

Komparasi Algoritma *Machine Learning* untuk Deteksi Kondisi Daun Lengkuas Menggunakan Fitur Warna *RGB* dan *HSV*

Rachel Tinezia Zaitul Imaroh*, Muhammad Arifin, Arif Setiawan

Program Studi Sistem Informasi, Fakultas Teknik, Universitas Muria Kudus, Kota Kudus, Indonesia

Email: ¹*202153168@std.umk.ac.id, ²arifin.m@umk.ac.id, ³arif.setiawan@umk.ac.id

Email Penulis Korespondensi: 202153168@std.umk.ac.id

Submitted: 12/05/2026; Accepted: 26/08/2026; Published: 30/09/2026

Abstrak– Penurunan kualitas tanaman lengkuas (*Alpinia galanga*) dapat ditandai dengan munculnya gejala pada daun yang perlu diidentifikasi sejak awal. Penelitian ini bertujuan membandingkan algoritma *machine learning* untuk mendeteksi kondisi daun lengkuas berdasarkan fitur warna *RGB* dan *HSV*. Penelitian dilakukan di kebun lengkuas Desa Cranggang menggunakan 100 citra daun. Pada tahap awal, kondisi daun ditentukan berdasarkan pengamatan visual dan menghasilkan 76 citra daun sakit dan 24 citra daun sehat. Selanjutnya, dilakukan penentuan kategori menggunakan pendekatan *rule-based* berdasarkan diameter bercak yang terdeteksi secara komputasional dengan ambang batas 0,5 cm, sehingga diperoleh hasil akhir 82 citra dengan kategori sakit dan 18 citra dengan kategori sehat. Citra kemudian diolah menjadi fitur numerik berupa nilai rata-rata *RGB* dan *HSV*. Fitur tersebut dinormalisasi menggunakan *Z-transformation* untuk mengatasi perbedaan skala antarfitur sebelum pengujian algoritma *K-Nearest Neighbor (KNN)*, *Support Vector Machine (SVM)*, dan *Random Forest (RF)* dengan metode 10-fold Cross Validation. Hasil pengujian menunjukkan *KNN* memperoleh akurasi 85%, *SVM* 87%, dan *RF* 84%. *KNN* mengklasifikasikan 82 citra sakit dan 3 citra sehat dengan benar, *SVM* dengan 81 citra sakit dan 6 citra sehat, sedangkan *RF* dengan 77 citra sakit dan 7 citra sehat. Nilai AUC masing-masing sebesar 0,812, 0,833, dan 0,868. Berdasarkan *accuracy* sebagai kriteria utama, *SVM* dipilih sebagai algoritma terbaik dengan akurasi 87%. Hasil dari penelitian ini diharapkan menjadi referensi dalam memilih algoritma terbaik untuk mendeteksi kondisi daun pada tanaman lengkuas.

Kata Kunci: Deteksi Kondisi Daun; Lengkuas; Ekstraksi Fitur Warna; *RGB*; *HSV*; *Machine Learning*;

Abstract– A decline in the quality of galangal (*Alpinia galanga*) plants can be indicated by the appearance of symptoms on the leaves, which need to be identified early on. This study aims to compare machine learning algorithms for detecting the condition of galangal leaves based on *RGB* and *HSV* color features. The study was conducted at a galangal plantation in Cranggang Village using 100 leaf images. In the initial stage, leaf conditions were determined based on visual observation, resulting in 76 images of diseased leaves and 24 images of healthy leaves. Next, categorization was performed using a *rule-based* approach based on the diameter of spots detected computationally with a threshold of 0.5 cm, yielding a final result of 82 images categorized as diseased and 18 images categorized as healthy. The images were then processed into numerical features in the form of average *RGB* and *HSV* values. These features were normalized using *Z-transformation* to address scale differences between features before testing the *K-Nearest Neighbor (KNN)*, *Support Vector Machine (SVM)*, and *Random Forest (RF)* algorithms using the 10-fold cross-validation method. The test results showed that *KNN* achieved an accuracy of 85%, *SVM* 87%, and *RF* 84%. *KNN* correctly classified 82 diseased images and 3 healthy images; *SVM* classified 81 diseased images and 6 healthy images; and *RF* classified 77 diseased images and 7 healthy images. The AUC values were 0.812, 0.833, and 0.868, respectively. Based on accuracy as the primary criterion, *SVM* was selected as the best algorithm with an accuracy of 87%. The results of this study are expected to serve as a reference in selecting the best algorithm for detecting leaf conditions in galangal plants.

Keywords: Leaf Condition Detection; Galangal; Color Feature Extraction; *RGB*; *HSV*; *Machine Learning*;

1. PENDAHULUAN

Lengkuas atau laos (*Alpinia galanga*) merupakan tanaman rimpang dari famili *Zingiberaceae* yang banyak dimanfaatkan dalam masakan Indonesia serta pengobatan tradisional di Asia [1]. Selain berfungsi sebagai bumbu masak, lengkuas juga sering digunakan sebagai antiseptik, pencegah kanker, antialergi, antijamur, dan antioksidan [2]. Tingginya nilai guna tersebut menjadikan lengkuas sebagai salah satu tanaman yang banyak dibudidayakan di sektor pertanian.

Inovasi kreatif mulai diterapkan dalam pertanian melalui teknologi informasi salah satunya adalah *precision agriculture* atau pertanian presisi, yang memanfaatkan *GPS*, sensor, robot, dan perangkat lunak untuk meningkatkan efisiensi pengelolaan pertanian [3]. Sejalan dengan kemajuan tersebut, penelitian ini berupaya menggabungkan aspek pertanian dengan teknologi modern melalui sistem deteksi kondisi tanaman.

Penelitian dilakukan di Desa Cranggang, Kecamatan Dawe, Kabupaten Kudus, wilayah yang mayoritas penduduknya berprofesi sebagai petani. Tanaman lengkuas termasuk sebagai komoditas yang banyak masyarakat budidayakan selain tebu, jagung, ketela, dan kencur. Berdasarkan data Badan Pusat Statistik (BPS) di tahun 2023, Provinsi Jawa Tengah tercatat sebagai wilayah dengan produksi lengkuas tertinggi ketiga di Indonesia. Kondisi tersebut menunjukkan potensi yang besar dalam pengembangan tanaman lengkuas di provinsi ini, khususnya di Kabupaten Kudus. Oleh karena itu, tanaman lengkuas dipilih sebagai objek utama dalam penelitian ini.

Hasil observasi awal di kebun lengkuas Desa Cranggang yang dilakukan dengan penglihatan manual menghasilkan prediksi 76 daun sakit yang disertai dengan ciri bercak coklat dan kuning, kemudian 24 daun sehat dengan warna hijau merata. Gejala penyakit bercak daun ditunjukkan oleh munculnya bercak berwarna cokelat hingga kehitaman pada permukaan daun yang dapat meluas seiring perkembangan penyakit dan disertai perubahan warna kekuningan di sekitar bercak [4]. Gangguan pada daun berpotensi menurunkan kemampuan fotosintesis tanaman sehingga mempengaruhi pertumbuhan dan kualitas rimpang yang dihasilkan. Deteksi selama ini masih mengandalkan pengamatan visual yang dilakukan secara manual oleh petani, sehingga menyebabkan keterlambatan identifikasi yang berdampak langsung pada penyebaran penyakit [5].

Daun yang dikategorikan sebagai daun sakit pada tanaman lengkuas ditandai oleh perubahan warna serta munculnya pola bercak pada permukaan daun. Karakteristik visual tersebut menjadikan pendekatan pengolahan citra digital (*image processing*) relevan untuk digunakan karena mampu mengekstraksi informasi visual secara objektif dibandingkan pengamatan manual. Melalui ekstraksi fitur warna dan proses segmentasi area bercak daun, sistem berbasis komputer dapat membantu proses identifikasi kondisi tanaman secara otomatis dibandingkan hanya memprediksi menggunakan penglihatan manual.

Berbagai penelitian telah menerapkan *image processing* dan *machine learning* untuk deteksi kondisi tanaman. Setiawan et al. [6], memanfaatkan fitur hasil *image processing* untuk mengklasifikasikan spesies akuatik secara otomatis. Pendekatan tersebut mampu membedakan spesies berdasarkan karakteristik visual citra. Hatuwal et al. [7], membandingkan algoritma *KNN*, *SVM*, *Random Forest*, dan *CNN* pada klasifikasi penyakit daun. Temuan penelitian tersebut menunjukkan bahwa algoritma *traditional machine* tetap kompetitif pada dataset terbatas, sedangkan Khultsum et al. [8], menerapkan *Random Forest* untuk klasifikasi penyakit daun tomat menggunakan kombinasi fitur tertentu. Ramli et al. [9], memanfaatkan fitur warna *HSV* pada klasifikasi penyakit daun padi menggunakan *SVM*, sementara Kurniawan et al. [10], melakukan komparasi *KNN*, *SVM*, dan *Neural Network* pada klasifikasi penyakit daun jeruk. Penelitian lain oleh Waheed et al. [11], menggunakan pendekatan *Deep Learning* pada tanaman famili *Zingiberaceae* dengan dataset yang besar dan sumber daya komputasi yang tinggi.


Meskipun berbagai studi telah mengeksplorasi pengolahan citra untuk deteksi kondisi tanaman, terdapat beberapa celah signifikan yang menjadi dasar penelitian ini. Sebagian besar penelitian terdahulu berfokus pada tanaman komoditas umum, sehingga karakteristik visual pada daun lengkuas belum banyak dieksplorasi. Selain itu, penelitian yang membandingkan kinerja algoritma *KNN*, *SVM*, dan *Random Forest* pada klasifikasi kondisi daun lengkuas juga masih jarang ditemukan. Di sisi lain, pendekatan *Deep Learning* umumnya memerlukan dataset besar dan sumber daya komputasi tinggi sehingga kurang sesuai untuk implementasi pada skala pertanian lokal dengan keterbatasan perangkat keras. Kebaruan penelitian ini terletak pada penerapan deteksi kondisi daun lengkuas menggunakan citra yang diperoleh langsung dari kebun, dengan memanfaatkan fitur warna *RGB-HSV* sebagai fitur model serta membandingkan algoritma *KNN*, *SVM*, dan *Random Forest* untuk menentukan algoritma dengan performa terbaik.

Tujuan utama dari penelitian ini adalah mengembangkan sistem deteksi kondisi pada daun lengkuas berbasis *machine learning* dengan memanfaatkan ekstraksi fitur warna sebagai fitur klasifikasi. Luaran yang diharapkan adalah sebuah sistem deteksi otomatis yang mampu membantu petani atau pengelola kebun dalam mengidentifikasi kondisi sejak dini. Selain itu, hasil penelitian ini diharapkan dapat menjadi rujukan metodologis dalam pengembangan sistem deteksi kondisi tanaman berbasis pengolahan citra digital, baik dalam bentuk aplikasi monitoring berbasis desktop maupun sistem pendukung keputusan untuk optimasi kesehatan tanaman.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Prosedur pelaksanaan penelitian ini dirancang secara sistematis untuk memastikan validitas dan akurasi proses deteksi kondisi daun pada tanaman lengkuas. Tahapan penelitian dilakukan secara terintegrasi, yang dimulai dari pengumpulan data lapangan hingga penentuan model klasifikasi terbaik. Secara menyeluruh, alur diagram yang menggambarkan keterkaitan antar tahapan penelitian ini diperlihatkan dalam Gambar 1.



Gambar 1. Alur Tahapan Penelitian

Rangkaian urutan lengkap tahapan penelitian ini dijabarkan sebagai berikut :


2.1.1. Pengambilan Citra (Data Acquisition)

Tahap awal penelitian diawali dengan proses akuisisi data berupa pengambilan sampel citra daun tanaman lengkuas (*Alpinia galanga*) langsung dari lahan perkebunan di Desa Cranggang, Kecamatan Dawe, Kabupaten Kudus.

Berikut adalah detail pengambilan gambar :

Tabel 1. Detail Akuisisi Citra Daun Lengkuas

Kondisi Pencahayaan	Menggunakan pencahayaan alami matahari
Jarak Kamera	18,3 cm
Perangkat yang digunakan	SmartPhone Realme C11 2021



Gambar 2. Proses Pengambilan Daun Laos (Lengkuas) di Kebun Indrasta Mart Desa Cranggang



Gambar 3. Proses Akuisisi Pengambilan Citra Daun Laos (Lengkuas)

2.1.2. Pelabelan Manual Awal (Manual Labeling)

Sebelum dilakukan pemrosesan secara komputasional, 100 citra daun lengkuas dikelompokkan berdasarkan pengamatan visual. Daun dikategorikan sakit apabila menunjukkan bercak coklat atau kuning, sedangkan sehat apabila berwarna hijau relatif merata. Hasil pelabelan awal terdiri atas 76 daun sakit dan 24 daun sehat. Label awal tersebut hanya digunakan sebagai identifikasi awal kondisi daun berdasarkan pengamatan visual, kemudian dilakukan penentuan kategori akhir berdasarkan kriteria operasional diameter bercak yang diperoleh melalui proses pengolahan citra. Kategori tersebut tidak dimaksudkan sebagai diagnosis jenis penyakit atau identifikasi patogen.

Tabel 2. Hasil Pelabelan Manual Awal (Manual Labeling)

Kategori Daun	Ciri	Hasil Manual Labeling
Daun Sakit	Bercak Coklat/Kuning	76

Daun Sehat	Hijau Merata		24
TOTAL			100

Sumber : Kebun Lengkuas Indrasta Mart Desa Cranggang

2.1.3. Pengolahan Citra Digital (*Image Processing*)

a. Ekstraksi Fitur Warna RGB dan HSV

Ekstraksi fitur warna merupakan proses mengubah informasi warna pada citra menjadi nilai-nilai numerik [12], Citra daun berformat *.jpg* diinput ke dalam aplikasi pengolahan citra berbasis *Python*. Citra kemudian dikonversi dari format *BGR* ke *RGB* dan diseragamkan ukurannya menjadi 300×300 piksel. Selanjutnya, dihitung nilai rata-rata kanal Red (R), Green (G), dan Blue (B) sebagai fitur RGB. Perhitungan nilai rata-rata komponen Red, Green, dan Blue dilakukan menggunakan Persamaan (1)–(3).

$$R = \frac{R}{(R + G + B)} \quad (1)$$

$$G = \frac{G}{(R + G + B)} \quad (2)$$

$$B = \frac{B}{(R + G + B)} \quad (3)$$

Keterangan :

1. R = Red
2. G = Green
3. B = Blue

Nilai rata-rata kanal Red (R), Green (G), dan Blue (B) dihitung sebagai fitur RGB dengan rentang nilai 0–255. Nilai RGB kemudian dikonversi ke ruang warna HSV, dengan hasil H, S, dan V berada pada rentang 0–1. Persamaan konversi *RGB* ke *HSV* ditunjukkan pada persamaan (4)–(7), yang mengacu pada metode oleh Dede Wandu et.al. [13].

$$\theta = \cos^{-1} \left\{ \frac{\frac{1}{2} [(R - G) + (R - B)]}{[(R - G)^2 + (R - B)(G - B)]} \right\} \frac{1}{2} \quad (4)$$

$$H = \begin{cases} \theta & \text{Jika } B \leq G \\ 360 - \theta & \text{Jika } B > G \end{cases} \quad (5)$$

$$S = \begin{cases} \theta & \text{Jika } V = 0 \\ 1 - \frac{\min(r, g, b)}{v} & \text{Jika } V > 0 \end{cases} \quad (6)$$

$$V = \max(r, g, b) \quad (7)$$

Keterangan :

- H (*Hue*) = Nilai rona atau warna dasar (merah, hijau, biru) yang dihitung dari sudut pada ruang warna *HSV*.
- S (*Saturation*) = Tingkat kejenuhan warna, menunjukkan seberapa murni atau kuat warna dibandingkan dengan abu-abu.
- V (*Value / Brightness*) = Tingkat kecerahan warna, ditentukan oleh nilai maksimum dari komponen *RGB*.
- θ (*Theta*) = Sudut yang digunakan dalam perhitungan *Hue* berdasarkan selisih nilai *RGB*.
- $\cos^{-1}$ (*arccos*) = fungsi kebalikan cosinus untuk menghitung sudut θ dari nilai *RGB*

r, g, b
 $\min(r, g, b)$
 $\max(r, g, b)$

dan menentukan nilai *Hue* (H).

= Nilai intensitas masing-masing kanal warna merah (R), hijau (G), serta biru (B).

= Nilai minimum dari ketiga kanal warna *RGB*.

= Nilai maksimum dari ketiga kanal warna *RGB*.

Karena fitur *RGB* dan *HSV* memiliki rentang nilai yang berbeda, dilakukan normalisasi menggunakan metode *Z-transformation* pada *RapidMiner* sebelum proses klasifikasi. Normalisasi dilakukan terhadap seluruh atribut numerik (*R,G,B – H,S,V*) untuk menyamakan skala antarfitur. Nilai hasil normalisasi selanjutnya digunakan sebagai masukan pada proses training dan pengujian model *machine learning*.

b. Segmentasi Bercak Daun dan Penentuan Kategori Kondisi

Proses pengolahan citra dilanjutkan dengan segmentasi menggunakan *thresholding* pada ruang warna *HSV* untuk mendeteksi area bercak pada permukaan daun. Hasil segmentasi digunakan untuk mendeteksi dan menghitung diameter bercak dalam satuan piksel.



Gambar 4. Penerapan *reference scale* pada pengambilan citra daun


Untuk memperoleh ukuran fisik, digunakan *reference scale* berupa penggaris berukuran 1–30 cm yang ditempatkan pada bidang yang sama dengan daun saat pengambilan citra. Hasil pengukuran *reference scale* digunakan untuk memperoleh faktor konversi piksel ke centimeter.

Diameter bercak yang telah dikonversi ke satuan centimeter menggunakan *reference scale* kemudian digunakan sebagai kriteria operasional untuk menentukan kategori kondisi daun, dengan ambang 0,5 cm yang mengacu pada penelitian Sucianto et al. [14], yang menyatakan bahwa ukuran bercak sekitar 0,5 cm merupakan salah satu karakteristik tanaman yang terserang penyakit bercak daun. Berdasarkan acuan tersebut, penelitian ini menerapkan aturan penentuan kategori sebagai berikut :

- Jika diameter bercak yang terdeteksi lebih dari 0,5 cm, maka citra daun dikategorikan sebagai Daun Sakit.
- Jika diameter bercak yang terdeteksi kurang dari atau sama dengan 0,5 cm, atau tidak ditemukan bercak, maka citra daun dikategorikan sebagai Daun Sehat.

Diameter bercak hanya digunakan untuk menentukan kategori kondisi daun dan tidak digunakan sebagai fitur masukan pada proses klasifikasi. Fitur yang digunakan dalam proses klasifikasi adalah nilai rata rata *RGB* dan *HSV*. Kategori Daun Sakit dan Daun Sehat dalam penelitian ini ditetapkan berdasarkan kriteria operasional tersebut dan tidak diperoleh melalui diagnosis ahli atau konfirmasi patogen. Oleh karena itu, hasil klasifikasi dalam penelitian ini merepresentasikan klasifikasi kondisi visual daun berdasarkan karakteristik warna citra, bukan identifikasi jenis penyakit atau patogen tertentu.

2.1.4. Penyusunan Dataset Daun Lengkuas



Gambar 5. Alur Penyusunan Dataset Daun Lengkuas

Seluruh citra daun yang telah diproses melalui aplikasi *Python* kemudian diekstraksi fitur warnanya dengan menghitung nilai rata-rata *RGB* dan *HSV* serta ditentukan kategorinya berdasarkan aturan diameter bercak. Seluruh hasil ekstraksi selanjutnya disimpan dalam berkas berformat *.csv*. Dataset tersebut terdiri atas atribut rata-rata nilai *R, G, B, H, S, V*, serta label kondisi daun dan selanjutnya digunakan sebagai data masukan pada proses *machine learning*.

2.1.5. Pelatihan Model (*Model Training*)

Dataset numerik yang telah terbentuk kemudian diinput ke dalam tahap pelatihan (*training*) *machine learning*. Pada tahapan ini dilakukan pelatihan model menggunakan tiga algoritma klasifikasi yang berbeda, yaitu :

- K-Nearest Neighbor (KNN)* berbasis kedekatan jarak antar data pada ruang fitur, yang pada penelitian ini menggunakan *Weighted 10-Nearest Neighbor*, Parameter ($K = 10$). Pemilihan nilai $K = 10$ juga digunakan oleh Fathoni et al. [15], dalam klasifikasi penyakit daun anggur dengan menguji nilai K dari 1 hingga 10 dan memperoleh akurasi tertinggi sebesar 88,6% pada nilai $K = 10$.
- Support Vector Machine (SVM)* berbasis pemisahan ruang fitur optimal menggunakan *hyperplane*, yang pada penelitian ini menggunakan tipe C-SVC dengan kernel *Radial Basis Function (RBF)*, sedangkan parameter C dan γ menggunakan nilai bawaan (*default*) dari Altair Studio. Penerapan kernel *RBF* pada klasifikasi penyakit daun juga dilakukan oleh Maulidia et al. [16], dengan memanfaatkan fitur warna *HSV* dan tekstur *GLCM* dan memperoleh akurasi terbaik sebesar 94,21%.
- Random Forest (RF)* berbasis metode *ensemble* pohon keputusan (*decision tree*), yang pada penelitian ini dengan menggunakan 100 pohon keputusan (*number of trees = 100*), kriteria pemilihan atribut menggunakan *Gain Ratio*, dan kedalaman maksimum pohon (*maximal depth*) sebesar 10. Penggunaan 100 pohon keputusan juga diterapkan oleh Wahyuningtyas et al. [17], dalam identifikasi penyakit pada daun kopi dengan menggunakan parameter *n-estimators* sebesar 100 dan memperoleh akurasi terbaik sebesar 95,83%.

2.1.6. Evaluasi Multialgoritma

Kinerja dari ketiga algoritma *machine learning* yang telah dilatih kemudian dievaluasi menggunakan skema *10-Fold Cross Validation*. Metrik performa dihitung berdasarkan *confusion matrix*, yang meliputi nilai *accuracy*, *precision*, *recall*, serta *Area Under Curve (AUC)* untuk mengukur kemampuan model dalam membedakan kelas daun sehat dan daun sakit. Hasil evaluasi dari ketiga algoritma kemudian dibandingkan secara setara (*apple-to-apple*) berdasarkan nilai yang diperoleh dari *confusion matrix*.

$$\text{Precision} : \frac{TP}{TP + FP} \quad (8)$$

$$\text{Recall} : \frac{TP}{TP + FN} \quad (9)$$

$$\text{Accuracy} : \frac{TP+TN}{TP+TN+FP+FN} \quad (10)$$

Dimana :

- *TP (True Positive)* : Banyaknya data berlabel positif yang sukses diklasifikasi dengan benar selaku positif.
- *TN (True Negative)* : Banyaknya data berlabel negatif yang sukses dikenali secara tepat selaku negatif.
- *FP (False Positive)* : Banyaknya data berlabel negatif yang keliru diklasifikasi selaku positif.
- *FN (False Negative)* : Banyaknya data berlabel positif yang salah diklasifikasi selaku negatif.

2.1.7. Pemilihan Algoritma Terbaik

Pemilihan algoritma terbaik dilakukan berdasarkan hasil evaluasi kinerja dengan *accuracy* sebagai kriteria utama, sedangkan metrik lainnya digunakan sebagai pendukung. Algoritma dengan *accuracy* tertinggi dipilih sebagai model utama dalam sistem deteksi kondisi daun lengkuas.

3. HASIL DAN PEMBAHASAN

3.1 Implementasi hasil pindai *Image Processing* (Pengolahan Citra Digital)


Citra daun lengkuas hasil pemindaian diolah menggunakan aplikasi berbasis *Python* sehingga diperoleh fitur berupa hasil segmentasi bercak, nilai rata-rata *RGB*, nilai rata-rata *HSV*, serta diameter bercak. Fitur-fitur tersebut kemudian digunakan sebagai data input pada proses klasifikasi *machine learning*, sedangkan kategori kondisi daun (sehat atau sakit) ditentukan berdasarkan kriteria diameter bercak menggunakan pendekatan berbasis aturan (*rule-based*).



Gambar 6 . Tampilan Aplikasi pengolahan citra digital (Sistem Deteksi Kondisi Daun Laos) berbasis *python*

3.1.1. Ekstraksi Fitur Warna RGB

Ekstraksi fitur warna RGB dilakukan untuk memperoleh nilai rata-rata Red, Green, dan Blue. Pada tahap ini, peneliti menggunakan 1 sample daun dari 100 citra daun untuk dijadikan contoh.




Gambar 7. Hasil fitur aplikasi (Sistem Deteksi Kondisi Daun Laos) berbasis *python* yang menampilkan nilai rata-rata *RGB* pada salah satu daun lengkuas

Tabel 3. Nilai rata-rata *RGB* pada salah satu daun lengkuas yang dihasilkan dari aplikasi

Nama Citra	R(red)	G(green)	B(blue)
Daun006	97.75	127.31	66.85

3.1.2. Ekstraksi Fitur Warna HSV

Ekstraksi fitur warna *HSV* dilakukan untuk memperoleh nilai rata-rata Hue, Saturation, dan Value. Pada tahap ini, peneliti menggunakan 1 sample daun dari 100 citra daun untuk dijadikan contoh.



Gambar 8. Hasil fitur aplikasi (Sistem Deteksi Kondisi Daun Laos) berbasis *python* yang menampilkan nilai rata-rata *HSV* pada salah satu daun lengkuas

Tabel 4. Nilai rata-rata *HSV* pada salah satu daun lengkuas yang dihasilkan dari aplikasi

Nama Citra	H(hue)	S(saturation)	V(value)
Daun006	0.248	0.475	0.499

3.1.3. Segmentasi Bercak dan Penentuan Kategori Kondisi

Pada tahap segmentasi bercak, aplikasi mendeteksi area bercak pada bagian daun berdasarkan karakteristik warna, kemudian mengukur diameter bercak dalam satuan piksel. Agar hasil pengukuran tersebut dapat dinyatakan dalam satuan centimeter (cm), digunakan *reference scale* yang terdapat pada citra. Pada pengambilan citra, jarak antara tanda 1 cm dan 30 cm pada penggaris adalah 29 cm.



Gambar 9. Hasil fitur aplikasi (Sistem Deteksi Kondisi Daun Laos) berbasis *python* yang menampilkan hasil diameter bercak pada salah satu daun lengkuas

Tabel 5. Hasil ukuran bercak pada salah satu daun lengkuas menggunakan Aplikasi (Sistem Deteksi Kondisi Daun Laos) berbasis *python*

Nama Citra	Diameter Bercak
Daun 006	1.43 cm

Berdasarkan pengukuran pada citra asli, jarak kedua titik tersebut diperoleh sebesar 1.269,38 piksel. Nilai tersebut kemudian digunakan untuk menentukan faktor konversi antara piksel dan ukuran sebenarnya. Perhitungannya adalah:

$$1.269,38 \text{ piksel} \div 29 \text{ cm} = 43,77 \text{ piksel/cm}$$

Dengan demikian, diperoleh faktor konversi sebesar 43,77 piksel/cm. Artinya, setiap 1 cm pada objek dalam citra direpresentasikan oleh sekitar 43,77 piksel. Nilai inilah yang kemudian digunakan untuk mengubah hasil pengukuran diameter bercak dari satuan piksel menjadi centimeter. Pada citra daun 006, aplikasi menghasilkan diameter bercak sebesar 1,43 cm. Untuk memperlihatkan hubungan antara hasil pengukuran tersebut dengan faktor konversi yang diperoleh, diameter 1,43 cm memiliki nilai piksel ekuivalen sebesar :

$$1,43 \text{ cm} \times 43,77 \text{ piksel/cm} = 62,59 \text{ piksel}$$

Nilai tersebut dapat dikonversi kembali ke centimeter untuk melakukan pengecekan :


$$62,59 \text{ piksel} \div 43,77 \text{ piksel/cm} = 1,43 \text{ cm}$$

Dengan demikian, hasil pengukuran diameter bercak sebesar 1,43 cm sesuai dengan faktor *reference scale* sebesar 43,77 piksel/cm yang diperoleh dari citra. Nilai diameter tersebut selanjutnya digunakan untuk menentukan status kondisi daun berdasarkan aturan *rule-based*, yaitu diameter bercak lebih dari 0,5 cm dikategorikan sebagai daun sakit, sedangkan

diameter kurang dari atau sama dengan 0,5 cm atau tidak ditemukan bercak dikategorikan sebagai daun sehat. Pada citra daun 006, diameter bercak sebesar 1,43 cm lebih besar daripada ambang batas 0,5 cm. Oleh karena itu, berdasarkan aturan yang diterapkan, citra daun 006 dikategorikan sebagai daun sakit.

3.2 Hasil Deteksi

Hasil deteksi pada aplikasi menghasilkan fitur numerik berupa nilai rata-rata *RGB*, nilai rata-rata *HSV*, diameter bercak, serta label kondisi daun (sehat atau sakit). Seluruh hasil tersebut kemudian disimpan dalam bentuk dataset yang digunakan pada tahap klasifikasi *machine learning*.



Gambar 10. Hasil fitur aplikasi (Sistem Deteksi Kondisi Daun Laos) berbasis *python* yang menampilkan hasil deteksi pada salah satu daun lengkuas

Tabel 6. Hasil Deteksi pada salah satu daun lengkuas di aplikasi *python*

Nama Citra	R	G	B	H	S	V	Diameter Bercak	Kondisi Daun
Daun006	97.75	127.31	66.85	0.248	0.475	0.499	1.43 cm	SAKIT

Seluruh hasil konversi dan pelabelan tersebut kemudian disimpan secara otomatis dalam bentuk dataset dengan format *.csv* untuk digunakan pada tahap klasifikasi menggunakan *machine learning*.

Tabel 7. Dataset Keseluruhan (Daun Lengkuas)

Nama Citra	R	G	B	H	S	V	Label
Daun001	49.39	78.69	46.04	0.316	0.415	0.309	SEHAT
Daun002	96.16	111.23	50.13	0.208	0.549	0.436	SAKIT
-	-	-	-	-	-	-	-
-	-	-	-	-	-	-	-
Daun099	82.76	114.92	48.06	0.247	0.582	0.451	SAKIT
Daun100	94.82	128.3	54.5	0.242	0.575	0.503	SAKIT

Tabel 8. Keseluruhan Rata-rata *RGB* dan *HSV* dari 100 citra daun lengkuas berdasarkan kondisi

Kondisi Daun	Jumlah Data	R	G	B	H	S	V
SEHAT	18	70.65	98.83	52.10	0.279	0.472	0.388
SAKIT	82	84.97	111.74	55.75	0.249	0.499	0.438

Pada tahap awal, pelabelan manual terhadap 100 citra daun menghasilkan 76 citra daun sakit dan 24 citra daun sehat. Selanjutnya, dilakukan penentuan kategori kondisi menggunakan pendekatan berbasis aturan (*rule-based*). Hal ini dilakukan untuk membandingkan hasil pelabelan manual berdasarkan pengamatan visual dengan hasil pelabelan secara komputasional menggunakan *Python*. Pelabelan secara komputasional digunakan sebagai dasar penetapan label akhir karena penentuan kondisi daun dilakukan berdasarkan kriteria yang terukur, yaitu diameter bercak yang terdeteksi pada citra. Dengan demikian, penentuan label dapat dilakukan secara lebih konsisten berdasarkan aturan (*rule-based*) yang telah ditetapkan. Setelah penentuan kategori kondisi secara komputasional dilakukan, diperoleh hasil akhir sebanyak 82 citra daun sakit dan 18

citra daun sehat. Berdasarkan dataset pada Tabel 7, diperoleh nilai rata-rata *RGB* dan *HSV* dari 100 citra daun pada kategori sakit dan sehat. Hasil tersebut menunjukkan adanya perbedaan karakteristik warna antara kedua kategori kondisi daun sebagaimana disajikan pada Tabel 8. Hasil penentuan kategori kondisi daun tersebut selanjutnya digunakan sebagai label akhir dalam proses klasifikasi *machine learning*.

3.3 Pengujian Algoritma Machine Learning


Proses selanjutnya adalah pengujian model klasifikasi, yang dalam penelitian ini dilakukan menggunakan tiga algoritma *machine learning*, yaitu *K-Nearest Neighbor (KNN)*, *Random Forest*, dan *Support Vector Machine (SVM)*. Pada penelitian ini digunakan 100 data citra daun lengkuas yang terdiri atas dua kelas, yaitu daun sakit dan daun sehat. Evaluasi model dilakukan menggunakan metode *10-fold cross-validation*, dengan sembilan *fold* sebagai data pelatihan dan satu *fold* sebagai data pengujian secara bergantian selama 10 iterasi. Kinerja model dievaluasi berdasarkan nilai *accuracy*, *precision*, *recall*, dan *AUC*. Perbandingan lengkap performa ketiga algoritma diperlihatkan dalam Tabel 9.

Tabel 9. Hasil Pengujian Algoritma Klasifikasi
(Keterangan: *Precision* dan *recall* dihitung dengan kelas SAKIT sebagai *positive class*).

Algoritma	Accuracy	Precision	Recall	AUC
KNN	85%	84.54%	100%	0.812
SVM	87%	87.10%	98.78%	0.833
RF	84%	87.50%	93.90%	0.868

Berdasarkan Tabel 9, *SVM* memperoleh *accuracy* tertinggi sebesar 87%, diikuti *KNN* sebesar 85% dan *RF* sebesar 84%. *KNN* memperoleh *recall* tertinggi sebesar 100%, sedangkan *RF* memperoleh nilai *precision* dan *AUC* tertinggi masing-masing sebesar 87,50% dan 0,868. Berdasarkan *accuracy* sebagai kriteria utama, *SVM* dipilih sebagai algoritma terbaik dalam klasifikasi kondisi daun lengkuas.

3.6.1. K-Nearest Neighbor (KNN)




Gambar 11. Hasil Pengujian Algoritma KNN

Sebelum proses klasifikasi, seluruh fitur *RGB* dan *HSV* telah dinormalisasi menggunakan *Z-transformation* untuk menyamakan skala antarfitur. Berdasarkan *confusion matrix* pada Gambar 11, algoritma *K-Nearest Neighbor (KNN)* dengan parameter *K* = 10 dan pendekatan *weighted nearest neighbor* mampu mengklasifikasikan 82 citra SAKIT dan 3 citra SEHAT dengan benar. Sebanyak 15 citra SEHAT diklasifikasikan sebagai SAKIT, sedangkan tidak terdapat citra SAKIT yang diklasifikasikan sebagai SEHAT. Dengan SAKIT sebagai *positive class*, diperoleh *precision* sebesar 84,54%, *recall* sebesar 100%. Dengan demikian, diperoleh 85 prediksi benar dari 100 citra dan *accuracy* sebesar 85%. Hasil tersebut menunjukkan bahwa *KNN* mampu mengenali seluruh citra pada kelas SAKIT, tetapi masih memiliki keterbatasan dalam mengenali kelas SEHAT.

Nilai *accuracy* dihitung menggunakan persamaan berikut :

$$\begin{aligned}
 \text{SAKIT} &= 82 \text{ benar, } 0 \text{ salah} \\
 \text{SEHAT} &= 3 \text{ benar, } 15 \text{ salah} \\
 \text{Prediksi benar} &= 82 + 3 = 85 \\
 \text{Total data} &= 82 + 0 + 3 + 15 = 100 \\
 \text{Accuracy} &= \frac{\text{jumlah prediksi benar}}{\text{total data}} \times 100\% \\
 &= \frac{85}{100} \times 100\%
 \end{aligned}$$

$$\begin{aligned} &= 85\% \\ \text{Precision} &= 82/(82+15) = 84,54\% \\ \text{Recall} &= 82/(82+0) = 100\% \end{aligned}$$



Gambar 12. Nilai AUC pada pengujian KNN

Performa model juga dievaluasi menggunakan kurva *Receiver Operating Characteristic (ROC)* seperti yang ditunjukkan pada Gambar 12. Berdasarkan hasil pengujian, algoritma *K-Nearest Neighbor (KNN)* memperoleh nilai *Area Under Curve (AUC)* sebesar 0,812. Nilai tersebut menunjukkan kemampuan model dalam membedakan kelas daun sehat dan daun sakit berdasarkan fitur warna *RGB* dan *HSV* pada dataset yang digunakan.

3.6.2. Random Forest

accuracy: 84.00% +/- 9.66% (micro average: 84.00%)

	true SEHAT	true SAKIT	class precision
pred. SEHAT	7	5	58.33%
pred. SAKIT	11	77	87.50%
class recall	38.89%	93.90%	

Parameters

Performance (Performance (Binominal Classification))

☒ manually set positive class

positive class: SAKIT

Parameters

Normalize


method: Z-transformation

Gambar 13. Hasil Pengujian Algoritma *Random Forest*

Sebelum proses klasifikasi, seluruh fitur *RGB* dan *HSV* telah dinormalisasi menggunakan *Z-transformation* untuk menyamakan skala antarfitur. Sesuai confusion matrix dalam Gambar 13, algoritma *Random Forest* mampu mengklasifikasikan 77 citra SAKIT dan 7 citra SEHAT dengan benar. Sebanyak 5 citra SEHAT diklasifikasikan sebagai SAKIT, sedangkan 11 citra SAKIT diklasifikasikan sebagai SEHAT. Dengan SAKIT sebagai *positive class*, diperoleh *precision* sebesar 87,50% dan *recall* sebesar 93,90%. Dengan demikian, diperoleh 84 prediksi benar dari 100 citra dan *accuracy* sebesar 84%. Nilai akurasi dihitung menggunakan persamaan berikut :

$$\begin{aligned} \text{SAKIT} &= 77 \text{ benar, } 11 \text{ salah} \\ \text{SEHAT} &= 7 \text{ benar, } 5 \text{ salah} \\ \text{Prediksi benar} &= 77 + 7 = 84 \\ \text{Total data} &= 77 + 11 + 7 + 5 = 100 \\ \text{Accuracy} &= \frac{\text{jumlah prediksi benar}}{\text{total data}} \times 100\% \\ &= \frac{84}{100} \times 100\% \\ &= 84\% \\ \text{Precision} &= \frac{77}{77 + 11} = 87,50\% \\ \text{Recall} &= \frac{77}{77 + 5} = 93,90\% \end{aligned}$$

Dari hasil perhitungan itu, algoritma *Random Forest* mendapatkan akurasi dengan nilai 84%. *Random Forest* bekerja melalui hasil beberapa pohon keputusan, selanjutnya mengombinasikan hasil prediksi dari tiap pohon dengan sistem voting dalam menetapkan kelas akhir. Pendekatan ensemble tersebut membuat model lebih stabil serta mampu menangkap pola yang lebih kompleks pada data citra daun berdasarkan fitur warna *RGB* dan *HSV* yang digunakan.



Gambar 14. Nilai AUC pada pengujian *Random Forest*

Performa model dievaluasi juga mempergunakan kurva *Receiver Operating Characteristic (ROC)* seperti yang ditunjukkan pada Gambar 14. Sesuai hasil uji, algoritma *Random Forest* memperoleh *Area Under Curve (AUC)* sejumlah 0,868. Nilai tersebut merupakan AUC tertinggi dari ketiga algoritma, yang menunjukkan kemampuan diskriminatif *RF* yang lebih tinggi berdasarkan nilai AUC.

3.6.3. *Support Vector Machine (SVM)*

accuracy: 87.00% +/- 6.75% (micro average: 87.00%)

	true SEHAT	true SAKIT	class precision
pred SEHAT	6	1	85.71%
pred SAKIT	12	81	87.10%
class recall	33.33%	98.78%	

Parameters

Performance (Performance (Binominal Classification))

☒ manually set positive class

positive class: SAKIT

Parameters

Normalize

method: Z-transformation

Gambar 15. Hasil Pengujian Algoritma *SVM*

Sebelum proses klasifikasi, seluruh fitur *RGB* dan *HSV* telah dinormalisasi menggunakan *Z-transformation* untuk menyamakan skala antarfitur. Sesuai confusion matrix pada Gambar 15, algoritma *Support Vector Machine (SVM)* mampu mengklasifikasikan 81 citra SAKIT dan 6 citra SEHAT dengan benar. Sebanyak 1 citra SEHAT diklasifikasikan sebagai SAKIT, sedangkan 12 citra SAKIT diklasifikasikan sebagai SEHAT. Dengan SAKIT sebagai *positive class*, diperoleh nilai *precision* sebesar 87,10% dan *recall* sebesar 98,78%. Dengan demikian, diperoleh 87 prediksi benar dari 100 citra dan *accuracy* sebesar 87%. Nilai akurasi dihitung menggunakan persamaan berikut :

$$\begin{aligned}
 \text{SAKIT} &= 81 \text{ benar, } 12 \text{ salah} \\
 \text{SEHAT} &= 6 \text{ benar, } 1 \text{ salah} \\
 \text{Prediksi benar} &= 81 + 6 = 87 \\
 \text{Total data} &= 81 + 12 + 6 + 1 = 100 \\
 \text{Accuracy} &= \frac{\text{jumlah prediksi benar}}{\text{total data}} \times 100\% \\
 &= \frac{87}{100} \times 100\% \\
 &= 87\% \\
 \text{Precision} &= \frac{81}{81 + 12} = 87,10\% \\
 \text{Recall} &= \frac{81}{81 + 1} = 98,78\%
 \end{aligned}$$

Hasil dari uji algoritma *Support Vector Machine (SVM)* memperlihatkan akurasi dengan nilai 87%. Hasil tersebut menandakan bahwasanya model bisa mengklasifikasikan sebagian besar data uji secara cukup baik dalam membedakan daun sehat dan daun sakit. Performa yang diperoleh memperlihatkan *SVM* mampu memanfaatkan fitur warna *RGB* serta *HSV* yang dipergunakan dalam penelitian ini untuk membentuk batas pemisah antar kelas pada ruang fitur. Pada pengujian *SVM* ini, dipergunakan kernel *Radial Basis Function (RBF)* untuk mengatasi kemungkinan pemisahan data yang bersifat non-linear. Kernel *RBF* dipilih karena mampu membentuk batas keputusan yang lebih fleksibel pada ruang fitur, sehingga model dapat menangkap pola distribusi warna yang lebih kompleks pada citra daun.

Kernel Model


```
Total number of Support Vectors: 38
Bias (offset): 0.095

w[R(red)] = -9.706
w[G(green)] = -10.267
w[B(blue)] = 1.733
w[H(hue)] = 13.430
w[S(saturation)] = -10.596
w[V(value)] = -10.323

number of classes: 2
number of support vectors for class SEHAT: 18
number of support vectors for class SAKIT: 20
```

Gambar 16. Kernel RBF pada SVM

Berdasarkan hasil kernel model SVM pada Gambar 16, jumlah total support vector yang dipergunakan pada pembentukan hyperplane yaitu sejumlah 38 support vector, yang meliputi 20 data kelas daun sakit serta 18 data kelas daun sehat, dengan nilai bias (*offset*) sebesar 0,095. Model SVM menggunakan *kernel Radial Basis Function (RBF)* untuk membentuk batas keputusan non-linear dalam proses klasifikasi.



Gambar 17. Nilai AUC pada pengujian SVM

Performa model juga dievaluasi menggunakan kurva ROC (Gambar 17). Hasil pengujian menunjukkan algoritma SVM memperoleh nilai AUC sebesar 0,833 dengan SAKIT sebagai *positive class*. Nilai tersebut lebih tinggi dibandingkan KNN sebesar 0,812, tetapi lebih rendah dibandingkan RF sebesar 0,868.

Dari hasil pengujian ketiga algoritma, SVM dipilih sebagai algoritma terbaik dalam mendeteksi kondisi daun lengkuas pada penelitian ini. Hal ini dikarenakan SVM memperoleh nilai *accuracy* tertinggi sebesar 87%, dibandingkan KNN sebesar 85% dan *Random Forest* sebesar 84%. SVM juga menghasilkan nilai *precision* sebesar 87,10%, dan *recall* sebesar 98,78% yang menunjukkan kemampuan model dalam mengklasifikasikan data berdasarkan fitur warna RGB dan HSV. Penggunaan *kernel Radial Basis Function (RBF)* memungkinkan SVM membentuk batas keputusan non-linear sehingga dapat menangkap pola yang lebih kompleks pada ruang fitur. Dengan mempertimbangkan *accuracy* sebagai kriteria utama pemilihan model, SVM dinilai sebagai algoritma dengan performa terbaik dalam klasifikasi kondisi daun sehat dan sakit pada dataset yang dipergunakan.

Temuan yang didapat juga sejalan pada penelitian sebelumnya dari Gusviani et al. [18], yang menerapkan *Support Vector Machine (SVM)* untuk klasifikasi penyakit daun singkong berbasis citra digital. Hasil penelitian tersebut menunjukkan bahwa SVM memperoleh akurasi sebesar 88% dan memberikan kinerja yang lebih tinggi dibandingkan CNN pada dataset yang digunakan. Hal ini menunjukkan bahwa SVM cukup efektif dalam memanfaatkan fitur visual citra untuk membedakan kondisi daun berdasarkan karakteristik yang digunakan.

Di sisi lain, sebagian besar penelitian terdahulu umumnya menggunakan dataset sekunder atau citra yang diperoleh dari sumber web daring. Burhanuddin et.al [19], misalnya, menggunakan dataset *Classification of Rice Diseases Using Leaf Images* yang diperoleh dari Kaggle untuk melakukan klasifikasi penyakit padi berdasarkan citra daun. Berbeda dengan pendekatan tersebut, penelitian ini menggunakan citra daun lengkuas yang diperoleh langsung dari kebun lengkuas dengan kondisi lingkungan alami, sehingga sistem diuji pada variasi warna dan pola bercak yang lebih realistis. Keunikan penelitian ini terletak pada integrasi segmentasi bercak berbasis ruang warna HSV dengan ekstraksi fitur warna RGB dari citra lapangan nyata, serta evaluasi kinerja tiga algoritma *machine learning*. Pendekatan ini menunjukkan bahwa algoritma SVM mampu memberikan performa terbaik dalam mengenali pola visual daun lengkuas, sehingga sistem yang dikembangkan memiliki potensi penerapan yang lebih adaptif pada kondisi perkebunan nyata.

4. KESIMPULAN

Sesuai hasil dari pelaksanaan penelitian, sistem deteksi kondisi daun pada tanaman lengkuas menggunakan fitur warna *RGB* dan *HSV* serta algoritma *machine learning* berhasil dikembangkan. Hasil pengujian menggunakan 10-fold *cross-validation* menunjukkan bahwa algoritma *K-Nearest Neighbor (KNN)* memperoleh *accuracy* sebesar 85% dengan AUC 0,812, *Support Vector Machine (SVM)* memperoleh *accuracy* sebesar 87% dengan AUC 0,833, sedangkan *Random Forest (RF)* memperoleh *accuracy* sebesar 84% dengan AUC 0,868. Berdasarkan *accuracy* sebagai kriteria utama, *SVM* dipilih sebagai algoritma terbaik dengan *accuracy* paling tinggi sebesar 87%, dengan *precision* 87,10%, *recall* 98,78%, dan AUC 0,833. Hasil tersebut menunjukkan bahwa *SVM* mampu mengklasifikasikan kondisi visual daun sehat dan sakit berdasarkan fitur warna *RGB* dan *HSV* pada dataset yang digunakan. Dengan demikian, *SVM* dapat dianggap sebagai algoritma terbaik dalam mendeteksi kondisi daun pada tanaman lengkuas berdasarkan fitur warna *RGB* serta *HSV* dalam penelitian ini. Meskipun demikian, penelitian ini memiliki keterbatasan karena penentuan kategori kondisi daun menggunakan diameter bercak sebagai kriteria operasional, sehingga hasil penelitian merepresentasikan klasifikasi kondisi visual daun dan bukan identifikasi jenis penyakit atau patogen tertentu. Selain itu, penggunaan 100 citra dari satu lokasi membatasi generalisasi hasil pada kondisi lingkungan yang lebih beragam. Penelitian selanjutnya disarankan menggunakan diagnosis ahli atau konfirmasi patogen sebagai dasar penentuan label, serta menggunakan dataset yang lebih besar dan beragam untuk meningkatkan kemampuan klasifikasi dan generalisasi model. Hasil penelitian ini diharapkan dapat menjadi referensi dalam pemilihan algoritma *machine learning* untuk mendeteksi kondisi daun lengkuas berdasarkan fitur warna *RGB* dan *HSV*, serta mendukung penerapan deteksi dini kondisi tanaman di perkebunan nyata.

REFERENCES

- [1] R. Nafis, A. Oktaviani, D. Febrianti, P. Maulida, and A. Sukarso, "PENGOLAHAN LENGKUAS MENJADI LENGKUAS BUBUK UNTUK OPTIMALKAN PEMANFAATAN LENGKUAS DI DESA PENIMBUNG, KEC. GUNUNG SARI, LOMBOK BARAT," *J. Wicara Desa*, vol. 1, no. 2, pp. 190–199, Apr. 2023, doi: 10.29303/wicara.v1i2.2407.
- [2] J. Ando, M. Rizal, I. Purnama, F. Pertanian, and J. Agroteknologi, "INTERAKSI PEMBERIAN PUPUK KANDANG SAPI DAN MULSA ORGANIK TERHADAP PERTUMBUHAN PRODUKSI TANAMAN LENGKUAS MERAH (*Alpinia purpurata* K. Schum)," *J. Agrotela*, vol. 3, no. 1, pp. 41–47, 2023.
- [3] H. Kuswanto and D. Panggabean, "FAKTOR PENENTU ADOPSI TEKNOLOGI PRECISION AGRICULTURE PADA PERKEBUNAN KELAPA SAWIT DI KECAMATAN PENAJAM KABUPATEN PENAJAM PASER UTARA," *Pros. Semin. Nas. Sains dan Teknol. Seri III Fak. Sains dan Teknol.*, vol. 2, no. 1, 2025.
- [4] I. G. R. Mahendra, J. S. Maharani, and F. Rochman, "PENGARUH APLIKASI *Trichoderma* sp. TERHADAP INTENSITAS PENYAKIT BERCAK DAUNDAN KARAT DAUN PADA BEBERAPA VARIETAS KACANG TANAH," *AGROSCRIPT J. Appl. Agric. Sci.*, vol. 7, no. 2, pp. 126–136, 2025, doi: 10.36423/agroscript.v7i2.2226.
- [5] D. E. Arisandi and A. Rofiqi, "Sistem Monitoring Gambar Daun Mangga Untuk Deteksi Awal Penyakit," *Karapan Netw. J.*, vol. I, No.1, 2025, doi: 10.20473/KNJ.X.X.84-96.
- [6] A. Setiawan, A. W. Wibowo, P. Setiaji, W. A. Triyanto, and M. Arifin, "Classification of Aquatic Species in Cultivation Ponds via Image Processing and Machine Learning," *Int. J. Artif. Intell. Sci. e-ISSN*, vol. 2, no. 1, pp. 3064–2728, 2025, doi: 10.63158/IJAIS.v2i1.9.
- [7] B. K. Hatuwal, A. Shakya, and B. Joshi, "Plant Leaf Disease Recognition Using Random Forest, KNN, SVM and CNN," *POLIBITS*, vol. 62, pp. 13–19, 2020, doi: 10.17562/PB-62-2.
- [8] U. Khultsum and A. Subekti, "Penerapan Algoritma Random Forest dengan Kombinasi Ekstraksi Fitur Untuk Klasifikasi Penyakit Daun Tomat," *J. MEDIA Inform. BUDIDARMA*, vol. 5, no. 1, p. 186, Jan. 2021, doi: 10.30865/mib.v5i1.2624.
- [9] R. Ramli and A. A. Riadi, "Classification of Rice Leaf Diseases Using Support Vector Machine with HSV and GLCM-Based Feature Extraction," *J. Appl. Informatics Comput.*, vol. 9, no. 5, p. 2329, 2025, [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [10] D. Kurniawan, D. Triyanto, M. Wahyudi, L. Pujiastuti, and I. Chaidir, "KOMPARASI ALGORITMA K-NEAREST NEIGHBOR, SUPPORT VECTOR MACHINE, DAN NEURAL NETWORK UNTUK KLASIFIKASI PENYAKIT DAUN JERUK," *J. TEKNOINFO*, vol. 19, no. 2, pp. 288–294, Jul. 2025, [Online]. Available: <https://publikasi.teknokrat.ac.id/index.php/teknoinfo/index>
- [11] H. Waheed, N. Zafar, W. Akram, A. Manzoor, A. Gani, and S. U. Islam, "Deep Learning Based Disease, Pest Pattern and Nutritional Deficiency Detection System for 'Zingiberaceae' Crop," *Agric.*, vol. 12, no. 6, Jun. 2022, doi: 10.3390/agriculture12060742.
- [12] M. N. Abdullah *et al.*, "Colour Features Extraction Techniques and Approaches for Content-Based Image Retrieval (CBIR) System," *J. Mater. Sci. Chem. Eng.*, vol. 09, no. 07, pp. 29–34, 2021, doi: 10.4236/msce.2021.97003.
- [13] D. Wandu, F. Fauziah, and N. Hayati, "Deteksi Kelayuan Pada Bunga Mawar dengan Metode Transformasi Ruang Warna Hue Saturation Intensity (HSI) dan Hue Saturation Value (HSV)," *J. MEDIA Inform. BUDIDARMA*, vol. 5, no. 1, p. 308, Jan. 2021, doi: 10.30865/mib.v5i1.2562.
- [14] E. T. Suciando and D. M. Abbas, "Jenis, Frekuensi Kemunculan, dan Persentase Penyakit Cendawan pada Tanaman Sayuran," *Maj. Ilm. Biol. Biosf. A Sci. J.*, vol. 36, no. 1, pp. 1–9, Jan. 2019, doi: 10.20884/1.mib.2019.36.1.719.
- [15] F. Mahrus Fathoni, C. Aji Putra, A. Lina Nurlaili, F. Ilmu Komputer, U. Pembangunan Nasional, and J. Timur, "KLASIFIKASI PENYAKIT DAUN ANGGUR MENGGUNAKAN METODE K-NEAREST NEIGHBOR BERDASARKAN GRAY LEVEL CO-OCCURRENCE MATRIX," *Biner J. Ilm. Inform. dan Komput.*, vol. 3, no. 1, pp. 8–15, 2024, [Online]. Available: <https://ojs.unsiq.ac.id/index.php/biner>
- [16] U. Maulidia, F. Wajidi, and N. Arifin, "Klasifikasi Penyakit Pada Daun Tanaman Kubis Menggunakan Metode



- Support Vector Machine (SVM) Berdasarkan Warna Dan Tekstur,” *Techno.Com*, vol. 24, no. 3, pp. 1053–1066, Aug. 2025, doi: 10.62411/tc.v24i3.13748.
- [17] B. Wahyuningtyas, I. I. Tritoasmoro, and N. Ibrahim, “Identifikasi Penyakit Pada Daun Kopi Menggunakan Metode Local Binary Pattern Dan Random Forest,” *e-Proceeding Eng.*, vol. 8, no. 6, pp. 2972–2980, Dec. 2022.
- [18] A. Gusviani, I. Handayani, and U. T. Yogyakarta, “Perbandingan Support Vector Machine Dan Convolutional Neural Network Untuk Klasifikasi Penyakit Daun Singkong Comparison of Support Vector Machine and Convolutional Neural Network for Cassava Leaf Disease Classification,” *J. Inf. Technol. Comput. Sci.*, vol. 8, no. 6, pp. 1947–1957, 2025.
- [19] R. R. Burhanuddin, “KLASIFIKASI PENYAKIT PADI MELALUI CITRA DAUN MENGGUNAKAN METODE NAIVE BAYES,” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 2, Apr. 2024, doi: 10.23960/jitet.v12i2.4012.