

Identifikasi Penyakit Daun Pisang Berbasis Citra Warna dengan Ekstraksi *ResNet50* dan *Support Vector Machine*

Alwie Muflich*¹, Kusrini²

^{1,2,3} Program Studi Teknik informatika, Universitas Amikom Yogyakarta
E-mail: ^{1*}alwiemuflich@students.amikom.ac.id, ² kusrini@amikom.ac.id

Abstrak

Penyakit daun pisang merupakan salah satu faktor utama yang menyebabkan penurunan produktivitas tanaman pisang. Identifikasi penyakit secara manual masih memiliki keterbatasan karena bersifat subjektif, membutuhkan keahlian khusus, dan kurang efisien pada skala besar. Oleh karena itu, penelitian ini mengusulkan sistem identifikasi penyakit daun pisang berbasis citra warna dengan pendekatan ekstraksi fitur menggunakan Convolutional Neural Network (CNN) berbasis *ResNet50* dan klasifikasi menggunakan Support Vector Machine (SVM). Dataset yang digunakan terdiri dari empat kelas, yaitu daun sehat, Sigatoka, layu *Fusarium*, dan bercak Cordana, dengan pembagian data training 70%, validasi 15%, dan testing 15%. Tahapan penelitian meliputi pra-pemrosesan citra, augmentasi data, ekstraksi fitur menggunakan CNN, serta klasifikasi menggunakan SVM dengan beberapa variasi kernel. Selain itu, dilakukan analisis perbandingan ruang warna RGB dan HSV untuk mengetahui representasi warna yang paling efektif dalam mendukung proses klasifikasi. Hasil penelitian menunjukkan bahwa kombinasi CNN dan SVM kernel RBF memberikan akurasi validasi sebesar 99,52% dan akurasi testing sebesar 99,04%, serta nilai precision, recall, dan F1-score yang seimbang. Analisis fitur warna menunjukkan bahwa ruang warna HSV lebih stabil terhadap variasi pencahayaan, namun kombinasi RGB dan HSV mampu memberikan representasi warna yang lebih lengkap. Hasil penelitian ini menunjukkan bahwa metode CNN-SVM efektif dalam mengidentifikasi penyakit daun pisang secara akurat dan berpotensi diterapkan pada sistem deteksi dini berbasis kecerdasan buatan di bidang pertanian.

Kata kunci—CNN, Support Vector Machine, Penyakit Daun Pisang, citra warna, *ResNet50*.

1. PENDAHULUAN

Tanaman pisang merupakan salah satu komoditas hortikultura strategis yang memiliki nilai ekonomi tinggi di Indonesia dan berperan penting dalam sektor pertanian berkelanjutan. Produktivitas tanaman pisang sangat dipengaruhi oleh kesehatan daun, karena daun berfungsi sebagai organ utama dalam proses fotosintesis. Berbagai penyakit daun seperti Sigatoka, bercak daun, dan infeksi jamur dapat menyebabkan perubahan warna, tekstur, serta penurunan kualitas tanaman secara signifikan apabila tidak terdeteksi sejak dini [1]. Oleh karena itu, identifikasi penyakit daun pisang secara cepat dan akurat menjadi aspek penting dalam mendukung sistem pertanian presisi [2].

Secara konvensional, identifikasi penyakit tanaman masih dilakukan melalui observasi visual oleh petani atau pakar pertanian. Pendekatan ini memiliki keterbatasan berupa subjektivitas, ketergantungan pada pengalaman ahli, serta kurang efisien ketika diterapkan pada skala lahan yang luas [3]. Selain itu, kemiripan gejala visual antar penyakit daun sering menyebabkan kesalahan diagnosis, sehingga diperlukan sistem otomatis berbasis pengolahan citra digital dan kecerdasan buatan untuk meningkatkan akurasi dan konsistensi identifikasi penyakit tanaman.

Perkembangan computer vision dan artificial intelligence telah mendorong pemanfaatan citra digital daun sebagai sumber informasi utama dalam deteksi penyakit tanaman. Penelitian terbaru menunjukkan bahwa fitur warna dan tekstur merupakan indikator penting dalam membedakan daun sehat dan daun yang terinfeksi penyakit [4]. Representasi warna dalam ruang RGB dan HSV banyak digunakan karena mampu menangkap perubahan warna daun akibat infeksi patogen secara lebih representatif [5]. Namun, ekstraksi fitur manual berbasis warna masih memiliki keterbatasan dalam merepresentasikan pola kompleks pada citra daun.

Seiring dengan perkembangan *deep learning*, *Convolutional Neural Network* (CNN) menjadi metode yang populer dalam ekstraksi fitur citra karena kemampuannya dalam mengekstraksi fitur hierarkis secara otomatis dan robust [6]. CNN telah berhasil diterapkan dalam berbagai penelitian klasifikasi penyakit tanaman dengan tingkat akurasi yang tinggi. Di sisi lain, *Support Vector Machine* (SVM) juga dikenal sebagai algoritma klasifikasi yang efektif pada data berdimensi tinggi dan dataset berukuran terbatas, serta memiliki kemampuan generalisasi yang baik [7]. Kombinasi CNN sebagai *feature extractor* dan SVM sebagai *classifier* menjadi pendekatan hibrid yang semakin banyak digunakan dalam penelitian terkini untuk meningkatkan performa klasifikasi citra pertanian [8].


Beberapa penelitian sebelumnya telah mengkaji deteksi penyakit tanaman menggunakan berbagai metode. Penelitian oleh Ferdianysah et al. (2024) menggunakan CNN untuk klasifikasi penyakit daun pisang dan menunjukkan bahwa *deep learning* mampu meningkatkan akurasi klasifikasi dibandingkan metode konvensional [9]. Penelitian lain oleh Zhang et al. (2022) mengembangkan sistem deteksi penyakit tanaman berbasis *deep learning* dan memperoleh performa tinggi pada dataset daun tanaman, namun membutuhkan dataset berukuran besar dan komputasi tinggi [10]. Selanjutnya, penelitian oleh Fakhrunnia et al. (2023) menerapkan SVM *multiclass* untuk klasifikasi penyakit tanaman dan menunjukkan bahwa SVM efektif dalam menangani data fitur berdimensi tinggi dengan akurasi yang stabil [11]. Sementara itu, Wu dan Fang (2023) menekankan bahwa ekstraksi fitur warna berbasis segmentasi citra dapat meningkatkan kemampuan sistem dalam mengidentifikasi perubahan visual pada daun tanaman [12].

Meskipun berbagai penelitian telah dilakukan, masih terdapat beberapa celah penelitian (research gap) yang belum banyak dikaji secara komprehensif. Pertama, sebagian besar penelitian menggunakan *deep learning end-to-end* tanpa mengkombinasikan ekstraksi fitur CNN dengan klasifikasi SVM, sehingga belum optimal pada dataset berukuran terbatas. Kedua, penelitian terdahulu umumnya berfokus pada satu ruang warna saja, sementara analisis komparatif antara fitur warna RGB dan HSV pada identifikasi penyakit daun pisang masih jarang dilakukan. Ketiga, kajian mengenai pengaruh pra-pemrosesan citra dan variasi kernel SVM (*Linear*, *Polynomial*, dan *RBF*) terhadap performa klasifikasi penyakit daun pisang berbasis citra warna masih terbatas. Selain itu, objek spesifik tanaman pisang juga relatif kurang dieksplorasi dibandingkan tanaman lain seperti padi dan tomat dalam studi computer vision pertanian.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan sistem identifikasi penyakit tanaman pisang berbasis citra warna daun dengan pendekatan ekstraksi fitur menggunakan *Convolutional Neural Network* (CNN) dan klasifikasi menggunakan *Support Vector Machine* (SVM). Penelitian ini juga mengintegrasikan fitur warna RGB dan HSV serta mengevaluasi pengaruh pra-pemrosesan citra dan variasi kernel SVM terhadap kinerja model klasifikasi. Kontribusi utama penelitian ini adalah: (1) Mengusulkan kerangka kerja hibrida CNN–SVM untuk identifikasi penyakit daun pisang menggunakan fitur citra warna, (2) melakukan analisis perbandingan antara ruang warna RGB dan HSV untuk kinerja deteksi penyakit, dan serta (3) Mengevaluasi dampak berbagai kernel SVM (*Linear*, *Polynomial*, dan *RBF*) terhadap akurasi klasifikasi menggunakan dataset gambar pertanian yang terbatas. Diharapkan, sistem yang diusulkan dapat memberikan solusi deteksi dini penyakit tanaman pisang yang akurat, efisien, dan sesuai untuk implementasi pada sistem pertanian cerdas berbasis kecerdasan buatan.

2. METODE PENELITIAN

Penelitian ini dilakukan melalui beberapa tahapan utama yang meliputi pengumpulan dataset citra daun pisang, pra-pemrosesan citra, ekstraksi fitur, dan klasifikasi. Pada tahap pra-pemrosesan, citra dinormalisasi, diubah ukurannya, serta dilakukan peningkatan kualitas untuk memperoleh representasi citra yang seragam. Selanjutnya, ekstraksi fitur dilakukan menggunakan model *Convolutional Neural Network* (CNN) berbasis ResNet50 yang berperan sebagai *feature extractor* untuk menghasilkan fitur mendalam yang merepresentasikan karakteristik visual daun. Dataset kemudian dibagi menjadi data *training*, *validasi*, dan *testing* untuk memastikan proses *training* dan evaluasi model berjalan secara objektif. Fitur hasil ekstraksi selanjutnya digunakan sebagai masukan pada *algoritma Support Vector Machine* (SVM) dengan beberapa variasi kernel untuk melakukan klasifikasi penyakit daun pisang. Kinerja model dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score guna mengukur tingkat keberhasilan sistem dalam mengidentifikasi penyakit secara tepat. Untuk memberikan gambaran yang lebih *sistematis* mengenai tahapan penelitian yang dilakukan, disusun diagram alur metodologi yang menjelaskan proses secara menyeluruh mulai dari pengumpulan data hingga tahap klasifikasi dan evaluasi model. Diagram ini memperlihatkan alur kerja sistem yang diusulkan, meliputi pra-pemrosesan citra, ekstraksi fitur menggunakan *Convolutional Neural Network* (CNN) berbasis ResNet50 sebagai *feature extractor*, serta proses klasifikasi menggunakan *Support Vector Machine* (SVM) dengan beberapa variasi *kernel*. Selain itu, ditampilkan pula tahapan pembagian dataset menjadi data *training*, *validation*, dan *testing* untuk memastikan proses pelatihan dan pengujian model berjalan secara objektif dan terstruktur. Rangkaian proses tersebut ditunjukkan secara visual pada Gambar 1.0.



Gambar 1 Diagram Alur Metodologi Penelitian

Gambar 1.0 Metodologi penelitian ini dirancang secara sistematis untuk memastikan proses identifikasi penyakit daun pisang berjalan terstruktur dan menghasilkan model klasifikasi yang optimal. Setiap tahapan memiliki peran yang saling terintegrasi, dimulai dari studi literatur sebagai dasar konseptual, pengumpulan dan pra-pemrosesan data citra, hingga proses ekstraksi fitur menggunakan *Convolutional Neural Network* (CNN) dan klasifikasi menggunakan *Support Vector Machine* (SVM). Selain itu, dilakukan evaluasi kinerja model untuk mengukur tingkat

akurasi dan kemampuan generalisasi sistem. Penjelasan rinci mengenai setiap tahapan penelitian dijabarkan pada subbagian berikut.

2.1 Studi Literatur

Tahapan awal penelitian dimulai dengan mengumpulkan referensi ilmiah dari jurnal, buku, dan prosiding yang berkaitan dengan:

- citra digital pada tanaman. Karakteristik penyakit tanaman pisang (Sigatoka dan Layu Fusarium)
- pengolahan citra digital berbasis warna daun,
- Metode ekstraksi fitur menggunakan Convolutional Neural Network
- Metode klasifikasi *Support Vector Machine*
- Penelitian terdahulu yang relevan

Tinjauan pustaka dilakukan untuk mengidentifikasi studi-studi relevan yang berkaitan dengan deteksi penyakit tanaman, pengolahan citra warna, ekstraksi fitur berbasis CNN, dan metode klasifikasi SVM.

2.2 pengumpulan data citra daun pisang

Data penelitian berupa citra digital daun pisang yang diklasifikasikan ke dalam Empat kelas:


- Daun pisang Sehat
- Daun terinfeksi penyakit sigatoka
- Daun terinfeksi penyakit layu fusarium
- Bercak daun cordana

2.3 Pra-pemrosesan citra

Pra-pemrosesan dilakukan untuk meningkatkan kualitas dan keseragaman data citra, meliputi:

- Cropping* area daun
- Penghapusan latar belakang
- Normalisasi ukuran citra
- Reduksi *noise*
- Konversi ruang warna RGB dan HSV, Ruang warna RGB (*Red, Green, Blue*) merupakan representasi warna yang paling umum digunakan dalam sistem pencitraan digital. Namun, RGB sangat sensitif terhadap perubahan pencahayaan. Sebagai alternatif, ruang warna HSV (*Hue, Saturation, Value*) memisahkan informasi warna (*Hue*) dari intensitas cahaya (*Value*), sehingga lebih stabil terhadap variasi pencahayaan. [13]
- Augmentasi data (rotasi, *Flipping* dan *zoom*)

Visualisasi hasil citra setelah melalui pra-pemrosesan citra ditampilkan pada Gambar 2



Gambar 2 Visualisasi Pra pemrosesan citra

Gambar 2.0 memperlihatkan hasil visualisasi tahapan pra-pemrosesan citra yang dilakukan sebelum proses ekstraksi fitur. Tahapan ini meliputi *cropping* untuk memfokuskan area daun sebagai objek utama, *background removal* untuk mengurangi gangguan latar belakang, serta *normalization* untuk menyeragamkan distribusi intensitas piksel. Hasil pra-pemrosesan menunjukkan citra yang lebih terfokus dan memiliki kualitas visual yang lebih konsisten,

sehingga mendukung proses ekstraksi fitur menggunakan *Convolutional Neural Network (CNN)* dan meningkatkan performa klasifikasi oleh *Support Vector Machine (SVM)*.

2.4 Pembagian dataset

Dataset yang telah dipra-pemrosesan dibagi menjadi tiga bagian utama:

- Data *Training*: 70% Digunakan untuk: *Training* model CNN dan Pembentukan fitur untuk *training* SVM
 - Data *validasi* 15% digunakan untuk mengevaluasi performa model selama proses *training* serta melakukan penyetelan parameter model SVM
 - Data *Testing*: 15% Digunakan untuk: *Testing* performa akhir sistem CNN–SVM
- Data *validasi* digunakan khusus untuk memantau proses *training* CNN, menghindari *overfitting*, dan menentukan model CNN terbaik, Data *testing* tidak digunakan sama sekali dalam proses *training* dan *validasi*.

Untuk pembagian dataset akan di tampilkan di tabel 1.0 berikut.

Table 1.0 Pembagian dataset

Class	Training (70%)	Validasi (15%)	Testing (15%)	Total
Healthy	243	52	52	347
Sigatoka	243	52	52	347
Fusarium Wilt	243	52	52	347
Cordana Spots	243	52	52	347
Total	972	208	208	1388

Tabel 1.0 menunjukkan pembagian dataset citra daun pisang ke dalam data *training* (70%), *validasi* (15%), dan *testing* (15%) dengan distribusi yang seimbang pada setiap kelas. Masing-masing kelas terdiri dari 347 citra sehingga total dataset berjumlah 1.388 citra. Pembagian yang proporsional ini bertujuan untuk menghindari ketidakseimbangan kelas serta memastikan proses pelatihan dan evaluasi model berlangsung secara objektif. Data *training* digunakan untuk melatih model *Convolutional Neural Network (CNN)* dan membentuk fitur untuk *Support Vector Machine (SVM)*, sedangkan data *testing* digunakan untuk mengukur kinerja akhir sistem secara independen

2.5 Training Model CNN (Sebagai feature extractor)

Model **Convolutional Neural Network (CNN)** dilatih menggunakan data *training* dan dievaluasi menggunakan data *validasi*, tahapan:

- Input citra RGB dan HSV ke dalam CNN
- Training* CNN menggunakan data *training*
- Evaluasi performa CNN menggunakan data *validasi*
- Pemilihan model CNN terbaik berdasarkan hasil *validasi*
- confusion Matrix*

CNN tidak digunakan sebagai pengklasifikasi akhir, melainkan sebagai *feature extractor* otomatis.

2.6 Ekstraksi fitur menggunakan CNN

Ekstraksi fitur merupakan tahapan penting dalam pengolahan citra yang bertujuan mengubah informasi visual menjadi representasi numerik yang bermakna. Pada pendekatan konvensional, ekstraksi fitur warna dilakukan secara manual menggunakan statistik warna seperti *mean*, *standard deviation*, atau *histogram*. Namun, pendekatan ini memiliki keterbatasan dalam menangkap pola visual kompleks *Convolutional Neural Network (CNN)* merupakan arsitektur *deep learning* yang mampu mengekstraksi fitur visual secara otomatis dan hierarkis melalui lapisan konvolusi [14]. setelah cnn terlatih:

- Output dari layer *pooling* atau *fully connected* diambil sebagai **vektor fitur**.
- Ekstraksi fitur dilakukan pada: Data *training* (70%), Data *validasi* (15%) dan Data *testing* (15%)
- Vektor fitur disimpan sebagai data numerik.

2.7 Klasifikasi menggunakan Support Vector Machine

Support Vector Machine (SVM) merupakan algoritma *supervised learning* yang digunakan untuk klasifikasi dan regresi. Prinsip utama SVM adalah mencari *hyperplane* optimal yang

memisahkan kelas data dengan margin maksimum [15]. *vector* fitur hasil ekstraksi CNN digunakan sebagai input ke model *Support Vector Machine*, tahapan:

- Training* SVM menggunakan fitur dari data *training* (70%)
- Testing* SVM menggunakan fitur dari data *Validasi* (15%)
- Testing* SVM menggunakan fitur dari data (15%)
- Testing* beberapa kernel SVM: *Linear*, *Polynomial*, *Radial Basis Function (RBF)*

Untuk memahami mekanisme kerja *Support Vector Machine (SVM)* secara lebih mendalam, diperlukan formulasi matematis yang menjelaskan bagaimana algoritma ini menentukan batas pemisah antar kelas. Secara prinsip, SVM bekerja dengan mencari *hyperplane* optimal yang mampu memaksimalkan jarak (margin) antara dua kelas data pada ruang fitur. Margin yang lebih besar menunjukkan kemampuan generalisasi model yang lebih baik terhadap data baru. Pada penelitian ini, vektor fitur yang diperoleh dari proses ekstraksi menggunakan *Convolutional Neural Network (CNN)* digunakan sebagai input dalam pembentukan model SVM. Formulasi matematis berikut menjelaskan proses optimasi dan fungsi keputusan yang digunakan dalam proses klasifikasi. Secara matematis, *Support Vector Machine (SVM)* bertujuan mencari *hyperplane* optimal yang memaksimalkan margin antar kelas. Untuk kasus klasifikasi linear, persamaan *hyperplane* dinyatakan sebagai:

$$w \times x + b = 0$$

dengan w merupakan vektor bobot, x adalah vektor fitur hasil ekstraksi *Convolutional Neural Network (CNN)*, dan b adalah bias. Proses optimasi SVM dirumuskan sebagai berikut:

$$\min_{w,b} \frac{1}{2} \|w\|^2$$

dengan kendala: di mana $y_i \in \{-1, +1\}$ merupakan label kelas dan x_i adalah data latih.

Fungsi keputusan (*decision function*) untuk menentukan kelas suatu data baru dinyatakan sebagai:

$$f(x) = \text{sign}(w \times x + b)$$

Apabila nilai $f(x) > 0$, maka data diklasifikasikan ke kelas positif, sedangkan jika $f(x) < 0$, maka ke kelas negatif.

Untuk menangani data yang tidak terpisah secara linear, digunakan fungsi *kernel*. Pada penelitian ini digunakan *Radial Basis Function (RBF)* yang dirumuskan sebagai:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$$

dengan parameter γ yang mengontrol bentuk batas keputusan.

Contoh Perhitungan Sederhana

Misalkan diperoleh vektor fitur hasil ekstraksi CNN:

$$x = (2, 3)$$

dan parameter model:

$$w = (0.5, -0.3), b = 0.1$$

Maka dihitung:

$$\begin{aligned} w \times x &= (0.5 \times 2) + (-0.3 \times 3) \\ &= 1 - 0.9 = 0.1 \end{aligned}$$

Selanjutnya ditambahkan bias:

$$f(x) = 0.1 + 0.1 = 0.2$$

Karena $f(x) > 0$, maka sampel diklasifikasikan ke kelas positif (daun sehat).

2.8 Evaluasi Kinerja Sistem

Evaluasi kinerja model dilakukan untuk mengukur tingkat keberhasilan sistem dalam mengklasifikasikan citra daun pisang. Pengukuran dilakukan menggunakan metrik *Accuracy*, *Precision*, *Recall*, *F1-score*, serta analisis *Confusion Matrix*. Perhitungan metrik didasarkan pada nilai *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*.

Sebagai contoh, misalkan diperoleh:

$$TP = 40$$

$$TN = 50$$

$$FP = 5$$

FN = 5

a. *Accuracy*

Accuracy menunjukkan proporsi jumlah prediksi yang benar terhadap seluruh data.

$$\begin{aligned} \text{Accuracy} &= \frac{TP + TN}{TP + TN + FP + FN} \\ &= \frac{40 + 50}{40 + 50 + 5 + 5} \\ &= \frac{90}{100} = 0.90(90\%) \end{aligned}$$

b. *Precision*

Precision mengukur ketepatan model dalam memprediksi kelas positif.

$$\begin{aligned} \text{Precision} &= \frac{TP}{TP + FP} \\ &= \frac{40}{40 + 5} \\ &= \frac{40}{45} = 0.89(89\%) \end{aligned}$$

c. *Recall*

Recall menunjukkan kemampuan model dalam mendeteksi seluruh data positif.

$$\begin{aligned} \text{Recall} &= \frac{TP}{TP + FP} \\ &= \frac{40}{40 + 5} \\ &= \frac{40}{45} = 0.89(89\%) \end{aligned}$$

d. *F1-score*

F1-score merupakan rata-rata harmonik antara *Precision* dan *Recall*.

$$\begin{aligned} F1 &= 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \\ &= 2 \times \frac{0.89 \times 0.89}{0.89 + 0.89} \\ &= 0.89(89\%) \end{aligned}$$

e. *Confusion Matrix*

Confusion Matrix merupakan tabel yang menampilkan distribusi hasil prediksi model terhadap kondisi aktual. Matriks ini terdiri dari empat komponen utama, yaitu TP, TN, FP, dan FN, yang menjadi dasar perhitungan seluruh metrik evaluasi di atas. Melalui *Confusion Matrix*, dapat dianalisis pola kesalahan klasifikasi yang dilakukan oleh model secara lebih rinci.

2.9 Analisis dan penarikan Kesimpulan

Hasil *testing* dianalisis untuk :

- Menentukan kombinasi CNN - SVM Terbaik
- Perbandingan rgb dan hsv

3. HASIL DAN PEMBAHASAN

3.1 Hasil Training dan ekstraksi fitur Convolution Network

Berdasarkan hasil *testing* deteksi penyakit daun pisang citra warna daun, kombinasi Convolutional Neural Network sebagai *feature extractor* dan *Support Vector Machine* dengan kernel RBF sebagai *classifier* menunjukkan kinerja yang sangat tinggi. Proses ekstraksi fitur menggunakan arsitektur ResNet50 mampu menghasilkan representasi fitur mendalam yang efektif dalam membedakan karakteristik visual daun sehat, Sigatoka, layu Fusarium, dan bercak Cordana. Hal ini dibuktikan dengan akurasi *validasi* sebesar 99,52% dan akurasi *testing* sebesar

99,04%, yang menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik dan tidak mengalami *overfitting* secara signifikan. Selain itu, nilai *precision* (99,08%), *recall* (99,04%), dan *F1-score* (99,04%) yang seimbang mengindikasikan bahwa sistem mampu mengklasifikasikan setiap kelas secara konsisten dengan tingkat kesalahan yang sangat rendah. Hasil ini menegaskan bahwa fitur yang diekstraksi oleh CNN memiliki daya diskriminatif tinggi, sehingga ketika diproses oleh SVM kernel RBF yang mampu menangani pemisahan *non-linear* pada ruang fitur berdimensi tinggi, sistem klasifikasi penyakit daun pisang dapat bekerja secara optimal dan akurat.

Dibandingkan dengan penelitian sebelumnya tentang klasifikasi penyakit tanaman menggunakan pembelajaran mendalam dan pembelajaran mesin konvensional, Hasil penelitian ini menunjukkan akurasi *testing* sebesar 99,04%, lebih tinggi dibandingkan penelitian Ferdianysah et al. (2024) yang menggunakan CNN *end-to-end* dengan akurasi 96–98% [9]. Selain itu, penelitian Zhang et al. (2022) melaporkan bahwa model *deep learning* memerlukan dataset besar untuk mencapai performa optimal [10], sedangkan penelitian ini mampu mencapai akurasi tinggi pada dataset terbatas melalui pendekatan hibrida CNN–SVM. Hal ini menunjukkan bahwa kombinasi *feature extraction* CNN dan klasifikasi SVM lebih efisien pada dataset berukuran kecil pada dataset yang relatif terbatas. Penelitian sebelumnya seperti deteksi penyakit tanaman berbasis CNN umumnya membutuhkan dataset skala besar dan sumber daya komputasi yang tinggi, sedangkan model hibrida yang diusulkan menunjukkan efisiensi kinerja yang tinggi dan generalisasi yang kuat dengan ukuran dataset yang lebih kecil. Untuk memberikan gambaran kuantitatif mengenai performa model yang diusulkan, hasil evaluasi klasifikasi menggunakan kombinasi *Convolutional Neural Network* (CNN) sebagai *feature extractor* dan *Support Vector Machine* (SVM) dengan kernel *Radial Basis Function* (RBF) disajikan dalam bentuk tabel. Evaluasi dilakukan pada data validasi dan data *testing* menggunakan metrik *accuracy*, *precision*, dan *recall* guna mengukur tingkat ketepatan serta konsistensi model dalam mengidentifikasi setiap kelas penyakit daun pisang. Ringkasan hasil pengujian tersebut ditampilkan pada Tabel 2.0.

Tabel 2.0 Hasil Akurasi Klasifikasi menggunakan fitur ekstraksi *Convolutional Neural Network* dan klasifikasi *SVM-RBF*


Metrik Evaluasi	Nilai (%)
Akurasi <i>Validasi</i>	99,52
Akurasi <i>Testing</i>	99,04
<i>Precision</i> (Macro Avg)	99,08
<i>Recall</i> (Macro Avg)	99,04

Tabel 2.0 menunjukkan performa keseluruhan model CNN–SVM dengan kernel RBF pada data *validasi* dan *testing*. Nilai *macro average* digunakan untuk mengevaluasi keseimbangan performa pada seluruh kelas.

3.2 Hasil Analisis Perbandingan RGB dan HSV

Berdasarkan hasil perhitungan rata-rata fitur warna pada dataset citra daun pisang, diperoleh nilai rata-rata komponen RGB yaitu Red sebesar 154,77, Green sebesar 161,17, dan Blue sebesar 51,39. Nilai ini menunjukkan bahwa distribusi warna daun didominasi oleh komponen hijau dan merah, sedangkan komponen biru relatif rendah, yang sesuai dengan karakteristik warna alami daun serta perubahan warna akibat infeksi penyakit. Pada ruang warna HSV, diperoleh rata-rata *Hue* sebesar 31,70, *Saturation* sebesar 176,30, dan *Value* sebesar 163,61. Nilai *Saturation* yang tinggi menunjukkan intensitas warna daun yang cukup kuat, sedangkan nilai *Hue* merepresentasikan pergeseran warna yang berkaitan dengan gejala penyakit seperti klorosis dan bercak.

Hasil analisis menunjukkan bahwa ruang warna HSV lebih mampu merepresentasikan karakteristik warna daun secara stabil dibandingkan RGB, terutama dalam memisahkan informasi warna dan intensitas cahaya. Pada RGB, perubahan pencahayaan dapat mempengaruhi nilai setiap kanal secara bersamaan, sedangkan pada HSV informasi warna utama direpresentasikan oleh komponen *Hue* sehingga lebih robust terhadap variasi iluminasi. Namun demikian, penggunaan kombinasi fitur RGB dan HSV memberikan representasi warna yang lebih lengkap karena mampu menangkap informasi warna dasar sekaligus karakteristik persepsi warna, sehingga meningkatkan kualitas fitur yang digunakan dalam proses klasifikasi penyakit daun pisang. Hasil di tunjukkan pada visualisasi pada gambar 3.0 , Untuk menganalisis karakteristik distribusi warna pada dataset citra daun pisang, dilakukan perhitungan nilai rata-rata (*mean*) pada masing-masing komponen ruang warna RGB dan HSV. Analisis ini bertujuan untuk mengetahui representasi warna dominan serta mengevaluasi stabilitas masing-masing ruang warna dalam mendukung proses klasifikasi penyakit daun pisang. Hasil perhitungan nilai rata-rata fitur warna tersebut disajikan pada Tabel 3.0.



Gambar 3 Hasil Analisis Perbandingan Ruang Warna RGB dan HSV

Gambar 3.0 menampilkan visualisasi perbandingan distribusi nilai rata-rata fitur warna pada ruang RGB dan HSV. Grafik tersebut memperlihatkan bahwa komponen Green memiliki kontribusi dominan pada ruang RGB, yang sesuai dengan karakteristik alami daun sebagai objek utama penelitian. Sementara itu, pada ruang HSV terlihat bahwa komponen Saturation dan Value memiliki nilai relatif tinggi, menunjukkan intensitas warna dan tingkat kecerahan daun yang cukup kuat pada dataset. Visualisasi ini memperjelas perbedaan karakteristik kedua ruang warna, di mana HSV mampu memisahkan informasi warna dan pencahayaan secara lebih representatif. Hasil ini mendukung analisis bahwa kombinasi fitur RGB dan HSV memberikan representasi warna yang lebih komprehensif untuk meningkatkan performa klasifikasi penyakit daun pisang.

Table 3.0 Hasil Analisis Perbandingan Ruang Warna RGB dan HSV

Fitur Warna	Nilai Rata-rata
Mean Red (R)	154,77
Mean Green (G)	161,17
Mean Blue (B)	51,39
Mean Hue (H)	31,7
Mean Saturation (S)	176,3
Mean Value (V)	163,61

Tabel 3.0 menunjukkan bahwa pada ruang warna RGB, komponen Green memiliki nilai rata-rata tertinggi dibandingkan Red dan Blue, yang mengindikasikan dominasi warna hijau sebagai karakteristik utama daun. Sementara itu, pada ruang warna HSV, nilai Saturation dan Value relatif tinggi, yang menunjukkan intensitas warna dan tingkat kecerahan daun cukup kuat pada dataset. Komponen Hue merepresentasikan variasi spektrum warna yang berkaitan dengan perubahan fisiologis akibat infeksi penyakit.

Secara umum, hasil ini menunjukkan bahwa ruang warna HSV mampu memisahkan informasi warna dan intensitas cahaya secara lebih jelas dibandingkan RGB. Namun, kombinasi fitur RGB dan HSV memberikan representasi warna yang lebih komprehensif sehingga mendukung peningkatan kualitas fitur dalam proses klasifikasi menggunakan model *CNN-SVM*.


3.3 Hasil Evaluasi Kinerja Kernel SVM pada Dataset Citra Daun Pisang

Evaluasi kinerja klasifikasi dilakukan menggunakan algoritma **Support Vector Machine** dengan tiga variasi kernel, yaitu *Linear*, *Polynomial*, dan *Radial Basis Function (RBF)*. Proses klasifikasi memanfaatkan fitur yang telah diekstraksi oleh **Convolutional Neural Network** berbasis **ResNet50**, sehingga setiap kernel diuji pada ruang fitur yang sama untuk memastikan hasil perbandingan yang objektif.

Berdasarkan hasil *testing*, kernel *Linear* memperoleh akurasi *validasi* sebesar 99,52% dan akurasi *testing* sebesar 98,56%, dengan nilai *precision* 98,59%, *recall* 98,56%, dan *F1-score* 98,56%. Hasil ini menunjukkan bahwa kernel *Linear* mampu memberikan performa yang baik, namun masih terdapat beberapa kesalahan klasifikasi, terutama pada kelas penyakit yang memiliki kemiripan karakteristik visual. Kernel *Polynomial* memperoleh akurasi *validasi* sebesar 97,61% dan akurasi *testing* sebesar 99,04%, dengan nilai *precision*, *recall*, dan *F1-score* masing-masing sebesar 99,08%, menunjukkan bahwa kernel ini mampu menangani hubungan *non-linear*, namun performa *validasinya* lebih rendah dibandingkan kernel lainnya sehingga stabilitas model masih perlu diperhatikan.

Sementara itu, kernel RBF menunjukkan kinerja terbaik dengan akurasi *validasi* sebesar 99,52% dan akurasi *testing* sebesar 99,04%, serta nilai *precision* 99,08%, *recall* 99,04%, dan *F1-score* 99,04%. Hasil ini menunjukkan bahwa kernel RBF lebih mampu memisahkan data pada ruang fitur berdimensi tinggi hasil ekstraksi CNN, sehingga menghasilkan tingkat kesalahan klasifikasi yang lebih rendah dan performa yang lebih konsisten.

Secara keseluruhan, hasil perbandingan kernel menunjukkan bahwa fitur yang dihasilkan oleh CNN memiliki distribusi *non-linear*, sehingga kernel *non-linear* seperti RBF lebih sesuai digunakan dalam klasifikasi penyakit daun pisang. Kombinasi ekstraksi fitur CNN dan klasifikasi SVM kernel RBF terbukti memberikan performa yang optimal, dengan akurasi tinggi, keseimbangan *precision* dan *recall* yang baik, serta kemampuan generalisasi model yang stabil pada data *testing* di tunjukkan pada table 4.0 dan visualisasi pada gambar 4.0.




Gambar 4 Hasil Analisis Kinerja Kernel SVM pada Dataset Citra Daun Pisang

Gambar 4 menampilkan visualisasi perbandingan kinerja tiga variasi *kernel* pada algoritma *Support Vector Machine (SVM)*, yaitu *Linear*, *Polynomial*, dan *Radial Basis Function (RBF)*, berdasarkan metrik akurasi, *precision*, *recall*, dan *F1-score*. Dari visualisasi tersebut terlihat bahwa *kernel* RBF memberikan performa yang paling konsisten dan stabil baik pada data *validasi* maupun data *testing*. Meskipun *kernel* *Linear* juga menunjukkan akurasi yang tinggi, terdapat sedikit penurunan performa pada data *testing*. Sementara itu, *kernel* *Polynomial* menunjukkan variasi nilai yang lebih fluktuatif pada tahap *validasi*.

Secara keseluruhan, grafik pada Gambar 4.0 mengindikasikan bahwa distribusi fitur hasil ekstraksi *Convolutional Neural Network (CNN)* cenderung bersifat *non-linear*, sehingga *kernel* RBF lebih mampu membentuk batas keputusan yang optimal pada ruang fitur berdimensi tinggi. Visualisasi ini memperkuat temuan bahwa kombinasi CNN sebagai *feature extractor* dan SVM

dengan *kernel* RBF merupakan konfigurasi terbaik dalam sistem identifikasi penyakit daun pisang yang diusulkan.

Dan Untuk menganalisis distribusi kesalahan klasifikasi secara lebih rinci pada model terbaik, ditampilkan visualisasi *Confusion Matrix* dari kombinasi *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM) dengan *kernel* *Radial Basis Function* (RBF) pada data



testing. Visualisasi ini bertujuan untuk menunjukkan tingkat ketepatan prediksi pada setiap kelas serta pola kesalahan yang terjadi selama proses klasifikasi pada gambar 5

Gambar 5 *Confusion Matrix SVM-RBF pada Data Testing*

Gambar 5 menunjukkan bahwa sebagian besar sampel pada setiap kelas berhasil diklasifikasikan dengan benar, yang ditandai dengan dominasi nilai pada diagonal utama matriks. Jumlah kesalahan klasifikasi antar kelas relatif kecil dan tidak menunjukkan pola kesalahan yang signifikan pada kelas tertentu. Hal ini mengindikasikan bahwa model memiliki kemampuan diskriminatif yang baik dalam membedakan karakteristik visual antara daun sehat, Sigatoka, layu Fusarium, dan bercak Cordana.

Distribusi prediksi yang seimbang pada seluruh kelas juga menunjukkan bahwa model tidak mengalami bias terhadap salah satu kategori tertentu. Dengan demikian, analisis *Confusion Matrix* memperkuat hasil evaluasi kuantitatif sebelumnya bahwa kombinasi CNN sebagai *feature extractor* dan SVM *kernel* RBF mampu menghasilkan performa klasifikasi yang stabil dan akurat pada dataset citra daun pisang.

Dan untuk membandingkan performa klasifikasi dari setiap variasi *kernel* pada algoritma *Support Vector Machine* (SVM), dilakukan evaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* pada data validasi dan data *testing*. Pengujian ini bertujuan untuk mengidentifikasi konfigurasi *kernel* yang paling optimal dalam memanfaatkan fitur hasil ekstraksi *Convolutional Neural Network* (CNN). Ringkasan hasil pengujian tersebut disajikan pada Tabel 4.0 sebagai dasar analisis dalam menentukan model terbaik yang digunakan pada sistem yang diusulkan.

Table 4 Hasil Evaluasi Kinerja Kernel SVM pada Dataset Citra Daun Pisang

Kernel SVM	Akurasi Validasi (%)	Akurasi Testing (%)	Precision (%)	Recall (%)	F1-Score (%)
Linear	99.52%	98.56%	98.59%	98.56%	98.56%
RBF	99.52%	99.04%	99.08%	99.04%	99.04%
Polynomial	97.61%	99.04%	99.08%	99.04%	99.04%

Tabel 4 menyajikan perbandingan kinerja beberapa variasi *kernel* pada algoritma *Support Vector Machine* (SVM) berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score* pada data validasi dan data *testing*. Hasil pengujian menunjukkan bahwa setiap *kernel* memiliki

karakteristik performa yang berbeda dalam memanfaatkan fitur hasil ekstraksi *Convolutional Neural Network (CNN)*.

Secara umum, *kernel* Linear dan Polynomial mampu menghasilkan tingkat akurasi yang baik, namun masih menunjukkan variasi nilai pada tahap *testing*. Sementara itu, *kernel Radial Basis Function (RBF)* memberikan performa yang paling konsisten dan stabil pada seluruh metrik evaluasi. Konsistensi ini mengindikasikan bahwa distribusi fitur yang dihasilkan CNN bersifat non-linear dan lebih optimal dipisahkan menggunakan pendekatan RBF.

Dengan demikian, berdasarkan hasil pada Tabel 4.0, kombinasi CNN sebagai *feature extractor* dan SVM dengan *kernel* RBF dipilih sebagai model terbaik karena mampu memberikan performa klasifikasi yang paling optimal dan reliabel dalam mengidentifikasi penyakit daun pisang.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, sistem identifikasi penyakit daun pisang berbasis citra warna dengan ekstraksi fitur menggunakan *Convolutional Neural Network (CNN)* dan klasifikasi menggunakan *Support Vector Machine (SVM)* mampu memberikan kinerja yang sangat baik. Model terbaik diperoleh menggunakan *kernel Radial Basis Function (RBF)* dengan akurasi validasi sebesar 99,52% dan akurasi *testing* sebesar 99,04%. Selain itu, nilai *precision* sebesar 99,08%, *recall* sebesar 99,04%, dan *F1-score* sebesar 99,04% menunjukkan bahwa model memiliki keseimbangan performa yang baik pada seluruh kelas, yaitu daun sehat, Sigatoka, layu Fusarium, dan bercak Cordana.

Hasil perbandingan *kernel* menunjukkan bahwa RBF lebih stabil dibandingkan Linear (akurasi *testing* 98,56%) dan Polynomial (akurasi validasi 97,61%), yang mengindikasikan bahwa distribusi fitur hasil ekstraksi CNN bersifat non-linear. Analisis fitur warna juga menunjukkan bahwa ruang warna HSV lebih stabil terhadap variasi pencahayaan, dengan nilai rata-rata Saturation sebesar 176,30 dan Value sebesar 163,61, sedangkan kombinasi RGB dan HSV memberikan representasi warna yang lebih komprehensif. Dengan demikian, pendekatan hibrida CNN–SVM terbukti efektif dan memiliki kemampuan generalisasi yang kuat dalam mengidentifikasi penyakit daun pisang pada dataset terbatas.

Studi ini menunjukkan bahwa model hibrida CNN–SVM sangat efektif untuk identifikasi penyakit daun pisang menggunakan fitur citra warna. Hasil eksperimen menunjukkan bahwa *kernel* RBF memberikan kinerja terbaik dengan akurasi, presisi, *recall*, dan *F1-score* yang tinggi. Lebih lanjut, kombinasi fitur warna RGB dan HSV meningkatkan ketahanan klasifikasi dalam berbagai kondisi pencahayaan. Oleh karena itu, pendekatan yang diusulkan cocok untuk sistem deteksi penyakit pertanian cerdas, terutama untuk skenario dengan dataset terbatas.

5. SARAN

Berdasarkan hasil penelitian yang telah diperoleh, terdapat beberapa saran untuk pengembangan Penelitian selanjutnya dapat diperluas:

1. Penelitian dapat diperluas dengan menggunakan dataset yang lebih besar dan bervariasi, termasuk citra daun dengan kondisi pencahayaan dan latar belakang yang lebih kompleks agar model memiliki kemampuan generalisasi yang lebih baik.
 2. Eksplorasi arsitektur CNN lainnya seperti EfficientNet atau DenseNet dapat dilakukan untuk membandingkan performa ekstraksi fitur yang lebih optimal
 3. *Eesting* sistem pada kondisi lapangan secara langsung (*real-time detection*) menggunakan perangkat mobile atau sistem berbasis web dapat menjadi langkah lanjutan untuk mengimplementasikan model dalam skenario nyata. Selain itu, integrasi metode segmentasi citra sebelum proses ekstraksi fitur juga berpotensi meningkatkan akurasi dengan memfokuskan analisis pada area daun yang terinfeksi.
-

DAFTAR PUSTAKA

- [1] P. K. Sethy and B. Behera, "Detection of plant leaf diseases using image processing and machine learning: A review," *Journal of Physics: Conference Series*, vol. 2107, no. 1, 2021.
- [2] S. R. Dubey, S. Jalal, and P. Moorthy, "Plant disease recognition using convolutional neural networks and transfer learning," *Ecological Informatics*, vol. 68, 2022.
- [3] M. A. Hossain, M. S. Hossain, and K. Andersson, "A deep learning approach for plant disease detection using leaf images," *Applied Sciences*, vol. 12, no. 6, 2022.
- [4] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Computers and Electronics in Agriculture*, vol. 204, 2023.
- [5] Y. Wu and Y. Fang, "Color feature ekstraksi based on image segmentation for plant disease identification," *Scientific Reports*, vol. 13, 2023.
- [6] S. Khan, M. Tufail, M. T. Khan, Z. Khan, and M. Maqsood, "Deep learning-based identification system of plant diseases using leaf images," *Sustainability*, vol. 14, no. 5, 2022.
- [7] A. M. Fahad et al., "Support Vector Machine for multiclass plant disease klasifikasi using image features," *Computers and Electronics in Agriculture*, vol. 198, 2022.
- [8] R. S. Nanekaran, M. Zhang, and Y. Tian, "Hybrid CNN–SVM model for image klasifikasi in agricultural applications," *Artificial Intelligence in Agriculture*, vol. 6, 2022.
- [9] H. Ferdianysah, R. Kurniawan, and A. Nugroho, "Klasifikasi of banana leaf diseases using convolutional neural network," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 30, no. 2, 2024.
- [10] C. Zhang, P. Zhou, and Y. Li, "Plant disease detection based on deep learning: A review," *Agriculture*, vol. 12, no. 9, 2022.
- [11] N. Fakhrunnisa, A. Setiawan, and D. Prabowo, "Multiclass SVM for plant disease klasifikasi based on image features," *TELKOMNIKA*, vol. 21, no. 3, 2023.
- [12] J. Too, S. Yujian, L. Njuki, and Y. Yingchun, "A comparative study of fine-tuning deep learning models for plant disease identification," *Computers and Electronics in Agriculture*, vol. 161, 2021.
- [13] Amrozi, Y., & Yuliati, D. *Klasifikasi Jenis Buah Pisang Berdasarkan Citra Warna dengan Metode SVM*. Jurnal SISFOKOM (Sistem Informasi dan Komputer), Volume 11, Nomor 3, PP 394-399, 2022.
- [14] Bahaa S. Hamed, Mahmoud M. Hussein, et al, *Plant Disease Detection Using Deep Learning*. *International Journal of Intelligent Systems and Applications*, 15(6), 38-50, 2023.
- [15] U. Khaira, R. Aryani, and R. W. Hardian, "Komparasi Algoritma Naïve Bayes dan Support Vector Machine (SVM) Pada Analisis Sentimen Kebijakan Kemdikbudristek Mengenai Kuota Internet Selama Covid-19," *Jurnal Processor*, vol. 18, no. 2, pp. 1–10, 2023.