

KLASIFIKASI PENYAKIT TANAMAN NILAM BERDASARKAN CITRA DAUN MENGUNAKAN METODE GLCM DAN SVM

Sarina*¹⁾, Rizki Yusliana Bakti ²⁾, Muhammad Faisal ³⁾, Muhammad Syafaat⁴⁾, Andi Makbul Syamsuri⁵⁾, Muhyiddin AM Hayat⁶⁾, Andi Lukman Anas⁷⁾

1. Informatika, Universitas Muhammadiyah Makassar
sarinasonnesonnw@gmail.com
2. Informatika, Universitas Muhammadiyah Makassar
rizkiyusliana@unismuh.ac.id
3. Informatika, Universitas Muhammadiyah Makassar
muhfaisal@unismuh.ac.id
4. Teknik Pengairan, Universitas Muhammadiyah Makassar
syafaat_skuba@unismuh.ac.id
5. Teknik Pengairan, Universitas Muhammadiyah Makassar
amakbulsyamsuri@unismuh.ac.id
6. Informatika, Universitas Muhammadiyah Makassar
muhyiddin@unismuh.ac.id
7. Informatika, Universitas Muhammadiyah Makassar
lukmananas@unismuh.ac.id

Abstract

*This study presents a classification model for detecting diseases in patchouli (*Pogostemon cablin* Benth) leaves using image processing techniques. The method combines Grey Level Co-occurrence Matrix (GLCM) for texture feature extraction and Support Vector Machine (SVM) for classification, optimised using the Particle Swarm Optimisation (PSO) algorithm. A total of 2,080 leaf images were collected and categorized into four classes: healthy, leaf spot, yellowing, and mosaic. Each image was augmented and converted to grayscale to enhance the dataset and reduce computational complexity. Four GLCM features—contrast, correlation, energy, and homogeneity—were extracted to represent leaf textures. The classification model achieved an accuracy of 89.74% using SVM alone, and improved to 97.12% when optimized with PSO. The results indicate that the integration of GLCM, SVM, and PSO provides an effective and accurate solution for early detection of patchouli leaf diseases, potentially supporting farmers in decision-making and improving crop productivity and quality.*

Kata Kunci : GLCM, SVM, PSO, Klasifikasi Citra, Penyakit Daun Nilam

A. PENDAHULUAN

Tanaman nilam (*Pogostemon cablin* Benth) merupakan tanaman tradisional yang banyak digunakan dalam industri kimia sebagai wewangian parfum, kosmetika, farmasi, dan kebutuhan dasar

industri lainnya [1]. Minyak *atsiri* dari nilam diperoleh melalui proses penyulingan daun dan ranting, dan menjadi salah satu komoditas ekspor penting yang memberikan kontribusi

terhadap pendapatan negara serta kesejahteraan petani [2].

Salah satu permasalahan utama yang dihadapi petani nilam adalah keterbatasan informasi dalam mengidentifikasi penyakit tanaman secara dini. Keterlambatan dalam mengidentifikasi dan menangani penyakit tanaman dapat menyebabkan penurunan produktivitas dan kualitas hasil panen. Oleh karena itu, dibutuhkan suatu sistem yang mampu mendeteksi penyakit secara otomatis dan akurat, guna membantu petani dalam mengambil keputusan penanganan secara cepat dan tepat [3].

Seiring dengan kemajuan teknologi digital, penerapan pengolahan citra digital dan kecerdasan buatan telah menjadi solusi potensial dalam bidang pertanian, khususnya dalam deteksi penyakit tanaman secara otomatis. Salah satu metode yang banyak digunakan dalam analisis tekstur citra adalah *Gray Level Co-occurrence Matrix* (GLCM), yang berfungsi untuk mengekstraksi informasi tekstur berdasarkan hubungan spasial antar piksel dalam suatu citra [4]. Fitur tekstur yang dihasilkan dari GLCM selanjutnya digunakan dalam proses klasifikasi menggunakan algoritma *Support Vector Machine* (SVM), yaitu metode pembelajaran mesin yang mampu mengelompokkan data secara optimal, baik pada kasus linear maupun non-linear, melalui penerapan fungsi *kernel* [5].


Teknologi pengolahan citra digital berbasis GLCM dan SVM telah banyak diterapkan dalam klasifikasi penyakit pada berbagai jenis tanaman, seperti apel, bayam, dan cabai [6]. Penelitian oleh Tabbakh dan Barpanda berhasil mengklasifikasikan penyakit pada tanaman tomat menggunakan kombinasi metode GLCM dan SVM dengan kernel RBF, mampu mencapai akurasi hingga 93,15% [7]. Penelitian serupa pada daun tanaman juga menunjukkan hasil akurasi yang cukup baik dengan hasil 97,2% [8].

Metode GLCM dan SVM juga telah digunakan dalam berbagai studi klasifikasi citra bertekstur yang menguji kombinasi keduanya pada dataset *Kylberg Texture*. Studi tersebut menunjukkan bahwa pendekatan ini mampu mengenali pola tekstur yang kompleks secara efektif pada citra digital [9].

Penelitian ini bertujuan untuk melakukan klasifikasi penyakit tanaman nilam berbasis citra daun menggunakan GLCM dan SVM untuk proses klasifikasi, guna memperoleh hasil identifikasi penyakit yang akurat, dan efisien, sehingga dapat membantu petani dalam mengambil keputusan penanganan yang tepat serta mendukung upaya peningkatan produktivitas dan mutu hasil pertanian.

B. METODE PENELITIAN


Penelitian ini bertujuan untuk mengklasifikasikan penyakit daun tanaman nilam menggunakan metode GLCM, SVM dan PSO tahapan penelitian dapat dilihat pada gambar 1.



Gambar 1. Flowchart GLCM PSO dan SVM

1. Pengumpulan Data

Dataset yang di gunakan dalam penelitian ini merupakan data gambar tanaman nilam yang di peroleh di desa tawakua kec. Angkona kab. Luwu timur sebanyak 2080 data itu dapat di lihat pada Gambar 2. Gambar (a) menunjukkan daun sehat dengan warna hijau merata dan halus, Gambar (b) menunjukkan bercak daun dengan bintik gelap tak beraturan dan tekstur kasar; Gambar (c) menunjukkan penyakit kuning dengan warna kuning merata dan daun kering; dan Gambar (d) menunjukkan mozaik dengan pola belang kuning-hijau yang tidak simetris dan permukaan tidak rata.



Gambar 2. Tanaman nilam

2. Gray-Level Co-occurrence Matrix

GLCM merupakan metode statistik yang digunakan untuk mengukur tekstur suatu citra dengan menganalisis seberapa sering pasangan piksel dengan nilai intensitas (abu-abu) tertentu muncul dalam posisi spasial tertentu [10]. GLCM digunakan untuk menganalisis hubungan antara dua *pixel* dalam citra, yang memungkinkan identifikasi karakteristik tekstur yang relevan [11].

Dalam penelitian ini, digunakan empat fitur tekstur utama yang umum dipakai dalam pengolahan citra berbasis GLCM, yaitu *contrast*, *correlation*, *energy*, dan *homogeneity*. Fitur GLCM sebagai berikut:

a. Contrast

Contrast mengukur sejauh mana perbedaan intensitas antara piksel dan tetangganya dalam suatu gambar. Nilai *contrast* yang tinggi menunjukkan perbedaan tajam antar piksel, yang mencerminkan tekstur kasar atau tidak

seragam [12]. Rumus perhitungannya ditunjukkan pada Formula 1:

$$Contrast = \sum_i \sum_j (i - j)^2 \cdot P(i, j) \quad (1)$$

Penjelasan:

$\sum_i \sum_j$: penjumlahan untuk semua kombinasi i dan j .

$(i - j)^2$: perbedaan kuadrat antara dua tingkat keabuan.

$P(i, j)$: probabilitas pasangan piksel i dan j dalam GLCM.

b. Correlation

Correlation mengukur tingkat hubungan linier antara pasangan piksel. Semakin tinggi nilai korelasi, semakin kuat hubungan antara nilai piksel dan tetangganya, yang menunjukkan pola atau struktur tertentu dalam gambar [13]. Corelasi mempunyai rumus dapat dilihat pada formula 2:

$$Correlation = \sum_i \sum_j \frac{(i - \mu_i)(j - \mu_j)p(i, j)}{\sigma_i \sigma_j} \quad (2)$$

Penjelasan :

$\sum_i \sum_j$: penjumlahan untuk semua kombinasi i dan j .

$P(i, j)$: probabilitas pasangan piksel i dan j dalam GLCM.

μ_i, μ_j : Rata-rata (mean) dari nilai keabuan pada arah i dan j .

σ_i, σ_j : Simpangan baku dari nilai keabuan pada arah i dan j .

$(i - \mu_i)(j - \mu_j)$: Mengukur hubungan linear nilai keabuan i dan j .

c. energy

energy adalah ukuran keseragaman tekstur dalam gambar. Nilai *energy* yang tinggi menunjukkan tekstur yang homogen atau memiliki pola berulang yang teratur [14]. *Energy* mempunyai rumus dapat dilihat pada formula 3:

$$Energy = \sum_i \sum_j P(i, j)^2 \quad (3)$$

Penjelasan :

$\sum_i \sum_j$: Penjumlahan pasangan i dan j.

$P(i, j)$: probabilitas pasangan piksel i dan j dalam GLCM

$P(i,j)^2$: Kuadrat dari probabilitas, untuk menekankan frekuensi.

d. Homogeneity

Homogeneity menunjukkan seberapa dekat nilai elemen-elemen GLCM terhadap diagonal utama. Nilai *Homogeneity* yang tinggi menunjukkan bahwa intensitas piksel-piksel dalam gambar cenderung serupa, yang mencerminkan tekstur yang halus [15]. *Homogeneity* mempunyai rumus dapat dilihat pada formula 4:

$$Homogeneity = \sum_i \sum_j \frac{p(i,j)}{1+|i-j|} \quad (4)$$

Penjelasan :

$\sum_i \sum_j$: Penjumlahan semua kombinasi piksel.

$P(i, j)$: Probabilitas pasangan piksel dalam GLCM.

$|i - j|$: Selisih absolut antara tingkat keabuan piksel.

3. Support Vector Machine

SVM adalah metode klasifikasi yang pertama kali diperkenalkan oleh Vapnik pada tahun 1998 [16]. Pada dasarnya, metode ini bekerja dengan menetapkan batas pemisah antara dua kelas data melalui pencarian *hyperplane* terbaik yang memiliki margin maksimal. Margin merupakan jarak dari *hyperplane* ke titik data terdekat dari setiap kelas, yang disebut *support vector*. Dengan mekanisme ini, SVM efektif dalam klasifikasi, terutama untuk data yang dapat dipisahkan secara linear [17].

SVM dapat di bedakan menjadi dua jenis berdasarkan kernel yang digunakan, yaitu SVM-Linear dan SVM Non-Linear.

a. SVM Linear

Pada proses klasifikasi menggunakan SVM *Linear* data dapat dipisahkan dengan *hyperplane* menggunakan SVM dengan pembagian data yang jelas [18]. Adapun rumus untuk SVM linear dapat dilihat pada formula 5:

$$F(x) = \text{Sign}(w \cdot x + b) \quad (5)$$

Penjelasan:

Fungsi $f(x) = \text{sign}(w \cdot x + b)$ menentukan kelas data; +1 jika di atas *hyperplane*, -1 jika di bawah.

b. SVM Non-Linear

SVM *non-linear* memanfaatkan fungsi kernel untuk mengubah data *non-linear* menjadi bentuk yang dapat dipisahkan secara *linear*. Pendekatan ini dikenal sebagai teknik *kernel*, yang digunakan untuk mentransformasikan data dari ruang berdimensi rendah ke ruang berdimensi lebih tinggi [19]. Adapun rumus untuk SVM *Non-linear* dapat dilihat pada formula 6:

$$F(x) = \text{sign}(\sum_{i=1}^n a_i y_i k(x_i, x) + b) \quad (6)$$

Penjelasan :

$F(x)$ adalah prediksi kelas SVM, ditentukan oleh tanda dari jumlah bobot a_i , kernel $k(x_i, x)$, dan bias b yang membentuk batas keputusan.

4. Particle Swarm Optimization

PSO adalah metode optimasi berbasis populasi yang pertama kali diperkenalkan oleh Eberhart dan Kennedy pada tahun 1995, yang terinspirasi dari perilaku kawanan burung dan sekolah ikan [20].

PSO adalah algoritma iteratif berbasis populasi. Populasi terdiri dari banyak partikel, di mana di inisialisasi dengan populasi solusi acak dan digunakan untuk memecahkan masalah. Setiap partikel mewakili solusi kandidat dan bergerak menuju posisi optimal dengan mengubah

posisinya sesuai dengan kecepatan partikel terbang melalui ruang pencarian dengan kecepatan yang dinamis disesuaikan untuk perilaku historis [21].

C. HASIL DAN PEMBAHASAN

Bagian ini membahas hasil klasifikasi daun nilam menggunakan metode GLCM, PSO, dan SVM. Tahapan yang dilakukan meliputi pra-pemrosesan citra, ekstraksi fitur tekstur menggunakan GLCM, optimasi parameter dengan PSO, serta klasifikasi menggunakan SVM. Analisis dilakukan terhadap empat kategori daun berdasarkan citra yang telah diklasifikasikan. Evaluasi mencakup akurasi dan performa model, serta efektivitas kombinasi metode dalam membedakan setiap jenis penyakit daun.

1. Processing data

Pada tahap pra-pemrosesan, dilakukan augmentasi data untuk menambah jumlah dan variasi citra daun nilam. Teknik yang digunakan meliputi *flip horizontal*, *flip vertical*, rotasi 90°, rotasi 180°, serta citra asli (original), sehingga setiap gambar menghasilkan lima versi. Langkah ini bertujuan meningkatkan keberagaman data dan mengurangi *overfitting*. Hasil augmentasi ditampilkan pada Gambar 3.




Gambar 3. Hasil augmentasi

2. Mengubah gambar ke grayscale

Seluruh citra hasil augmentasi kemudian dikonversi ke *grayscale* untuk menyederhanakan informasi menjadi satu kanal intensitas, sesuai kebutuhan ekstraksi fitur tekstur GLCM dan mengurangi kompleksitas komputasi

dibandingkan RGB. Bersama dengan *resize*, langkah ini mempersiapkan data untuk ekstraksi fitur dan klasifikasi. Hasilnya ditampilkan pada Gambar 4.



Gambar 4. Format gambar grayscale pada tanaman nilam

3. Ekstraksi fitur GLCM

Citra yang telah melalui tahap pra-pemrosesan kemudian Fitur GLCM diekstraksi dari seluruh dataset gambar sebanyak 2.080 citra daun nilam. Empat fitur utama yang digunakan dalam proses ini adalah *contrast*, *correlation*, *energy*, dan *homogeneity*. Masing-masing fitur memiliki makna tersendiri, di antaranya: *contrast* mengukur tingkat perbedaan intensitas antar piksel, *correlation* menunjukkan ketergantungan *linear* antara nilai piksel, *energy* mencerminkan keseragaman distribusi piksel, dan *homogeneity* mengukur kemiripan nilai piksel dalam gambar. Nilai-nilai hasil ekstraksi ini dihitung berdasarkan rata-rata dari empat arah (0°, 45°, 90°, dan 135°) dan disimpan dalam basis data sebagai representasi numerik dari ciri tekstur setiap citra. Data ini kemudian digunakan dalam proses klasifikasi dan identifikasi penyakit daun nilam. Rincian nilai setiap fitur disajikan dalam Tabel 1.

Tabel 1. Hasil ekstraksi fitur GLCM


No.	Filename	Contrast	Correlation	Energy	Homogeneity	Label
1	D1.png	-0.467	0.969	0.041	1.105	Daun Sehat
2	D2.png	10.15	1.032	0.078	0.977	Daun Sehat
3	D3.png	27.90	0.784	0.076	0.592	Penyakit Kuning
4	D4.png	33.16	0.877	0.032	0.548	Penyakit Kuning
5	D5.png	46.40	0.689	0.039	0.435	Bercak Daun
6	D6.png	47.06	0.673	0.028	0.528	Bercak Daun
...	...	...	...	...	...	...
2080	D6.png	705.273	0.7735	0.0042	0.4066	Mozaik

4. Hasil Pengujian Model

Data citra daun nilam yang telah melalui proses ekstraksi fitur menggunakan GLCM selanjutnya digunakan dalam tahap klasifikasi menggunakan algoritma SVM yang dioptimasi dengan PSO. Sebanyak 2.080 citra diklasifikasikan ke dalam empat kelas: sehat, bercak daun, kuning, dan mozaik. PSO berperan dalam menentukan parameter optimal SVM agar model mampu mengenali pola tekstur dengan lebih akurat. Evaluasi dilakukan menggunakan *confusion matrix* serta metrik *akurasi*, *presisi*, *recall*, dan *F1-score*.

a. Hasil Klasifikasi SVM

Model SVM dengan kernel RBF diuji untuk mengklasifikasikan empat kelas daun nilam: sehat, bercak daun, kuning, dan mozaik. Hasilnya ditampilkan dalam bentuk *confusion matrix* pada Gambar 5.




Gambar 5. Confusion matrix

Gambar 5 menunjukkan *confusion matrix* yang menggambarkan distribusi prediksi model terhadap data aktual. Dari matriks ini diperoleh jumlah prediksi benar dan salah yang digunakan untuk menghitung metrik evaluasi, sebagaimana ditampilkan pada Tabel 2.

Tabel 2. Hasil klasifikasi report

Kelas	Presisi	Recall	F1-score
Daun Sehat	1.00	0.90	0.95
Penyakit Bercak Daun	0.73	0.95	0.82
Penyakit Kuning	0.97	0.88	0.92
Penyakit Mozaik	0.97	0.86	0.91


Tabel 2 menunjukkan bahwa model memiliki performa baik pada sebagian besar kelas, meskipun masih ada kesalahan pada kelas bercak daun. Visualisasi performa model secara keseluruhan ditampilkan pada Gambar 6.



Gambar 6. Grafik Evaluasi Kinerja Model SVM Kernel RBF

Pada Gambar 6 ditampilkan hasil evaluasi model SVM dengan *kernel* RBF berdasarkan empat metrik klasifikasi, yaitu akurasi, *presisi*, *recall*, dan *F1-score*. Model menghasilkan akurasi sebesar 89,7%, *presisi* 91,6%, *recall* 89,7%, dan *F1-score* 90,1%. Nilai-nilai ini menunjukkan bahwa model memiliki performa yang cukup baik dan seimbang dalam mengklasifikasikan citra daun nilam ke dalam empat kategori, dengan *presisi* menjadi metrik tertinggi.

Selanjutnya, perbandingan antara hasil prediksi dan data aktual model SVM dapat dilihat pada Gambar 7.



Gambar 7. Grafik actual dan prediksi


Pada Gambar 7 di atas ditampilkan perbandingan antara kelas aktual dan hasil prediksi model SVM, lengkap dengan garis *error*. Grafik ini menunjukkan bahwa sebagian besar prediksi sesuai dengan data aktual, meskipun masih terdapat beberapa kesalahan klasifikasi. Visualisasi ini mendukung hasil evaluasi sebelumnya bahwa performa model cukup baik namun masih dapat ditingkatkan.

b. Hasil klasifikasi SVM menggunakan PSO

Setelah proses pelatihan dilakukan, model SVM dengan *kernel* RBF dioptimasi menggunakan algoritma PSO. Tujuan dari optimasi ini adalah untuk mencari parameter terbaik dari model,

khususnya nilai *C* dan *gamma*, agar performa klasifikasi dapat ditingkatkan.

Model yang telah dioptimasi kemudian diuji menggunakan data uji sebanyak 624 data yang terdiri dari empat kelas, yaitu daun sehat, penyakit bercak daun, penyakit kuning, dan penyakit mosaik. Hasil pengujian model ditampilkan dalam bentuk *confusion matrix*, seperti pada Gambar 8.



Gambar 8. Grafik *confusion matrix* SVM menggunakan PSO

Pada Gambar 8 ditampilkan *confusion matrix* yang menunjukkan hasil klasifikasi model terhadap data uji. Matriks ini menjadi dasar evaluasi untuk menghitung *precision*, *recall*, dan *F1-score*, yang dirangkum dalam Tabel 3.


Tabel 3. Hasil pengujian tiap kelas

Kelas	Presisi	Recall	F1-score
Daun Sehat	0.98	0.99	0.99
Penyakit Bercak Daun	0.96	0.95	0.95
Penyakit Kuning	0.97	0.97	0.97
Penyakit Mosaik	0.97	0.97	0.97

Berdasarkan tabel di atas, dapat dilihat bahwa model SVM yang telah dioptimasi menggunakan PSO mampu memberikan kinerja klasifikasi yang

sangat baik pada keempat kelas. Meskipun masih terdapat sedikit kesalahan klasifikasi, khususnya antara kelas Penyakit Bercak Daun dan kelas lainnya, nilai evaluasi tetap tinggi dan konsisten. Hal ini menunjukkan bahwa model bekerja dengan efektif dan stabil.

Sebagai pelengkap, visualisasi metrik evaluasi dalam bentuk grafik batang dapat dilihat pada Gambar 9 untuk memberikan representasi performa model secara keseluruhan.



Gambar 9. Grafik evaluasi SVM menggunakan PSO

Pada Gambar 9 menampilkan hasil evaluasi kinerja model SVM yang telah dioptimasi menggunakan *Particle Swarm Optimization* (PSO) untuk setiap kelas penyakit daun tanaman nilam. Evaluasi dilakukan dengan tiga metrik utama, yaitu *Precision*, *Recall*, dan *F1-Score*. Hasil menunjukkan bahwa model memiliki performa yang sangat baik di semua kelas, dengan nilai di atas 0,95. Kelas daun sehat memperoleh nilai tertinggi, dengan *F1-Score* sebesar 0,99, sedangkan kelas penyakit bercak daun memiliki nilai terendah, yaitu *F1-Score* 0,95, meskipun masih dalam kategori sangat baik. Kelas penyakit kuning dan penyakit mosaik menunjukkan nilai yang konsisten, masing-masing dengan skor *Precision*, *Recall*, dan *F1-Score* sebesar 0,97. Secara keseluruhan, model SVM+PSO mampu

mengklasifikasikan penyakit daun nilam secara akurat dan seimbang antar kelas.

5. Hasil Perbandingan SVM DAN PSO


Pada tahap ini dilakukan pengujian untuk membandingkan performa algoritma SVM sebelum dan sesudah dilakukan optimasi menggunakan metode PSO. Pengujian dilakukan terhadap data citra daun tanaman nilam yang telah diekstraksi menggunakan metode GLCM.

Berdasarkan hasil pengujian, akurasi klasifikasi menggunakan SVM tanpa PSO diperoleh sebesar 89,74%, sedangkan setelah dilakukan optimasi dengan PSO, akurasi meningkat signifikan menjadi 97,12%. Hal ini menunjukkan bahwa metode PSO mampu mengoptimalkan parameter SVM secara efektif, sehingga model yang dihasilkan dapat melakukan klasifikasi dengan lebih baik. Hasil perbandingan nilai akurasi antara SVM dan PSO ditampilkan pada tabel 4.

Tabel 4. perbandingan SVM dan PSO

Metode	Akurasi
SVM	89,74 %
SVM + PSO	97,12 %

Visualisasi perbandingan akurasi dari kedua metode tersebut ditampilkan pada gambar 10.



Gambar 10. Grafik perbandingan SVM dan SVM+PSO

Pada Gambar 10 menampilkan grafik perbandingan akurasi (*accuracy*) antara metode SVM tanpa optimasi dan SVM yang dioptimasi dengan PSO (SVM + PSO) pada dataset citra daun tanaman Nilam. Berdasarkan hasil pengujian, model SVM tanpa PSO menghasilkan akurasi sebesar 89,74%, sedangkan model SVM yang telah dioptimasi dengan PSO mencapai akurasi 97,12%.

Peningkatan akurasi ini menunjukkan bahwa algoritma PSO mampu meningkatkan performa SVM secara signifikan, dengan perbedaan akurasi mencapai sekitar 7,38%. Hal ini mengindikasikan bahwa parameter yang dihasilkan melalui proses optimasi PSO lebih optimal dalam memisahkan data antar kelas pada proses klasifikasi. Dengan demikian, metode SVM + PSO terbukti lebih unggul dibandingkan SVM standar dalam mengklasifikasikan penyakit pada daun tanaman Nilam.

D. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengimplementasikan metode *Gray Level Co-occurrence Matrix* (GLCM) terbukti efektif dalam mengekstraksi fitur tekstur dari citra daun tanaman Nilam, sedangkan algoritma *Support Vector Machine* (SVM) mampu mengklasifikasikan kondisi daun ke dalam empat kategori penyakit dengan hasil yang baik. Model SVM tanpa optimasi menghasilkan akurasi sebesar 89,74%, sedangkan setelah dioptimasi menggunakan *Particle Swarm Optimization* (PSO), akurasinya meningkat signifikan menjadi 97,12%. Peningkatan ini menunjukkan bahwa integrasi PSO mampu meningkatkan kinerja klasifikasi secara nyata. Untuk pengembangan selanjutnya, disarankan agar penelitian ini menggabungkan fitur

warna dan morfologi serta dikembangkan ke dalam bentuk aplikasi berbasis web atau mobile guna membantu petani mendeteksi penyakit secara cepat dan praktis di lapangan.

E. REFERENSI

- [1] T. R. Rahmayanti, W. P. Mariana, and H. Susanti, "Pengenalan Morfologi dan Taksonomi Daun Nilam di Desa Namo Sialang," *J. Pengabd. Kpd. Masy.*, vol. 4, no. 1, pp. 60–65, 2023, [Online]. Available: <https://jurnal.stkipalmaksum.ac.id/index.php/jpkm>
- [2] Z. Zulfadli, N. I. Wasistha, H. Oktarina, K. Khairan, and R. Sriwati, "Pathogens causing wilt diseases in patchouli plant (*Pogostemon cablin* Benth.): A review on symptoms, bioecology, and management," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 1183, no. 1, 2023, doi: 10.1088/1755-1315/1183/1/012027.
- [3] G. Gu *et al.*, "Continuous cropping of Patchouli alters soil physiochemical properties and rhizosphere microecology revealed by metagenomic sequencing," *Front. Microbiol.*, vol. 15, 2024, doi: 10.3389/fmicb.2024.1482904.
- [4] S. Suharyana, F. Anwar, A. C. Dewi, M. Yunianto, U. Salamah, and R. Chai, "Pneumonia Classification Based on GLCM Features Extraction using K-Nearest Neighbor," *Indones. J. Appl. Phys.*, vol. 13, no. 2, p. 325, 2023, doi: 10.13057/ijap.v13i2.77120.
- [5] E. Nahak, R. P. Putra, and F. Marisa, "Klasifikasi Penyakit Pada

- Tanaman Apel Melalui Citra Daun Menggunakan Metode Multiclass Support Vector Machine,” *J. Tek. Inform. Sist. Inf.*, vol. 11, no. 3, pp. 401–408, 2024, [Online]. Available: <http://jurnal.mdp.ac.id>
- [6] Irene Oktaviani Duka, Huan Arthur Ado, and Yampi R.Kaesmetan, “Identifikasi Penyakit Tanaman Citra Daun Cabe Menggunakan Gray Level Co-Occurrence Matrix Dan Support Vector Machine,” *Neptunus J. Ilmu Komput. Dan Teknol. Inf.*, vol. 2, no. 2, pp. 41–52, 2024, doi: 10.61132/neptunus.v2i2.86.
- [7] A. Tabbakh and S. S. Barpanda, “Evaluation of Machine Learning Models for Plant Disease Classification Using Modified GLCM and Wavelet Based Statistical Features,” *Trait. du Signal*, vol. 39, no. 6, pp. 1893–1905, 2022, doi: 10.18280/ts.390602.
- [8] M. Jamjoom, A. Elhadad, H. Abulkasim, and S. Abbas, “Plant Leaf Diseases Classification Using Improved K-Means Clustering and SVM Algorithm for Segmentation,” *Comput. Mater. Contin.*, vol. 76, no. 1, pp. 367–382, 2023, doi: 10.32604/cmc.2023.037310.
- [9] P. M. Dinesh, “Texture image classification using hybridization of glcm and glwm features,” *Int. J. Sci. Technol. Res.*, vol. 9, no. 4, pp. 3216–3219, 2020.
- [10] L. lin Zhang, D. jian He, and H. bo Song, “Automatic tracking of multi-fruit targets with oscillation under natural growth conditions,” *Inf. Process. Agric.*, vol. 7, no. 4, pp. 546–555, 2020, doi: 10.1016/j.inpa.2019.11.004.
- [11] R. Andrian, D. Maharani, M. A. Muhammad, and A. Junaidi, “Butterfly identification using gray level co-occurrence matrix (Glcm) extraction feature and k-nearest neighbor (knn) classification,” *Regist. J. Ilm. Teknol. Sist. Inf.*, vol. 6, no. 1, pp. 11–21, 2020, doi: 10.26594/register.v6i1.1602.
- [12] E. D. Hartono and B. Hardiansyah, “Analisis Intensitas Cahaya Lampu Pijar dengan Menerapkan Metode Gray Level Co-occurrence Matrik,” *J. Sist. Komput. dan Inform.*, vol. 4, no. 2, p. 407, 2022, doi: 10.30865/json.v4i2.5366.
- [13] R. Cicchi, E. Baria, M. Mari, G. Filippidis, and D. Chorvat, “Extraction of collagen morphological features from second-harmonic generation microscopy images via GLCM and CT analyses: A cross-laboratory study,” *J. Biophotonics*, vol. 17, no. 8, pp. 1–11, 2024, doi: 10.1002/jbio.202400090.
- [14] M. Kabir, F. Unal, T. C. Akinci, A. A. Martinez-Morales, and S. Ekici, “Revealing GLCM Metric Variations across a Plant Disease Dataset: A Comprehensive Examination and Future Prospects for Enhanced Deep Learning Applications,” *Electron.*, vol. 13, no. 12, 2024, doi: 10.3390/electronics13122299.
- [15] H. H. Fauziah, D. R. Ningtias, B. Wahyudi, and ..., “Identification of lung cancer using gray level co-occurrence matrix (GLCM) and artificial neural network with backpropagation algorithm,” *J. Soft ...*, pp. 51–61, 2025, [Online]. Available:

- <https://shmpublisher.com/index.php/joscex/article/view/543%0Ahttps://shmpublisher.com/index.php/joscex/article/download/543/303> 144, 2025, doi: 10.37058/jeeee.v6i2.14644.
- [16] F. Putrawansyah, “Penerapan Metode Support Vector Machine Terhadap Klasifikasi Jenis Jambu Biji,” *JIKO (Jurnal Inform. dan Komputer)*, vol. 8, no. 1, p. 193, 2024, doi: 10.26798/jiko.v8i1.988.
 - [17] D. Udjulawa, “Klasifikasi Tanaman Hias Berdasarkan Tekstur Daun Menggunakan Metode Svm Dan Fitur Glcm,” *Klik - J. Ilmu Komput.*, vol. 3, no. 2, pp. 121–127, 2023, doi: 10.56869/klik.v3i2.418.
 - [18] S. Rabbani, D. Safitri, N. Rahmadhani, A. A. F. Sani, and M. K. Anam, “Perbandingan Evaluasi Kernel SVM untuk Klasifikasi Sentimen dalam Analisis Kenaikan Harga BBM,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 2, pp. 153–160, 2023, doi: 10.57152/malcom.v3i2.897.
 - [19] S. Rahayu and Y. Yamasari, “Klasifikasi Penyakit Stroke dengan Metode Support Vector Machine (SVM),” *J. Informatics Comput. Sci.*, vol. 5, no. 03, pp. 440–446, 2024, doi: 10.26740/jinacs.v5n03.p440-446.
 - [20] A. K. Balyan *et al.*, “A Hybrid Intrusion Detection Model Using EGA-PSO and Improved Random Forest Method,” *Sensors*, vol. 22, no. 16, pp. 1–20, 2022, doi: 10.3390/s22165986.
 - [21] M. I. Malik, “Optimization Design of Single-Tuned Passive Filter Using Particle Swarm Optimization Algorithm in Industry,” *J. Energy Electr. Eng.*, vol. 6, no. 2, pp. 137–