), suhu maksimum (*temp_max*), suhu minimum (*temp_min*), dan kecepatan angin (*wind*), yang diperoleh dari Kaggle (*Seattle weather*). Model SVM diterapkan untuk menangkap hubungan non-linear antara parameter iklim dengan indikator ketahanan pangan, sedangkan K-NN digunakan untuk menganalisis pola serupa pada data historis. Hasil penelitian menunjukkan bahwa SVM memiliki akurasi prediksi sebesar 78%, lebih unggul dibandingkan K-NN yang mencapai akurasi 74%. Temuan ini membuktikan bahwa SVM lebih efektif dalam memodelkan keterkaitan antara variabel iklim dan ketahanan pangan. Dengan demikian, penelitian ini berhasil mencapai tujuannya dan memberikan kontribusi penting dalam pengembangan sistem prediksi berbasis machine learning untuk mendukung kebijakan pangan yang adaptif terhadap perubahan iklim.

Kata Kunci: Ketahanan Pangan, K-Nearest Neighbors, Pertanian, Perubahan Iklim, Support Vector Machine



1. PENDAHULUAN

Perubahan iklim yang merusak, seperti cuaca ekstrem dan hilangnya biodiversitas, memengaruhi kehidupan global. Tujuan SDGs ke-13 berfokus pada mengatasi perubahan iklim melalui pengurangan emisi gas rumah kaca, meningkatkan ketahanan terhadap perubahan iklim, dan mempromosikan pembangunan ramah lingkungan. Selain itu, ketahanan pangan juga menjadi isu penting dalam SDGs 2030 untuk mengakhiri kelaparan, meningkatkan ketahanan pangan dan nutrisi, serta mendukung pertanian berkelanjutan.

Perubahan iklim merupakan fenomena global yang mempengaruhi berbagai aspek kehidupan di bumi, termasuk sektor pertanian. Kondisi iklim yang berubah-ubah, seperti peningkatan suhu, perubahan pola curah hujan, dan kejadian cuaca ekstrem, dapat membawa dampak signifikan terhadap pertumbuhan dan produktivitas tanaman [1], [2]. Salah satu tanaman yang rentan terhadap perubahan iklim adalah gandum, yang merupakan salah satu tanaman pangan utama di dunia [3]. Gandum berperan penting dalam penyediaan sumber karbohidrat bagi populasi global, sehingga perubahan dalam pola pertumbuhannya memiliki implikasi besar terhadap ketahanan pangan [4]. Ketahanan pangan merupakan salah satu isu strategis global yang terus mendapatkan perhatian besar, terutama di negara berkembang seperti Indonesia [5][6].

Perubahan iklim secara langsung menyebabkan gangguan pada sistem produksi pangan melalui peningkatan suhu, pola curah hujan yang tidak menentu, serta kejadian cuaca ekstrem seperti kekeringan dan banjir. Kondisi ini menurunkan produktivitas lahan pertanian, memperpendek masa tanam, dan meningkatkan risiko gagal panen, yang pada akhirnya mengancam ketersediaan dan stabilitas pangan. Dalam konteks ini, penelitian ini mendalami bagaimana variabel iklim seperti suhu, curah hujan, dan angin dapat dipetakan secara kuantitatif untuk memprediksi ketahanan pangan menggunakan algoritma machine learning, khususnya SVM dan K-NN, sehingga hasilnya dapat digunakan sebagai dasar pengambilan keputusan dalam upaya mitigasi dan adaptasi terhadap perubahan iklim.

Selain permasalahan sosial ekonomi, Kerusakan lahan pertanian karena perubahan iklim dan penurunan produksi termasuk beberapa ancaman terhadap ketahanan pangan. Menurut BMKG dalam Kompas (2020), daerah produksi pertanian akan menjadi fokus prediksi iklim tahun 2020, terutama di beberapa wilayah produksi pertanian dengan musim kemarau yang lebih kering (Diasumsikan bahwa ada kemungkinan hal tersebut akan terjadi setelah bulan Juni 2020). Mulai dari Sumatera, Jawa, Kalimantan, Sulawesi Selatan, dan Bali. Hanani (2020) melaporkan bahwa pandemi COVID-19 yang mungkin menjadi ancaman untuk produksi dan distribusi makanan dan produk pertanian untuk memenuhi kebutuhan masyarakat sehingga dapat mempengaruhi pada ketahanan pangan, tambahnya bahwa hal tersebut dapat diberikan [7]. *Food and Agriculture Organization* (FAO) mendefinisikan ketahanan pangan sebagai situasi ketika orang memiliki akses, baik fisik dan ekonomi terhadap pangan yang cukup, aman dan sehat setiap saat untuk memenuhi kebutuhan dan preferensi pangan mereka untuk hidup yang energik dan sehat [8]. Menurut Nurdin [9], sektor pertanian sangat rentan terhadap perubahan iklim karena dapat memengaruhi pola tanam, waktu tanam, produksi, dan kualitas hasil [10]. Variabilitas iklim berdampak pada pertanian padi, dan karakteristik serta respons petani dapat digunakan sebagai dasar untuk meningkatkan kapasitas adaptasi petani dalam meminimalkan risiko terhadap dampak variabilitas dan perubahan iklim [11].

Dalam penelitian ini, penggunaan algoritma analisis data menjadi krusial untuk menghasilkan informasi yang akurat dan berguna. Terdapat banyak algoritma klasifikasi dalam supervised learning pada machine learning, diantaranya adalah K-Nearest Neighbors (K-NN), Naive Bayes Classifier (NBC), Support Vector Machine (SVM), Neural Network (NN), Random Forest Classifier (RFC), AdaBoost Classifier (ABC) dan Quadratic Discriminant Analysis (QDA). Masing-masing algoritma ini mempunyai kelebihan dan kekurangan. Salah satu kelebihan metode klasifikasi ini terlihat dari caranya menangani objek kumpulan data. K-NN merupakan algoritma yang mengklasifikasikan data berdasarkan K tetangga terdekat (*nearest neighbours*) [12].

Algoritma K-NN adalah salah satu algoritma yang sudah populer. K-NN ini termasuk ke dalam grup *instance-based learning*. Metode K-NN merupakan teknik *lazy learning*. [13]. Algoritma SVR merupakan pengembangan dari algoritma Support Vector Machine untuk kasus regresi atau prediksi [14]. SVM merupakan salah satu algoritma dalam *supervised learning* yang biasanya digunakan untuk klasifikasi (seperti *Support Vector Classification*) dan regresi (*Support Vector Regression*). Dalam pemodelan klasifikasi, SVM memiliki konsep yang lebih matang dan lebih jelas secara matematis dibandingkan dengan teknik-teknik klasifikasi lainnya. SVM juga dapat mengatasi masalah klasifikasi dan regresi dengan linear maupun non linear. SVM dapat mengklasifikasikan data di mana kelas tidak dapat dipisahkan secara linear dengan memetakan data. SVM dapat mengklasifikasikan data di mana kelas tidak dapat dipisahkan secara linear dengan memetakan data [15].

Dalam penelitian sebelumnya yang dilakukan, beberapa faktor yang disebut sebagai faktor abiotik seperti jenis tanah, tingkat nutrisi, suhu, kelembaban, dan angin berpengaruh signifikan terhadap hasil panen [16]. Kombinasi algoritma SVM-K-NN terbukti mampu meningkatkan akurasi klasifikasi, seperti pada penelitian Akbar dkk. (2023) yang mengidentifikasi gagal ginjal kronis dan mencapai akurasi 94,25%, lebih tinggi dibandingkan SVM (94,09%) dan K-NN (91,73%) [17]. Pada penggunaan algoritma SVM, Kurniawan dkk. (2023) berhasil memprediksi hasil panen salak dengan akurasi baik, dan Rokhmah dkk. (2022)

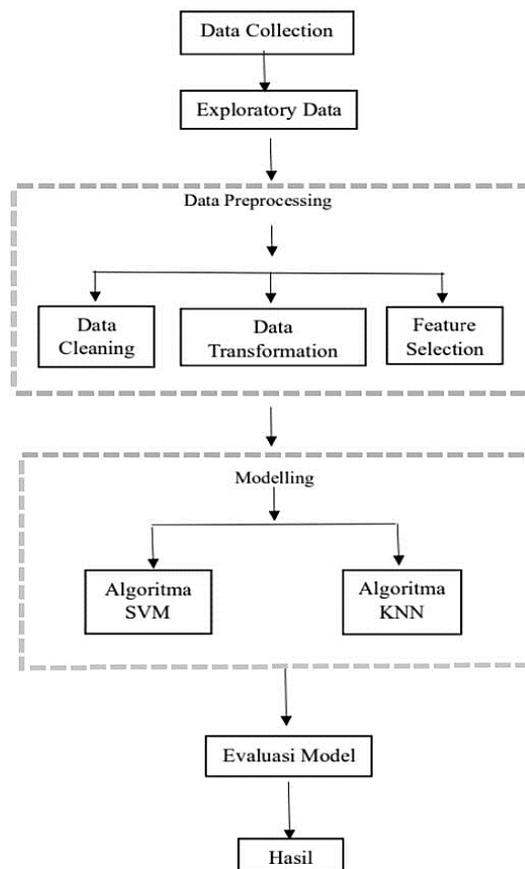
mengklasifikasikan produktivitas padi secara efektif [18][19]. Sementara itu, Algoritma K-NN digunakan oleh Rustanto dkk. (2023) dalam identifikasi penyakit daun padi berbasis citra, serta oleh Bhayangkara dkk. (2020) untuk klasifikasi kualitas tanah kedelai secara real-time menggunakan sensor Arduino [20][21].

Penelitian ini membandingkan K-NN dan SVM dalam memprediksi dampak perubahan iklim terhadap ketahanan pangan, mengevaluasi keakuratan dan efisiensi kedua algoritma dalam menganalisis variabel-variabel yang berhubungan dengan kondisi iklim dan ketahanan pangan. Secara akademik, penelitian ini memperkaya literatur machine learning dalam konteks ketahanan pangan dan perubahan iklim, serta menjadi referensi untuk pengembangan model prediksi yang lebih akurat dalam menghadapi tantangan perubahan iklim. Secara praktis, hasil penelitian ini dapat diterapkan dalam sistem peringatan dini dan strategi mitigasi untuk memastikan ketahanan pangan di masa depan, yang bermanfaat bagi pengambil kebijakan dan petani. Selain itu, penelitian ini memberikan wawasan penting bagi praktisi dan pengembang aplikasi berbasis teknologi untuk memilih algoritma terbaik yang dapat membantu memprediksi dan memitigasi dampak perubahan iklim terhadap ketahanan pangan, sehingga mendukung upaya global dalam meningkatkan ketahanan pangan dan mengurangi kerentanannya terhadap perubahan iklim.

Meskipun sudah banyak penelitian yang mengkaji K-NN dan SVM secara terpisah, perbandingan langsung antara kedua algoritma ini dalam memprediksi dampak perubahan iklim terhadap ketahanan pangan masih sangat terbatas. Padahal, penelitian komparatif seperti ini penting untuk mengidentifikasi algoritma mana yang lebih efektif dan efisien dalam menangani masalah kompleks yang melibatkan variabel iklim dan ketahanan pangan. Oleh karena itu, penelitian ini bertujuan untuk menganalisis kinerja kedua algoritma dalam memprediksi dampak perubahan iklim terhadap ketahanan pangan, serta mengidentifikasi keunggulan dan kelemahan masing-masing algoritma dalam memberikan prediksi yang akurat dan relevan. Evaluasi dilakukan menggunakan metrik-metrik seperti akurasi, presisi, *recall*, dan *F1-score*, untuk memberikan gambaran yang lebih jelas mengenai performa keduanya dalam konteks ini.

2. METODE PENELITIAN

Dari alur penelitian yang di gunakan disajikan pada Gambar 1.



Gambar 1. Methodologi Penelitian

Gambar 1 merupakan tahapan penelitian yang terdiri dari.

2.1. Data Collection

Dataset ini berasal dari penelitian yang bertujuan untuk menganalisis dampak perubahan iklim terhadap ketahanan pangan. Data yang digunakan meliputi data meteorologi harian periode 2012–2022, Data ini memiliki enam fitur utama:

1. *Date* (tanggal),
2. *Precipitation* (curah hujan, dalam mm),
3. *Temp_max* dan *Temp_min* (suhu maksimum dan minimum harian, dalam °C),
4. *Wind* (kecepatan angin, dalam m/s),
5. *Weather* (kondisi cuaca yang telah dikodekan dalam skala numerik: 1=hujan, 2=kabut, 3=panas, 4=salju, 5=gerimis).

Total terdapat 1460 data observasi. Data ini digunakan untuk merepresentasikan kondisi iklim yang akan menjadi prediktor dalam pemodelan ketahanan pangan.

2.2 Exploratory Data

Exploratory Data Analysis (EDA) adalah suatu pendekatan awal yang penting dalam analisis data yang bertujuan untuk menggali dan memahami struktur serta karakteristik data tanpa membuat asumsi sebelumnya [22]. EDA bertujuan untuk memahami struktur, pola, dan karakteristik dataset. Analisis ini melibatkan evaluasi distribusi data, identifikasi *outlier*, dan pemahaman hubungan antarvariabel menggunakan visualisasi seperti histogram, *scatter plot*.

2.3. Data Preprocessing

Data Preprocessing adalah proses menyiapkan data mentah agar siap digunakan oleh Algoritma Machine Learning melalui pembersihan, transformasi, dan pemformatan data. Pada tahapan ini menggunakan tiga tahap:

1. Data Cleaning

Data Cleaning adalah proses membersihkan data dari kesalahan, inkonsistensi, atau nilai yang tidak sesuai agar lebih siap digunakan dalam analisis dan machine learning. Pembersihan data merupakan proses menghilangkan *noise* dan data yang tidak konsisten atau data tidak relevan [23].

2. Data Transformation

Data Transformation adalah proses mengubah atau memanipulasi data agar lebih sesuai untuk analisis atau pemodelan machine learning. Setelah data dibersihkan dari kesalahan, data ditransformasikan menurut tipe data pada tahap transformasi, dan tipe data diklasifikasikan sebagai data kategorikal [22]. Transformasi pada penelitian ini yaitu mengubah data pada fitur *BmiClass* kedalam bentuk numerik, yang nantinya akan dilakukan seleksi fitur [24].

3. Feature Selection

Feature Selection adalah proses memilih *subset fitur* (*variabel independen*) yang paling relevan untuk digunakan dalam model *machine learning*. *Feature selection* (seleksi fitur) bertujuan untuk memilih *feature* yang berpengaruh dan mengesampingkan *feature* yang tidak berpengaruh dalam suatu kegiatan pemodelan atau penganalisaan data. Menggunakan teknik seleksi fitur mengurangi jumlah fitur digunakan untuk belajar dan memilih fitur diskriminasi tinggi dalam proses seleksi fitur [25]. Selain itu, seleksi fitur membantu meningkatkan akurasi dengan memilih fitur yang optimal [26].

2.4. Modelling

Pada tahap Modeling Data, dibangun model prediktif menggunakan Algoritma SVM dan K-NN dengan pembagian data 80% untuk pelatihan dan 20% untuk pengujian. Parameter model dioptimalkan menggunakan Grid Search. Untuk SVM diuji kombinasi parameter C, kernel, dan gamma, sedangkan untuk K-NN diuji variasi k, weights, dan metric, guna memperoleh kombinasi terbaik dan mengevaluasi akurasi model.

Algoritma digunakan untuk mengolah data melalui serangkaian langkah yang terstruktur guna menghasilkan model yang sesuai dengan tujuan penelitian. Dalam penelitian ini, dua algoritma yang digunakan adalah:

1. Algoritma K-NN

K-NN merupakan salah satu Metode *supervised learning* yang dapat digunakan untuk berbagai tujuan, seperti klasifikasi dan penambangan data [27]. Metode klasifikasi ini menggunakan perkiraan statistik untuk menemukan solusi yang efisien [17]. Algoritma ini menentukan kelas suatu titik data dengan mempertimbangkan kelas dari K tetangga terdekatnya [28]. Jarak antar titik dihitung menggunakan rumus Euclidean ditunjukkan pada persamaan 1.

$$d(x, x_i)^n = \sqrt{\sum_{j=1}^n (x, x_{ij})^2} \quad (1)$$

Di mana d adalah jarak Euclidean antara titik data uji x dan titik data pelatihan x_i .

2. Algoritma SVM

Support Vector Machine (SVM) merupakan metode yang handal dalam menangani masalah klasifikasi data [27]. SVM termasuk dalam kategori *supervised learning* yang berfungsi mengklasifikasikan data baru ke dalam ruang berdimensi N dengan memanfaatkan *hyperplane* sebagai pemisah [29]. Metode ini tidak hanya efektif untuk data yang terpisah secara linier, tetapi juga mampu menangani data yang bersifat non-linier. Tujuan utama dari SVM yakni untuk menentukan *hyperplane* ideal yang memisahkan dua kelas dengan cara memaksimalkan margin antar kelas [29], persamaan umum dapat ditunjukkan pada persamaan 2.

$$f(x) = \omega^T x + b \quad (2)$$

SVM bertujuan untuk memaksimalkan margin antar kelas, yang dihitung sebagai:

$$\text{Margin} = \frac{2}{\|\omega\|} \quad (3)$$

SVM juga menggunakan fungsi kernel seperti Linear dan Radial Basis Function untuk menangani data yang tidak terpisahkan secara linear.

2.5. Evaluasi Model

Untuk mengukur kinerja dalam Evaluasi model menggunakan *Confusion Matrix*. *Confusion Matrix* adalah alat evaluasi yang digunakan untuk mengukur kinerja model klasifikasi dengan membandingkan prediksi model dengan nilai sebenarnya. Evaluasi memiliki makna yang berbeda dengan penilaian dan pengukuran. Evaluasi didahului dengan penilaian (*assessment*), sedangkan penilaian didahului dengan pengukuran [26]. Evaluasi Model adalah proses untuk menilai kinerja model machine learning setelah tahap pelatihan selesai. Tujuan dari evaluasi model adalah untuk mengetahui seberapa baik model yang dibangun dapat menggeneralisasi dan membuat prediksi yang akurat pada data yang tidak terlihat sebelumnya (data uji). Ini adalah langkah penting untuk memastikan model yang digunakan dapat memberikan hasil yang bermanfaat dan dapat diterapkan di dunia nyata. Optimasi dilakukan dengan Grid Search dan validasi silang 5-fold.

Evaluasi model dilakukan menggunakan empat metrik utama sebagai berikut:

1. Akurasi

Akurasi mengukur seberapa tepat model dalam memprediksi data dengan benar secara keseluruhan. Metrik ini memberikan gambaran umum tentang kinerja model pada seluruh dataset.

$$\text{Akurasi} = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (1)$$

2. Precision

Precision mengukur akurasi prediksi positif yang dibuat oleh model.

$$\text{Precision} = \frac{(TP)}{(TP+FP)} \quad (2)$$

3. Recall

Recall mengukur seberapa baik model dalam menemukan semua data positif yang sebenarnya

$$\text{Recall} = \frac{(TP)}{(TP+FN)} \quad (3)$$

4. F1-Score

F1-Score adalah rata-rata harmonik dari Precision dan Recall, memberikan keseimbangan antara keduanya.

$$\text{F1-Score} = \frac{2 (\text{PRECISION} \times \text{RECALL})}{\text{PRECISION} + \text{RECALL}} \quad (4)$$

Model dengan F1-score tertimbang tertinggi dianggap paling baik dalam klasifikasi kelas yang tidak seimbang. Pada tahapan berikut ini akan menjelaskan hasil dari kinerja model.

3. HASIL DAN PEMBAHASAN

3.1. Data Collection

Data ini di ambil di <https://kaggle.com> pemilik akun *mark medhat*. Dataset tersebut berisi data cuaca harian kota Seattle dengan total 1.460 entri, mencakup variabel: tanggal (*date*), curah hujan (*precipitation*), suhu maksimum (*temp_max*), suhu minimum (*temp_min*), kecepatan angin (*wind*), dan kondisi cuaca (*weather*). Data weather telah dikonversi ke dalam bentuk numerik yaitu: 1 untuk hujan, 2 untuk kabut, 3 untuk panas, 4 untuk salju, dan 5 untuk gerimis. *Dataset* publik ini telah digunakan dalam berbagai studi sebelumnya, seperti oleh Zamil et al. (2019) untuk klasifikasi cuaca menggunakan SVM dan K-NN dalam filtering email spam berbasis kondisi cuaca, serta oleh Egbunu et al. (2021) untuk memprediksi pengaruh iklim terhadap ketahanan pangan di Nigeria dengan Random Forest. Hal ini menunjukkan bahwa dataset tersebut relevan dan dapat dipertanggungjawabkan secara ilmiah untuk pemodelan prediksi iklim dan pangan, Tabel 1 merupakan isi *dataset* yang digunakan yaitu *Dataset Weather Seattle*.

Tabel 1. Dataset Weather Seattle

No	Date	Precipitation	Temp_Max	Temp_Min	Wind	Weather
0	2012-01-01	0.0	12.8	5.0	4.7	5
1	2012-01-02	10.9	10.6	2.8	4.5	1
2	2012-01-03	0.8	11.7	7.2	2.3	1
3	2012-01-04	20.3	12.2	5.6	4.7	1
4	2012-01-05	1.3	8.9	2.8	6.1	1
...
1456	2015-12-27	8.6	4.4	1.7	2.9	1
1457	2015-12-28	1.5	5.0	1.7	1.3	1
1458	2015-12-29	0.0	7.2	0.6	2.6	2
1459	2015-12-30	0.0	5.6	-1.0	3.4	3
1460	2015-12-31	0.0	5.6	-2.1	3.5	3

Pluviometer (Alat Ukur Curah Hujan), Termometer (*Max-Min*), *Anemometer*, *Wind Vane*, Stasiun Meteorologi.

3.2. Exploratory Data

Visualisasi data menunjukkan korelasi kuat antara suhu maksimum dan minimum, sementara curah hujan dan angin tidak memiliki hubungan jelas dengan variabel lain. Distribusinya cenderung skewed ke kanan, dan kategori cuaca tersebar merata tanpa pola spesifik terhadap variabel iklim.

3.3. Data Preprocessing

1. Data Cleaning

Pembersihan data merupakan proses menghilangkan noise dan data yang tidak konsisten atau data tidak relevan [23].

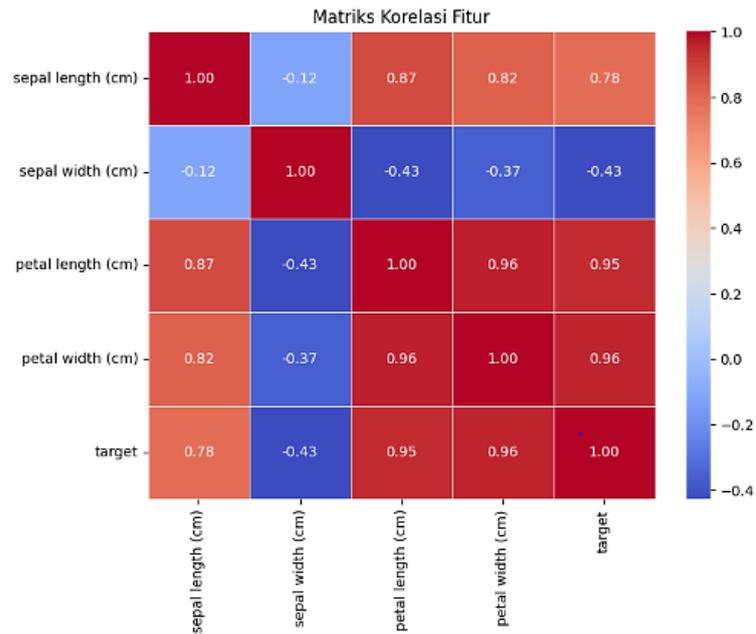
2. Data Transformation

Normalisasi data untuk memastikan setiap variabel memiliki skala yang sama.

3. Feature Selection

Memilih fitur-fitur penting berdasarkan korelasi atau analisis statistik.

Skrip ini mempersiapkan dataset cuaca Seattle untuk model K-NN dan SVM dengan membersihkan data (menghapus duplikasi, imputasi nilai hilang, dan menghapus outlier) serta mentransformasi fitur. Data dinormalisasi untuk K-NN menggunakan *MinMaxScaler* dan distandarisasi untuk SVM menggunakan *StandardScaler*, agar siap untuk pelatihan model selanjutnya. Gambar 2 korelasi antar fitur dapat di lihat di bawah ini.



Gambar 2. Matriks korelasi fitur

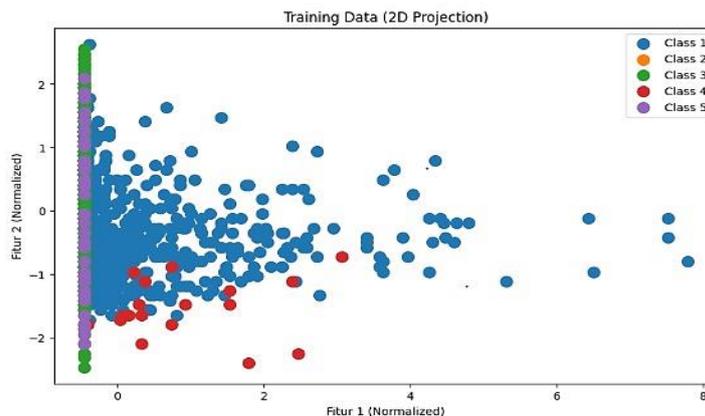
3.4 Hasil Evaluasi dan Visualisasi Model

Tahap ini melibatkan pembangunan model prediktif menggunakan algoritma SVM dan K-NN. Parameter model dioptimalkan menggunakan teknik grid search untuk meningkatkan performa. Modeling SVM dapat terlihat pada script Gambar 3.

```
Best parameters for SVM: {'C': 1, 'gamma': 'scale', 'kernel': 'linear'}
SVM Accuracy: 1.0
Best parameters for KNN: {'metric': 'euclidean', 'n_neighbors': 3, 'weights': 'uniform'}
KNN Accuracy: 1.0
```

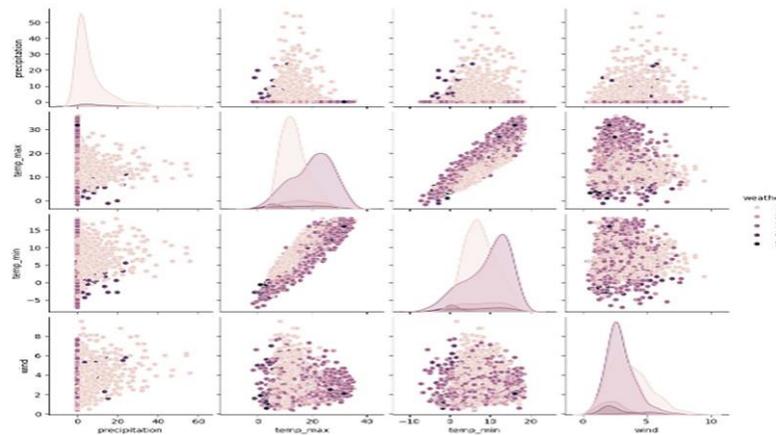
Gambar 3. Script

Hasil visualisasi SVM dapat di lihat pada Gambar 4.



Gambar 4. Visualisasi SVM

Visualisasi Algoritma SVM ini menunjukkan *scatter plot* dari data yang telah dinormalisasi, dengan dua fitur utama sebagai sumbu X dan Y. Setiap titik mewakili sampel data, dan warna yang berbeda menunjukkan kelas masing-masing. Dari pola sebarannya, terlihat bahwa *Class 1* (biru) memiliki distribusi yang lebih luas, sementara kelas lainnya lebih terkonsentrasi di sisi kiri grafik. Hal ini mengindikasikan bahwa fitur pertama mungkin memiliki pengaruh lebih besar dalam membedakan kelas dibandingkan fitur kedua. Disiniin (1) sebagai Hujan, (2) sebagai Kabut, (3) sebagai Panas, (4) sebagai Salju, dan (5) sebagai Gerimis. Hasil visualisasi K-NN dapat di lihat pada Gambar 5.



Gambar 5. Visualisasi K-NN

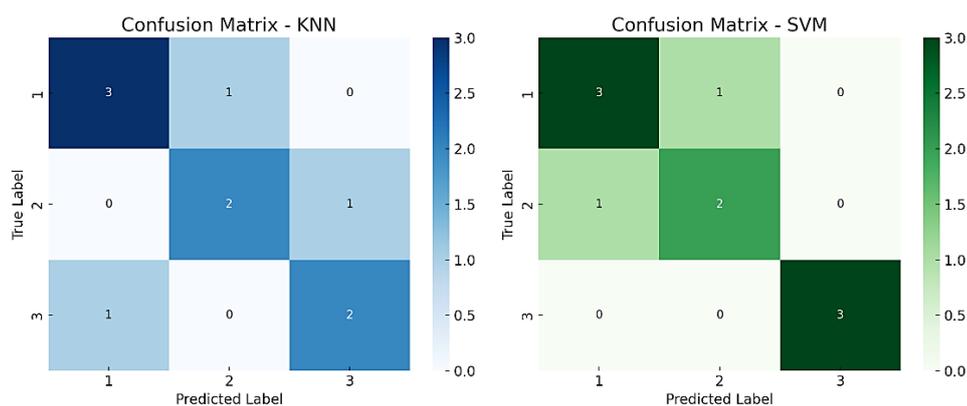
Scatter plot menunjukkan hubungan antar variabel cuaca pada model K-NN, dengan korelasi kuat antara suhu maksimum dan minimum, serta distribusi skewed pada curah hujan dan angin. Algoritma SVM dan K-NN digunakan untuk mengolah dataset dan membandingkan akurasi, di mana algoritma dengan akurasi tertinggi dijadikan acuan utama dalam penelitian ini. Evaluasi model dilakukan dengan menggunakan metrik seperti:

1. Akurasi: Untuk mengukur seberapa sering model memprediksi dengan benar.
2. *Precision, Recall, F1-Score*: Untuk mengevaluasi keseimbangan antara *true positives* dan *false positives*.
3. *Cross-Validation*: Untuk menghindari *overfitting*.

Tabel 2. Perbandingan Kinerja Model

Metrik Evaluasi	K-NN	SVM
Akurasi	74%	78%
Precision (weighted)	0.71	0.73
Recall (weighted)	0.72	0.75
F1-Score (weighted)	0.72	0.74
F1-Score (macro)	0.45	0.34

Hasil menunjukkan bahwa SVM unggul dalam semua metrik utama, terutama pada *F1-score* tertimbang. Namun, nilai *F1-score macro* yang rendah menunjukkan kedua algoritma masih memiliki kesulitan dalam mengklasifikasikan kelas minoritas.



Gambar 5. Confusion Matrix

Confusion matrix pada Gambar 5 memberikan gambaran visual mengenai prediksi benar dan salah dari masing-masing kelas. K-NN menunjukkan keunggulan dalam mengklasifikasikan kelas dominan seperti hujan dan panas, sementara SVM memperlihatkan kestabilan klasifikasi yang lebih baik secara keseluruhan.

3.5. Analisis Komparatif dan Statistik

Analisis pada Tabel 3 menunjukkan kelebihan dan kekurangan masing-masing algoritma dalam konteks prediksi ketahanan pangan:

Tabel 3. Analisis Komparatif Algoritma

Aspek	K-NN	SVM
Kelebihan	Sederhana, cepat untuk dataset kecil	Akurat untuk data kompleks dan non-linear
Kekurangan	Sensitif terhadap outlier, tidak efisien pada data besar	Perlu tuning parameter dan komputasi tinggi
Relevansi	Cukup untuk preiksi cuaca dasar	Efektif dalam mengenali pola iklim terhadap ketahanan pangan

Untuk mengetahui apakah perbedaan performa signifikan secara statistik, dilakukan uji paired t-test terhadap nilai F1-score dari validasi silang. Hasil pengujian menunjukkan:

$$p\text{-value} < 0.05$$

Hasil ini menunjukkan bahwa perbedaan performa antara K-NN dan SVM signifikan secara statistik, dan SVM secara konsisten menunjukkan performa yang lebih baik dalam klasifikasi prediksi ketahanan pangan berbasis iklim.

Algoritma K-NN memiliki akurasi 74%, dengan performa baik pada kelas 1 dan 3, namun buruk pada kelas 2, 4, dan 5. Sementara itu, SVM sedikit lebih akurat (78%) dan juga baik pada kelas 1 dan 3, namun sangat buruk pada kelas 2, 4, dan 5. Kedua model menunjukkan macro average f1-score yang rendah (K-NN: 0.45, SVM: 0.34), meskipun weighted average f1-score keduanya 0.72, yang berarti lebih baik pada kelas dengan data lebih banyak. Keduanya kesulitan dalam mengklasifikasikan kelas minoritas.

Dari kedua Algoritma, di dapatkan hasil untuk keduanya hanya mencapai good model yaitu kisaran 70%. Hasil utama yang di dapat adalah pengaruh dari setiap variabel yang telah di tentukan yaitu 1 sampai 5. Disini dari Algoritma SVM dan K-NN terdapat keunggulan pada Algoritma SVM dari segi variabel dan akurasi, modelnya 1 sebagai hujan dan 3 sebagai suhu maksimum adalah variabel yang paling berpengaruh dari penelitian ini. Untuk mencapai *excellent* di sarankan untuk menggunakan data yang banyak untuk menghasilkan model yang bagus.

3.6. Diskusi

Hasil penelitian menunjukkan bahwa Algoritma SVM memiliki performa lebih baik dibandingkan K-NN dalam memprediksi dampak perubahan iklim terhadap ketahanan pangan, dengan akurasi masing-masing sebesar 78% dan 74%. Kelebihan SVM terletak pada kemampuannya menangani data *non-linear* dan berdimensi tinggi melalui penggunaan fungsi kernel, sedangkan K-NN yang bersifat *instance-based* cenderung kurang efektif pada distribusi data yang tidak seimbang. Distribusi kelas yang tidak merata dalam dataset menyebabkan penurunan performa klasifikasi pada kelas minoritas, sebagaimana tercermin dari nilai *F1-score* makro yang rendah (SVM: 0.34; K-NN: 0.45). Hal ini menegaskan pentingnya teknik penyeimbangan data seperti Synthetic Minority Over-sampling Technique (SMOTE) untuk penelitian lanjutan.

Temuan ini sejalan dengan hasil studi sebelumnya seperti oleh Akbar et al. (2023) yang menunjukkan bahwa SVM dapat mengenali pola kompleks dengan baik. Dalam konteks ketahanan pangan, curah hujan ekstrem dan suhu maksimum terbukti menjadi variabel paling dominan dalam mempengaruhi hasil prediksi, dan relevansi temuan ini membuka peluang integrasi model ke dalam sistem pemantauan berbasis data.

Secara praktis, model yang dikembangkan berpotensi diimplementasikan dalam sistem peringatan dini untuk ketahanan pangan. Hal ini dapat dimanfaatkan oleh pemangku kebijakan seperti Kementerian Pertanian, BMKG, atau Badan Ketahanan Pangan untuk mendukung strategi adaptasi perubahan iklim. Namun, penelitian ini memiliki keterbatasan pada cakupan data spasial dan temporal yang terbatas serta belum mempertimbangkan variabel sosial ekonomi. Ke depan, penelitian serupa dapat memperluas data ke wilayah Indonesia dan menerapkan Algoritma *ensemble* seperti Random Forest atau XGBoost untuk meningkatkan akurasi serta membangun sistem pemantauan ketahanan pangan secara real-time melalui dashboard interaktif.

4. KESIMPULAN

Penelitian ini mengembangkan model prediksi dampak perubahan iklim terhadap ketahanan pangan menggunakan Algoritma SVM dan K-NN. Hasil penelitian menunjukkan bahwa SVM memiliki akurasi lebih tinggi (78%) dibandingkan K-NN (74%), meskipun kedua model mengalami kesulitan dalam mengklasifikasikan kelas minoritas. Analisis lebih lanjut mengungkap bahwa variabel yang paling berpengaruh terhadap ketahanan pangan dalam model SVM adalah curah hujan ekstrem dan suhu maksimum, sedangkan dalam model K-NN, variabel dominan adalah fluktuasi suhu harian dan curah hujan. Visualisasi data menunjukkan suhu maksimum dan minimum memiliki korelasi yang kuat, sementara curah hujan dan kecepatan angin menunjukkan distribusi yang skewed dengan beberapa outlier. Dari kelima variabel yang diteliti, curah hujan dan suhu ekstrem (panas) terbukti sebagai faktor paling berpengaruh dalam kedua algoritma, dengan curah hujan menjadi variabel utama yang konsisten mempengaruhi hasil prediksi. Oleh karena itu, curah hujan (peringkat 1) dan suhu ekstrem (peringkat 3) menjadi faktor kritis yang perlu

diperhatikan dalam merumuskan kebijakan. Dengan demikian, model prediktif ini dapat menjadi alat yang bermanfaat bagi pembuat kebijakan dalam merancang strategi mitigasi dan adaptasi terhadap dampak perubahan iklim pada sektor pertanian, guna menjaga keberlanjutan sistem pangan di wilayah yang rentan terhadap perubahan iklim. Dengan splitting data 80:20 dapat di peroleh bahwa yang terbaik adalah pada SVM adapun faktor yang mempengaruhi pada SVM itu adalah curah hujan (peringkat 1) dan suhu ekstrem (peringkat 3) menjadi faktor kritis yang perlu diperhatikan dalam merumuskan kebijakan. Hal itu akan menjadi dasar rekomendasi kebijakan untuk ketahanan pangan dalam menghadapi perubahan iklim.

REFERENSI

- [1] I. M. I. Agastya, R. P. D. Julianto, and M. Marwoto, "Review : Pengaruh Pemanasan Global Terhadap Intensitas Serangan Kutu Kebul (Bemisia Tabaci Genn) Dan Cara Pengendaliannya Pada Tanaman Kedelai," *Buana Sains*, vol. 20, no. 1, pp. 99–110, 2020, doi: 10.33366/bs.v20i1.1935.
- [2] A. Nurhidayat, A. K. T. Difa, F. Nasrullah, F. H. Anwar, and D. O. Radianto, "Pengaruh Perubahan Iklim Terhadap Produktivitas Pertanian Padi di Daerah Tropis," *Sains Student Res.*, vol. 2, no. 2, pp. 111–117, 2024.
- [3] Rosidin, D. A. Sulaeman, Sukarsa, A. Kohar, and M. I. Habibi, "Pengembangan Algoritma Pemrosesan Bahasa Alami Untuk Aplikasi Chatbot Dalam Pelayanan Pelanggan," *J. Rev. Pendidik. dan Pengajaran*, vol. 7, no. 3, pp. 7409–7414, 2024.
- [4] A. Ninasari, "Analisis Dampak Perubahan Iklim Terhadap Pola Pertumbuhan dan Produktivitas Tanaman Gandum," *J. Rev. Pendidik. dan Pengajaran*, vol. 7, no. 3, pp. 8022–8028, 2024.
- [5] O. Simon, H. Raharusun, and A. Hasibuan, "Sistem Prediksi Produksi Beras Menggunakan Multiple Linear Regression untuk Optimalisasi Ketahanan Pangan di Kabupaten Minahasa," no. 225, pp. 36–40, 2024.
- [6] A. M. Ashari, "Dampak Perubahan Iklim terhadap Ketahanan Pangan dan Adaptasinya oleh Masyarakat Pesisir," *Empiricism J.*, vol. 4, no. 2, pp. 426–431, 2023, doi: 10.36312/ej.v4i2.1611.
- [7] L. N. Aziza, R. Y. Astuti, B. A. Maulana, and N. Hidayati, "Penerapan Algoritma K-Nearest Neighbor untuk Klasifikasi Ketahanan Pangan di Provinsi Jawa Tengah," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 2, pp. 404–412, 2024, doi: 10.57152/malcom.v4i2.1201.
- [8] Arifah, Megawati, and N. Bando, "Climate Change Impact and Household Food Security :," *Pros. Semin. Sustain. Environ. Agric. Syst. Safety, Heal. Secur. Hum. Life*, pp. 659–664, 2021.
- [9] B. Nurwenda, "Analisis Dampak Perubahan Iklim Terhadap Ketahanan Pangan Petani Jagung Lokal Di Kecamatan Kabawo Kabupaten Muna," vol. 4, 2024.
- [10] K. A. Harvian and R. J. Yuhan, "Kajian Perubahan Iklim Terhadap Ketahanan Pangan," *Semin. Nas. Off. Stat.*, vol. 2020, no. 1, pp. 1052–1061, 2021, doi: 10.34123/semnasoffstat.v2020i1.593.
- [11] G. Rusmayadi, U. Salawati, and D. O. Suparwata, "Analisis Sistem Agrometeorologi dalam Meningkatkan Ketahanan Pangan saat Kemarau," *J. Geosains West Sci.*, vol. 1, no. 03, pp. 143–150, 2023, doi: 10.58812/jgws.v1i03.720.
- [12] A. M. Argina, "Penerapan Metode Klasifikasi K-Nearest Neighbor pada Dataset Penderita Penyakit Diabetes," *Indones. J. Data Sci.*, vol. 1, no. 2, pp. 29–33, 2020, doi: 10.33096/ijodas.v1i2.11.
- [13] R. Puspita and A. Widodo, "Perbandingan Metode K-NN, Decision Tree, dan Naïve Bayes Terhadap Analisis Sentimen Pengguna Layanan BPJS," *J. Inform. Univ. Pamulang*, vol. 5, no. 4, p. 646, 2021, doi: 10.32493/informatika.v5i4.7622.
- [14] R. A. Saputra *et al.*, "Detecting Alzheimer's Disease by the Decision Tree Methods Based on Particle Swarm Optimization," *J. Phys. Conf. Ser.*, vol. 1641, no. 1, pp. 61–67, 2020, doi: 10.1088/1742-6596/1641/1/012025.
- [15] F. H. Hasibuan, "Website: <https://j-innovative.org/index.php/Innovative> Klasifikasi Data Material Pending Pada Perusahaan dengan Metode SVM," *Innov. J. Soc. Sci. Res.*, vol. 4, pp. 5080–5090, 2024, [Online]. Available: <https://j-innovative.org/index.php/Innovative>
- [16] C. O. Egbunu, M. T. Ogedengbe, T. S. Yange, M. A. Rufai, and H. I. Muhammed, "Towards Food Security: the Prediction of Climatic Factors in Nigeria using Random Forest Approach," *J. Comput. Scine Inf. Technol.*, vol. 7, no. December 2018, pp. 70–81, 2021, doi: 10.35134/jcsitech.v7i4.15.
- [17] A. T. Akbar, N. Yudistira, and A. Ridok, "Identifikasi Gagal Ginjal Kronis dengan Mengimplementasikan Metode Support Vector Machine beserta K-Nearest Neighbour (SVM-K-NN)," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 2, pp. 301–308, 2023, doi: 10.25126/jtiik.20231026059.
- [18] R. Kurniawan, A. Halim, and H. Melisa, "Prediksi Hasil Panen Pertanian Salak di Daerah Tapanuli Selatan Menggunakan Algoritma SVM (Support Vector Machine)," *KLIK Kaji. Ilm. Inform. dan Komput.*, vol. 4, no. 2, pp. 903–912, 2023, doi: 10.30865/klik.v4i2.1246.
- [19] H. Tohari, S. Harini, M. A. Yaqin, I. B. Santoso, and C. Crysdiyan, "Penerapan Metode Support Vector Machine (SVM) Dalam Klasifikasi Produktivitas Padi," *J. Comput. Syst. Informatics*, vol. 5, no. 1, pp. 175–183, 2023, doi: 10.47065/josyc.v5i1.4538.
- [20] D. Wahyudi Rustanto, F. Liantoni, and N. Pradana Taufik Prakisyta, "Identifikasi Penyakit Daun pada

- Tanaman Padi Menggunakan Ekstraksi Fitur Gray Level Co-occurrence Matrix (GLCM) dan Metode K-Nearest Neighbour (K-NN),” *J. Sist. dan Teknol. Inf.*, vol. 12, no. 1, pp. 100–106, 2024, doi: 10.26418/justin.v12i1.69752.
- [21] H. Basri, P. Purnawansyah, H. Darwis, and F. Umar, “Klasifikasi Daun Herbal Menggunakan K-Nearest Neighbor dan Convolutional Neural Network dengan Ekstraksi Fourier Descriptor,” *J. Teknol. dan Manaj. Inform.*, vol. 9, no. 2, pp. 79–90, 2023, doi: 10.26905/jtmi.v9i2.10350.
- [22] Farhanuddin, Sarah Ennola Karina Sihombing, and Yahfizham, “Komparasi Multiple Linear Regression dan Random Forest Regression Dalam Memprediksi Anggaran Biaya Manajemen Proyek Sistem Informasi,” *J. Comput. Digit. Bus.*, vol. 3, no. 2, pp. 86–97, 2024, doi: 10.56427/jcbd.v3i2.408.
- [23] K. B. Sirait, M. N. Ermawati, N. Casie, P. Studi Teknik Informatika, S. AMIK Riau, and C. Author, “SENTIMAS: Seminar Nasional Penelitian dan Pengabdian Masyarakat Grouping of Egg Production in West Java Province Using the K-Means Algorithm Pengelompokan Produksi Telur di Provinsi Jawa Barat dengan Menggunakan Algoritma K-Means,” *Semin. Nas. Penelit. dan Pengabd. Masy.*, pp. 207–217, 2022, [Online]. Available: <https://journal.irpi.or.id/index.php/sentimas>
- [24] F. Putra, H. F. Tahiyat, and R. M. Ihsan, “Application of K-Nearest Neighbor Algorithm Using Wrapper as Preprocessing for Determination of Human Weight Information Penerapan Algoritma K-Nearest Neighbor Menggunakan Wrapper Sebagai Preprocessing untuk Penentuan Keterangan Berat Badan Manusia,” vol. 4, no. January, pp. 273–281, 2024.
- [25] J. Lee, D. Park, and C. Lee, “Feature selection algorithm for intrusions detection system using sequential forward search and random forest classifier,” *KSII Trans. Internet Inf. Syst.*, vol. 11, no. 10, pp. 5132–5148, 2017, doi: 10.3837/tiis.2017.10.024.
- [26] M. S. Bahri, “Problematika Evaluasi Pembelajaran dalam Mencapai Tujuan Pendidikan di Masa Merdeka Belajar,” *JHIP - J. Ilm. Ilmu Pendidik.*, vol. 6, no. 4, pp. 2871–2880, 2023, doi: 10.54371/jiip.v6i4.1954.
- [27] Y. K. Zamil, S. A. Ali, and M. A. Naser, “Spam image email filtering using K-NN and SVM,” *Int. J. Electr. Comput. Eng.*, vol. 9, no. 1, pp. 245–254, 2019, doi: 10.11591/ijece.v9i1.pp245-254.
- [28] R. A. Sucipto and B. K. Khotimah, “Tubuh Menggunakan Metode Support Vector Machine Dan K-Nearest Neighbors,” vol. 13, no. 1, pp. 795–803, 2025.
- [29] M. Susilo and A. Gunaryati, “Pendekatan Knowledge Management System Berbasis Framework Laravel dan Container untuk Kinerja Helpdesk pada BMKG Pusat Meteorologi Penerbangan,” *J. Teknol. Inform. dan Komput.*, vol. 9, no. 2, pp. 630–644, 2023, doi: 10.37012/jtik.v9i2.1672.