



Klasifikasi Citra Penyakit Daun Anggur Menggunakan *Radial Basis Function Neural Networks*

Moh. Erkamim^{1*}, Yanuardi², Mohammad Imam Shalahudin³, Arisantoso⁴

¹Program Studi Sistem Informasi Kota Cerdas, Universitas Tunas Pembangunan Surakarta, Surakarta, Indonesia

²Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Tangerang, Tangerang, Indonesia

³Program Studi Sistem Informasi, Sekolah Tinggi Teknologi Informasi NIIT, Jakarta Selatan, Indonesia

⁴Program Studi Teknik Informatika, Sekolah Tinggi Teknologi Informasi NIIT, Jakarta Selatan, Indonesia

Email: ^{1,*}erkamim@lecture.utp.ac.id, ²yanuardi99@gmail.com, ³imamshalahudin@gmail.com, ⁴arisantoso2008@gmail.com

Email Penulis Korespondensi: erkamim@lecture.utp.ac.id

Abstrak—Anggur merupakan salah satu komoditas hortikultura penting di Indonesia, namun produktivitasnya sering terganggu oleh penyakit daun yang berdampak pada kualitas dan kuantitas hasil panen. Identifikasi penyakit secara manual masih membutuhkan waktu yang lama, memerlukan keahlian khusus, dan seringkali menghasilkan diagnosis yang tidak konsisten. Tantangan seperti kelelahan, variasi pengalaman, serta perbedaan visual penyakit daun menjadi hambatan dalam melakukan diagnosis yang cepat dan akurat. Oleh karena itu, penelitian ini berfokus pada pengembangan model klasifikasi otomatis penyakit daun anggur menggunakan algoritma *Radial Basis Function Neural Networks* (RBFNN). Model ini memanfaatkan ekstraksi fitur warna dengan *Mean Color* untuk mendeteksi perubahan distribusi warna pada daun yang terinfeksi, serta GLCM (*Gray Level Co-occurrence Matrix*) untuk menganalisis pola tekstur yang menjadi penanda penyakit. Proses klasifikasi dilakukan oleh algoritma RBFNN melalui penghitungan jarak antara input dan pusat neuron menggunakan fungsi basis radial pada hidden layer. Hasil penelitian menunjukkan bahwa model ini mampu mengklasifikasikan penyakit daun anggur dengan akurasi keseluruhan sebesar 92,5%, menandakan bahwa model tersebut sangat efektif dalam mendeteksi dan mengklasifikasikan daun sehat maupun yang terinfeksi penyakit dengan tingkat kesalahan yang minim.

Kata Kunci: Penyakit Daun Anggur, RBFNN, *Mean Color*, GLCM, Klasifikasi Citra

Abstract—Grapes are one of the important horticultural commodities in Indonesia, but their productivity is often disrupted by leaf diseases that affect both the quality and quantity of the harvest. Manual disease identification remains time-consuming, requires specialized expertise, and often results in inconsistent diagnoses. Challenges such as fatigue, varying levels of experience, and visual differences in leaf diseases hinder the ability to perform fast and accurate diagnosis. Therefore, this study focuses on developing an automatic grape leaf disease classification model using the Radial Basis Function Neural Networks (RBFNN) algorithm. The model utilizes color feature extraction through Mean Color to detect changes in the color distribution of infected leaves, as well as GLCM (Gray Level Co-occurrence Matrix) to analyze texture patterns that serve as disease indicators. The classification process is conducted by the RBFNN algorithm, which calculates the distance between inputs and neuron centers using radial basis functions in the hidden layer. The results of this study show that the model is capable of classifying grape leaf diseases with an overall accuracy of 92.5%, indicating that the model is highly effective in detecting and classifying both healthy and infected leaves with minimal errors.

Keywords: Grape Leaf Disease, RBFNN, Mean Color, GLCM, Image Classification

1. PENDAHULUAN

Anggur merupakan salah satu komoditas hortikultura yang memiliki potensi besar untuk dikembangkan di Indonesia. Menurut data dari Badan Pusat Statistik (BPS), produksi anggur di Indonesia pada tahun 2023 mencapai 13.405 ton [1]. Daerah penghasil anggur utama di Indonesia meliputi Bali, Jawa Timur, dan Nusa Tenggara Barat, di mana Bali menjadi kontributor terbesar dengan produksi sebesar 4.500-ton pada tahun yang sama. Meskipun permintaan akan anggur di Indonesia terus meningkat, terutama di pasar ritel dan sektor pariwisata, produktivitas anggur dalam negeri masih menghadapi berbagai tantangan. Salah satu faktor utama yang mempengaruhi produktivitas anggur adalah serangan penyakit daun, yang dapat berdampak signifikan terhadap kualitas dan kuantitas hasil produksi [2]. Proses identifikasi penyakit secara manual masih memakan waktu yang lama, membutuhkan keahlian khusus, dan sering kali menghasilkan diagnosis yang tidak konsisten. Faktor-faktor seperti kelelahan, perbedaan pengalaman, dan variasi visual penyakit pada daun menjadi tantangan dalam penegakan diagnosis yang tepat dan cepat. Kesalahan dalam klasifikasi atau keterlambatan dalam diagnosis dapat memperparah kondisi tanaman dan meningkatkan risiko kerugian finansial bagi petani [3]. Dalam kondisi seperti ini, metode manual tidak lagi cukup efisien untuk menghadapi skala industri dan permintaan pasar yang semakin tinggi. Oleh karena itu, diperlukan sistem klasifikasi otomatis berbasis teknologi yang mampu melakukan deteksi dan diagnosis penyakit secara cepat, konsisten, dan akurat. Untuk menjawab tantangan ini, teknologi pengolahan citra digital dan kecerdasan buatan (*artificial intelligence*) menawarkan solusi yang lebih efisien dan akurat.

Berbagai penelitian telah mengaplikasikan kecerdasan buatan dalam klasifikasi penyakit tanaman dengan menggunakan fitur-fitur citra daun. Penelitian sebelumnya mengenai penggunaan *K-Nearest Neighbors* (KNN) untuk mengidentifikasi penyakit daun mentimun mencapai akurasi sebesar 76,67% [4]. Namun metode KNN sensitif terhadap *outlier* dan membutuhkan sumber daya komputasi yang besar untuk dataset yang kompleks. Sebuah studi yang menggunakan *Support Vector Machine* (SVM) untuk klasifikasi penyakit daun mangga mendapatkan akurasi sebesar 80% [5]. Efektivitas SVM dalam tugas ini sangat bergantung pada pemilihan parameter yang tepat, seperti kernel, dan parameter lainnya. Penelitian menggunakan jaringan syaraf *Extreme Learning Machine* (ELM) berhasil mengidentifikasi penyakit daun tomat dengan akurasi 84,667% [6]. Meskipun demikian, bobot input yang acak dalam ELM dapat memengaruhi kinerjanya. Di sisi lain, penelitian mengenai deteksi penyakit daun tomat menggunakan jaringan syaraf



Backpropagation juga mencapai akurasi yang lebih tinggi, yaitu 91% [7]. Namun, algoritma ini sering menghadapi masalah konvergensi, yang memperlambat pelatihan atau menyebabkan terjebak pada minimum lokal.

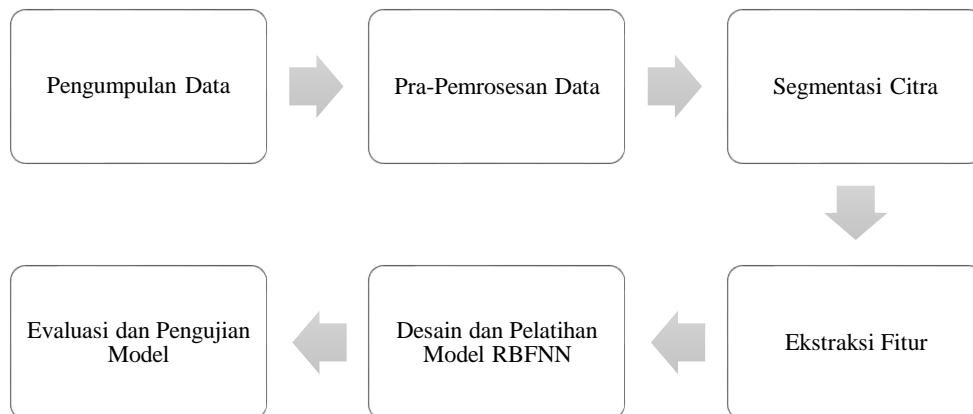
Berdasarkan penelitian sebelumnya, penggunaan jaringan syaraf tiruan telah menunjukkan kemampuan dalam mempelajari dan mengenali pola kompleks dari data pelatihan yang diberikan. Citra daun memiliki karakteristik yang kompleks dan data yang terbatas, sehingga diperlukan jaringan syaraf non-linear dengan satu lapisan tersembunyi untuk menangkap fitur visual yang rumit sambil tetap mampu belajar dari data yang terbatas [8]. Algoritma *Radial Basis Function Neural Networks* (RBFNN) sangat cocok untuk klasifikasi yang melibatkan data yang kompleks atau memiliki pola non-linear, seperti pada kasus penyakit daun anggur. Algoritma RBFNN dipilih dalam penelitian ini karena memiliki keunggulan yang signifikan dibandingkan metode jaringan syaraf tiruan lainnya. Salah satu keunggulan utama RBFNN adalah kemampuan pembelajarannya yang lebih cepat [9]. Berbeda dengan metode jaringan syaraf tiruan yang menggunakan *backpropagation* yang sering kali memerlukan banyak iterasi untuk menyesuaikan bobot, RBFNN cenderung lebih efisien karena menggunakan fungsi basis radial sebagai aktivasi neuron tersembunyi [10]. Fungsi ini memungkinkan jaringan untuk secara langsung memetakan *input* ke *output* dengan lebih cepat dan akurat.

Perbedaan penelitian ini dengan penelitian sebelumnya terletak pada fokus klasifikasi penyakit daun anggur menggunakan algoritma *Radial Basis Function Neural Networks* (RBFNN), serta ekstraksi fitur warna menggunakan *Mean Color* dan ekstraksi tekstur dengan *Gray Level Co-occurrence Matrix* (GLCM). Metode *Mean Color* digunakan untuk menghitung nilai rata-rata dari masing-masing komponen warna untuk mendapatkan informasi distribusi warna pada citra. Sedangkan metode GLCM digunakan untuk menghitung seberapa sering dua piksel dengan nilai intensitas tertentu muncul berdampingan pada jarak dan orientasi tertentu. Fitur yang telah didapatkan selanjutnya menjadi masukan algoritma RBFNN untuk melakukan klasifikasi dengan memetakan input ke ruang fitur berdimensi lebih tinggi, sehingga dapat memisahkan data yang tidak dapat dipisahkan secara linear di ruang input asli. Maka, tujuan dari penelitian ini adalah mengembangkan model klasifikasi penyakit daun anggur berdasarkan citranya menggunakan algoritma *Radial Basis Function Neural Networks* (RBFNN) serta ekstraksi fitur menggunakan *Mean Color* dan GLCM. Melalui model yang dibangun akan berkontribusi terhadap pengembangan model untuk klasifikasi citra khususnya untuk penyakit daun anggur dengan memanfaatkan pengolahan citra digital melalui kecerdasan buatan dan jaringan syaraf tiruan.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Tahapan penelitian menyediakan kerangka kerja yang memandu peneliti dari awal hingga akhir, memastikan penelitian dilakukan secara logis dan koheren [11]. Langkah-langkah untuk melakukan penelitian ini ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

a. Pengumpulan Data

Tahap awal penelitian ini melibatkan pengumpulan dataset citra daun teh, yang mencakup sampel daun sehat dan daun yang terinfeksi berbagai penyakit. Dataset yang digunakan adalah "Leaf Disease Dataset", sebuah dataset yang tersedia secara publik dan dapat diakses di Kaggle (<https://www.kaggle.com/datasets/asheniranga/leaf-disease-dataset-combination>) [12]. Penelitian ini berfokus pada empat kelas kondisi daun anggur: daun sehat, black rot, black measles, dan leaf blight. Total dataset terdiri dari 1.600 gambar, yang kemudian dibagi menjadi data pelatihan dan pengujian dengan rasio 80:20. Pembagian ini menghasilkan 1.280 gambar untuk data pelatihan (320 gambar per kelas) dan 320 gambar untuk data pengujian (80 gambar per kelas). Distribusi yang seimbang ini memastikan representasi yang memadai untuk setiap kelas dalam pelatihan dan evaluasi model.

b. Pre-Processing Data

Setelah data dikumpulkan, langkah selanjutnya adalah melakukan pra-pemrosesan data. Tahap ini bertujuan untuk meningkatkan kualitas gambar dan mempersiapkannya untuk proses ekstraksi fitur [13]. Proses ini bisa meliputi perubahan ukuran gambar, normalisasi intensitas cahaya, dan transformasi warna ke ruang warna CIELAB. Selain



itu, pembersihan data dari noise atau elemen yang tidak relevan dilakukan untuk memastikan bahwa gambar yang akan dianalisis berkualitas baik dan siap digunakan untuk tahap selanjutnya.

c. Segmentasi Citra

Segmentasi merupakan proses penting untuk memisahkan objek utama dari latar belakangnya [14]. Pada tahap ini, metode segmentasi seperti *Otsu's Thresholding* digunakan untuk secara otomatis membedakan bagian *foreground* (daun) dari *background*. Dengan segmentasi yang baik, citra akan siap untuk tahap ekstraksi fitur, dengan fokus hanya pada area yang relevan.

d. Ekstraksi Fitur

Ekstraksi fitur bertujuan mengidentifikasi karakteristik penting pada citra kemudian digunakan oleh model machine learning untuk membedakan antara kelas yang berbeda [15]. Fitur yang diekstraksi meliputi fitur warna dan tekstur. Fitur warna diperoleh menggunakan metode *Mean Color* di ruang warna CIELAB, yang memisahkan informasi warna dari intensitas cahaya, sehingga variasi warna pada daun yang terinfeksi bisa dianalisis lebih baik. Sementara itu, fitur tekstur diekstraksi menggunakan *Gray Level Co-occurrence Matrix* (GLCM), yang menganalisis hubungan spasial antar-*pixel* untuk menangkap pola tekstur yang relevan dengan kondisi daun.

e. Desain dan Pelatihan Model RBFNN

Tahap ini mencakup desain dan pelatihan model jaringan syaraf tiruan berbasis *Radial Basis Function Neural Networks* (RBFNN). RBFNN dipilih karena kemampuannya dalam menangani data non-linear dan kecepatan dalam proses pelatihan [16]. Model RBFNN dirancang dengan menggunakan fitur-fitur yang telah diekstraksi sebelumnya untuk mengidentifikasi pola yang ada dalam dataset. Proses pelatihan melibatkan pemberian data latih kepada model, di mana model akan belajar mengidentifikasi hubungan antara fitur yang ada dan kelas penyakit yang sesuai.

f. Evaluasi dan Pengujian Model

Setelah model RBFNN dilatih, tahap terakhir adalah evaluasi dan pengujian model. Model yang telah dilatih diuji menggunakan data uji untuk mengukur performanya dalam mengklasifikasikan penyakit daun anggur. Pada tahap ini, berbagai metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score* digunakan untuk menilai seberapa baik model mampu mengklasifikasikan gambar-gambar yang tidak dilihat sebelumnya. Nilai-nilai evaluasi tersebut didapatkan dari *confusion matrix*. *Confusion matrix* adalah tabel yang menunjukkan hasil klasifikasi model dengan membandingkan prediksi model terhadap hasil sebenarnya dari data uji [17]. Hasil dari evaluasi ini akan memberikan gambaran tentang efektivitas model dalam mendeteksi dan mengklasifikasikan penyakit daun anggur secara otomatis.

2.2 Mean Color

Mean Color merupakan salah satu metode sederhana namun efektif yang digunakan dalam ekstraksi fitur warna pada pengolahan citra digital. Metode ini menghitung nilai rata-rata intensitas warna pada masing-masing saluran warna dari suatu ruang warna tertentu [18]. Dalam konteks pengolahan citra daun anggur, *Mean Color* dapat membantu menggambarkan distribusi warna pada area daun yang terinfeksi, sehingga menjadi fitur penting dalam proses klasifikasi.

Salah satu ruang warna yang sering digunakan dalam pengolahan citra adalah CIELAB, yang memisahkan informasi warna menjadi tiga komponen: L^* (luminansi atau intensitas cahaya), a^* (rentang warna hijau ke merah), dan b^* (rentang warna biru ke kuning) [19]. *Mean Color* pada ruang warna CIELAB dihitung dengan cara mengambil rata-rata dari nilai intensitas masing-masing komponen L^* , a^* , dan b^* .

$$\mu_{color} = \frac{1}{N} \sum_{i=1}^N p_i \quad (1)$$

di mana μ_{color} adalah nilai rata-rata untuk salah satu komponen warna (L^* , a^* , atau b^*), N adalah jumlah total piksel dalam area tersegmentasi, dan p_i adalah intensitas komponen warna (L^* , a^* , atau b^*) pada piksel ke- i .

2.3 Gray Level Co-occurrence Matrix (GLCM)

Gray Level Co-occurrence Matrix (GLCM) adalah metode yang banyak digunakan dalam ekstraksi fitur tekstur pada pengolahan citra digital [20]. GLCM menganalisis hubungan spasial antar pasangan piksel dengan nilai intensitas tertentu dalam suatu citra [21]. Dengan cara ini, GLCM mampu menggambarkan pola tekstur dalam sebuah gambar yang sangat penting untuk proses klasifikasi citra.

GLCM dibentuk dengan menghitung frekuensi kemunculan pasangan piksel dengan nilai intensitas tertentu dalam jarak dan orientasi yang ditentukan. Dari GLCM ini, beberapa parameter tekstur dapat diekstraksi, seperti: *contrast*, *dissimilarity*, *homogeneity*, *energy*, dan *correlation*. Berikut adalah penjelasan untuk masing-masing parameter:

a. *Contrast*

Contrast mengukur variasi intensitas antara sebuah piksel dan piksel di sekitarnya. Semakin besar nilai *contrast*, semakin besar perbedaan intensitas antara piksel yang berdekatan, yang menandakan tekstur yang lebih kasar. Untuk mendapatkan nilai parameter ini digunakan persamaan (2).

$$Contrast = \sum_{i,j} (i - j)^2 P(i, j) \quad (2)$$

di mana $P(i, j)$ mewakili nilai dalam matriks GLCM untuk pasangan intensitas i dan j .

b. *Dissimilarity*

Dissimilarity adalah parameter yang mirip dengan *contrast*, tetapi hanya memperhitungkan perbedaan absolut antara intensitas piksel, sehingga menekankan tingkat ketidaksamaan intensitas.

$$Dissimilarity = \sum_{i,j} |i - j| P(i, j) \quad (3)$$



di mana $P(i, j)$ menunjukkan entri dalam GLCM yang sesuai dengan pasangan intensitas (i, j) .

c. *Homogeneity*

Homogeneity mengukur kedekatan distribusi elemen-elemen dalam GLCM dengan diagonal utama (di mana nilai intensitasnya sama). Semakin dekat nilai ke diagonal utama, semakin besar nilai *homogeneity*, yang menandakan tekstur yang lebih seragam.

$$\text{Homogeneity} = \sum_{i,j} \frac{P(i,j)}{1+|i-j|} \quad (4)$$

di mana $P(i, j)$ mewakili nilai dalam matriks GLCM untuk pasangan intensitas i dan j .

d. *Energy*

Energy mengukur tingkat pengulangan pola dalam citra. Nilai *energy* yang tinggi menunjukkan adanya pola berulang yang kuat dalam citra, dan energi dihitung dari kuadrat elemen GLCM.

$$\text{Energy} = \sum_{i,j} P(i,j)^2 \quad (5)$$

di mana $P(i, j)$ mewakili nilai dalam matriks GLCM untuk pasangan intensitas i dan j .

e. *Correlation*

Correlation mengukur hubungan antara intensitas piksel di seluruh citra. Jika piksel di sekitarnya memiliki intensitas yang mirip, nilai *correlation* akan tinggi.

$$\text{Correlation} = \sum_{i,j} \frac{(i-\mu_i)(j-\mu_j)P(i,j)}{\sigma_i\sigma_j} \quad (6)$$

di mana μ_i dan μ_j masing-masing melambangkan nilai intensitas rata-rata untuk i dan j , sementara σ_i dan σ_j melambangkan standar deviasi yang bersesuaian.

2.4 Radial Basis Function Neural Networks (RBFNN)

Radial Basis Function Neural Networks (RBFNN) adalah jenis jaringan syaraf tiruan yang digunakan untuk masalah klasifikasi, regresi, dan pengenalan pola [22]. RBFNN bekerja dengan memetakan input non-linear ke ruang fitur berdimensi lebih tinggi melalui fungsi basis radial [23]. Dalam jaringan ini, lapisan tersembunyi terdiri dari neuron yang menggunakan fungsi basis radial, seperti Gaussian, untuk menghitung jarak antara input dan pusat neuron, kemudian menghitung aktivasi neuron berdasarkan jarak tersebut.

Jaringan *Radial Basis Function Neural Networks* (RBFNN) terdiri dari tiga lapisan utama. Pertama, lapisan input, yang berfungsi untuk menerima data input dari luar sistem. Data ini kemudian diteruskan ke lapisan tersembunyi, di mana fungsi basis radial diterapkan untuk menghitung aktivasi setiap neuron berdasarkan jarak antara input dan pusat neuron. Terakhir, lapisan output bertugas untuk menggabungkan nilai aktivasi yang dihasilkan oleh lapisan tersembunyi guna menghasilkan output akhir yang menjadi hasil prediksi atau klasifikasi dari jaringan. Aktivasi fungsi basis radial biasanya berbentuk Gaussian dengan persamaan (7).

$$\phi(x) = \exp\left(-\frac{\|x-c\|^2}{2\sigma^2}\right) \quad (7)$$

di mana $\phi_j(x)$ adalah keluaran dari fungsi basis radial, x adalah input, c adalah pusat dari fungsi basis radial, σ adalah parameter lebar fungsi Gaussian (variansi), $\|x - c_j\|$ adalah jarak Euclidean antara input x dan pusat c .

Lapisan output kemudian menggunakan kombinasi linear dari aktivasi neuron di lapisan tersembunyi untuk menghasilkan output akhir, yang dapat dituliskan melalui persamaan (8).





$$y(x) = \sum_{i=1}^n w_i \cdot \phi_i(x) \quad (8)$$

di mana $y(x)$ adalah output dari jaringan RBFNN, w_i adalah bobot yang menghubungkan neuron di lapisan tersembunyi dengan neuron di lapisan output, $\phi_i(x)$ adalah keluaran dari fungsi basis radial untuk neuron i .

3. HASIL DAN PEMBAHASAN

Untuk mengembangkan model klasifikasi citra penyakit daun anggur menggunakan *Radial Basis Function Neural Networks* (RBFNN), langkah pertama adalah menyiapkan dataset yang akan digunakan untuk proses pelatihan dan pengujian model. Penelitian ini memanfaatkan dataset publik "Leaf Disease Dataset", sebuah dataset yang tersedia secara publik dan dapat diakses di Kaggle (<https://www.kaggle.com/datasets/asheniranga/leaf-disease-dataset-combination>) [12]. Penelitian ini menitikberatkan pada empat kategori kondisi daun anggur: daun sehat, black rot, black measles, dan leaf blight. Dataset yang digunakan berjumlah 1.600 gambar, yang dibagi menjadi data pelatihan dan data pengujian dengan rasio 80:20. Hasil pembagian ini adalah 1.280 gambar untuk pelatihan (320 gambar per kelas) dan 320 gambar untuk pengujian (80 gambar per kelas). Untuk memberikan gambaran visual dari dataset yang digunakan, beberapa contoh citra representatif dari masing-masing kategori ditampilkan dalam Tabel 1.

Tabel 1. Sampel Citra Dataset Yang Digunakan

No	Nama Kelas	Sampel Citra
1	Daun Sehat	
2	Black Rot	
3	Black Measles	
4	Leaf Blight	

Dataset yang ditunjukkan dalam Tabel 1 menjadi dasar penting dalam pengembangan model klasifikasi. Proses pelatihan dan pengujian merupakan bagian krusial dalam membangun model klasifikasi citra penyakit daun anggur, di mana model belajar memahami pola dan karakteristik spesifik dari berbagai jenis daun anggur. Langkah awal dalam proses ini adalah mengubah citra RGB diubah menjadi citra CIELAB. Transformasi ke ruang warna CIELAB dipilih karena kemampuannya yang lebih akurat dalam merepresentasikan persepsi visual manusia. Ruang warna ini unggul dalam memisahkan informasi warna dari intensitas, sehingga lebih efektif dalam pengolahan citra penyakit tanaman. Penggunaan komponen L, a, dan b memungkinkan isolasi informasi warna dan intensitas dengan lebih efisien, yang pada akhirnya meningkatkan performa algoritma dalam ekstraksi fitur dan segmentasi citra, terutama dalam penelitian klasifikasi citra berbasis daun. Untuk memberikan ilustrasi proses transformasi ini, hasil konversi dari citra RGB ke CIELAB ditampilkan pada Gambar 2.



(a)




(b)

Gambar 2. (a) Gambar Asli dan (b) Transformasi Gambar CIELAB




Gambar 2 memperlihatkan proses transformasi citra asli ke dalam format CIELAB, yang secara efisien memisahkan informasi warna dari intensitas. Tahap berikutnya adalah segmentasi, yang bertujuan untuk menghilangkan elemen yang tidak relevan dari citra, seperti noise latar belakang, bayangan, atau elemen lain yang tidak penting untuk analisis. Segmentasi ini sangat berguna untuk mempersiapkan citra sebelum memasuki tahap klasifikasi. Pada penelitian ini, digunakan metode *Otsu's Thresholding* untuk secara otomatis memisahkan citra menjadi dua bagian utama, yaitu foreground (objek daun) dan background. Metode ini bekerja dengan mencari nilai ambang optimal yang memaksimalkan varians antar kelas sehingga pemisahan objek utama dan latar belakang lebih efektif. Untuk memperjelas hasil segmentasi, Gambar 3 menunjukkan dua jenis keluaran: hasil segmentasi dan hasil segmentasi yang tetap mempertahankan karakteristik citra CIELAB.



Gambar 3. (a) Hasil Segmentasi dan (b) Segmentasi Dengan Mempertahankan Karakteristik CIELAB


Gambar 3 menunjukkan hasil citra yang telah tersegmentasi, dimana objek utama dan latar belakang dilakukan pemisahan. Setelah segmentasi, tahap berikutnya adalah ekstraksi fitur dari citra yang sudah diproses, terutama fitur warna dan tekstur. Analisis fitur warna dilakukan menggunakan metode *Mean Color*, yang menghitung rata-rata intensitas warna untuk setiap kanal dalam ruang warna. Dalam ruang warna CIELAB, rata-rata ini dihitung untuk komponen L^* , a^* , dan b^* . Hasil lengkap dari ekstraksi fitur warna tercantum dalam Tabel 2.

Tabel 2. Hasil Ekstraksi Fitur Dengan *Mean Color*

Citra Tersegmentasi	Parameter	Nilai
	L^*	129.1812
	a^*	121.1336
	b^*	139.1990


Pada Tabel 2, memperlihatkan hasil ekstraksi fitur warna menggunakan *Mean Color* dengan menampilkan nilai mean untuk masing-masing kanal yaitu L^* , a^* , dan b^* . Untuk karakteristik tekstur, digunakan teknik *Gray Level Co-occurrence Matrix (GLCM)*, yang menganalisis frekuensi kemunculan pasangan piksel dengan intensitas tertentu pada jarak dan orientasi yang telah ditentukan. Fitur tekstur diperoleh berdasarkan parameter seperti *contrast*, *dissimilarity*, *homogeneity*, *energy*, dan *correlation*. Hasil kuantitatif dari ekstraksi tekstur ini dirangkum dalam Tabel 3.

Table 3. Hasil Ekstraksi Fitur Dengan GLCM

Citra Tersegmentasi	Parameter	Nilai
	Contrast	331.9294
	Dissimilarity	0.8981
	Homogeneity	0.0974
	Energy	13.0162
	Correlation	0.0001



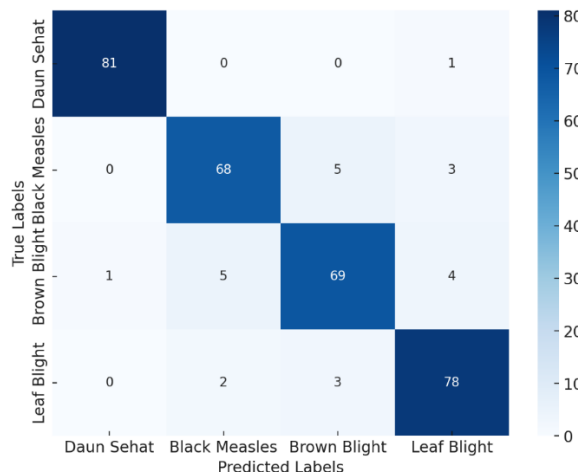
Tabel 3 menunjukkan citra daun lada dengan fitur yang diekstraksi berdasarkan GLCM, memberikan nilai untuk parameter yang digunakan untuk mendapatkan informasi mengenai tekstur dari citra tersebut. Langkah berikutnya adalah merancang arsitektur model RBFNN, termasuk menentukan jumlah neuron di lapisan tersembunyi dan fungsi basis radial yang akan digunakan, seperti fungsi Gaussian. *Radial Basis Function Neural Networks* (RBFNN) bekerja dengan memproses data input melalui fungsi basis radial di lapisan tersembunyi, yang menghitung jarak antara input dan pusat neuron. Setiap neuron di lapisan tersembunyi memiliki fungsi aktivasi yang menghasilkan output berdasarkan jarak antara input dan neuron tersebut. Lapisan input terdiri dari 4 neuron, yang masing-masing mewakili fitur yang diekstraksi menggunakan *Mean Color* dan GLCM. Lapisan tersembunyi menggunakan 20 neuron dengan fungsi aktivasi Gaussian. Lapisan output terdiri dari 4 neuron, yang masing-masing mewakili kelas (Daun Sehat, *Bacterial Spot*, *Cercospora Leaf Spot*, *Anthracnose*). Model yang dibangun kemudian dilatih menggunakan 320 gambar. Arsitektur RBFNN yang dibangun divisualisasikan pada Gambar 4.



Gambar 3. Arsitektur *Radial Basis Function Neural Networks* (RBFNN)

Gambar 4 merupakan visualisasi arsitektur jaringan syaraf *Radial Basis Function Neural Networks* (RBFNN), yang terdiri dari tiga lapisan utama: lapisan input, lapisan tersembunyi, dan lapisan output. Lapisan input menerima fitur-fitur dari data gambar daun anggur, seperti dua fitur utama yang dilabeli sebagai I1 dan I2. Fitur-fitur ini kemudian diproses oleh lapisan tersembunyi yang terdiri dari 10 neuron (H1 hingga H10), di mana neuron-neuron ini menggunakan fungsi aktivasi radial untuk mengukur kesesuaian data input dengan prototipe yang telah dilatih. Akhirnya, lapisan output yang terdiri dari 4 neuron (O1 hingga O4) memberikan hasil klasifikasi gambar ke dalam empat kelas: Daun Sehat, Black Rot, Black Measles, dan Leaf Blight. Proses ini menunjukkan bagaimana RBFNN memetakan data gambar ke hasil klasifikasi akhir dengan menggunakan pola yang dipelajari di lapisan tersembunyi.

Selanjutnya, model yang telah dibangun kemudian dilakukan evaluasi. Dalam tahap ini, sejumlah metrik evaluasi seperti akurasi, presisi, *recall*, dan *F1-score* diterapkan untuk mengevaluasi seberapa baik model dapat mengklasifikasikan gambar-gambar baru yang belum pernah dilihat sebelumnya. Nilai-nilai evaluasi ini diperoleh dari confusion matrix, yaitu tabel yang menunjukkan hasil klasifikasi model dengan membandingkan prediksi model terhadap hasil aktual dari data uji. Pengujian dilakukan dengan 320 gambar untuk (80 gambar per kelas). *Confusion matrix* yang dihasilkan dari pengujian yang dilakukan tersaji pada Gambar 5.



Gambar 5. Arsitektur *Radial Basis Function Neural Networks* (RBFNN)



Berdasarkan confusion matrix yang ditampilkan dalam Gambar 5, beberapa metrik penting seperti presisi, recall, dan akurasi dapat diperoleh. Hasil pengukuran ditampilkan pada Tabel 4.

Tabel 4. Hasil Evaluasi

Nama Kelas	Precision	Recall	F1-Score	Accuracy
Daun Sehat	98,78%	98,78%	98,78%	92,5%
Black Measles	90,67%	89,47%	90,07%	
Brown Blight	89,61%	87,34%	88,46%	
Leaf Blight	90,70%	93,98%	92,31%	

Hasil evaluasi pada Tabel 4 menunjukkan bahwa model yang dibangun memiliki kinerja yang cukup baik dengan akurasi keseluruhan sebesar 92,5%. Kategori daun sehat mencatat hasil terbaik, dengan *Precision*, *Recall*, dan *F1-Score* masing-masing sebesar 98,78%, yang mengindikasikan bahwa model sangat efektif dalam mendeteksi dan mengklasifikasikan daun sehat tanpa banyak kesalahan. Hal ini mungkin disebabkan oleh karakteristik visual yang lebih konsisten pada daun sehat, yang membuatnya lebih mudah dikenali oleh model. Sementara itu, kategori penyakit *Black Measles* dan *Leaf Blight* menunjukkan kinerja yang baik dengan *F1-Score* masing-masing sebesar 90,07% dan 92,31%. Meskipun kategori *Black Measles* sedikit mengalami kesulitan dalam mendeteksi semua kasus (*Recall* 89,47%), model secara keseluruhan masih dapat mengklasifikasikan sebagian besar citra dengan benar. Kategori *Brown Blight*, meskipun masih berada dalam kisaran yang cukup baik, memiliki *F1-Score* sebesar 88,46%, yang menunjukkan adanya tantangan bagi model dalam membedakan penyakit ini dari penyakit lain, mungkin karena kemiripan fitur visual seperti tekstur yang lebih kompleks.

Penggunaan *Mean Color* untuk ekstraksi fitur warna dan GLCM untuk tekstur sangat membantu dalam proses klasifikasi. *Mean Color* berhasil menangkap distribusi warna yang relevan untuk mendeteksi perubahan pada daun akibat penyakit, sedangkan GLCM mampu menangkap pola tekstur yang memberikan indikasi penting dalam mengidentifikasi penyakit. Secara keseluruhan, model RBFNN ini menunjukkan performa yang cukup baik, namun ada ruang untuk peningkatan lebih lanjut, terutama dalam mengoptimalkan deteksi untuk kelas-kelas dengan ciri visual yang lebih mirip.

Namun untuk beberapa kelas (*Black Measles* dan *Brown Blight*) menunjukkan hasil yang perlu ditingkatkan karena perolehan yang tidak merata dengan kelas yang lain. Metode pra-pemrosesan data dapat diperluas dengan menambahkan teknik augmentasi data guna memperbesar variasi data latih, yang dapat membantu model lebih *robust* dalam mendeteksi perbedaan antara kelas yang memiliki karakteristik visual serupa, seperti pada penyakit *Black Measles* dan *Brown Blight*. Selain itu, optimalisasi ekstraksi fitur dapat dilakukan dengan menggabungkan fitur lain seperti bentuk dan ukuran, selain hanya mengandalkan *Mean Color* dan GLCM. Ini akan memberikan lebih banyak informasi bagi model untuk memisahkan kategori yang sulit dibedakan. Selain itu, tuning lebih lanjut pada parameter RBFNN, seperti penentuan jumlah neuron pada lapisan tersembunyi dan fungsi basis radial yang digunakan, dapat membantu meningkatkan akurasi model.

4. KESIMPULAN

Penelitian ini telah mengembangkan model klasifikasi citra penyakit daun anggur menggunakan *Radial Basis Function Neural Networks* (RBFNN) dengan ekstraksi fitur warna melalui *Mean Color* dan fitur tekstur menggunakan *Gray Level Co-occurrence Matrix* (GLCM) telah menunjukkan performa yang baik. Dengan akurasi keseluruhan mencapai 92,5%, model ini secara efektif dapat mengklasifikasikan gambar daun anggur ke dalam empat kategori: Daun Sehat, Black Rot, Black Measles, dan Leaf Blight. Metode ekstraksi fitur menggunakan *Mean Color* untuk aspek warna dan GLCM untuk tekstur terbukti efektif dalam proses klasifikasi. *Mean Color* berhasil mengidentifikasi perubahan distribusi warna pada daun yang terinfeksi penyakit, sementara GLCM efektif dalam mendeteksi pola tekstur yang menjadi indikator penting keberadaan penyakit. Proses klasifikasi kemudian dilakukan oleh algoritma RBFNN, di mana data input diproses menggunakan fungsi basis radial pada hidden layer untuk menghitung jarak antara input dengan pusat neuron. Untuk penelitian selanjutnya, terdapat beberapa saran yang dapat dilakukan untuk meningkatkan kemampuan model. Teknik pra-pemrosesan data bisa diperluas dengan menerapkan augmentasi data untuk meningkatkan variasi data latih. Selain itu, optimalisasi pada ekstraksi fitur dapat dilakukan dengan menambahkan fitur lain, seperti bentuk dan ukuran, bukan hanya bergantung pada *Mean Color* dan GLCM. Penggunaan pendekatan hybrid, seperti menggabungkan RBFNN dengan algoritma optimisasi seperti *Particle Swarm Optimization* (PSO) atau *Genetic Algorithm* (GA), juga bisa dipertimbangkan untuk meningkatkan inisialisasi bobot dan menghindari masalah konvergensi lokal.

REFERENCES

- [1] Badan Pusat Statistik, "Produksi Tanaman Buah-buahan, 2021-2023," *Badan Pusat Statistik*, 2024. <https://www.bps.go.id/id/statistics-table/2/NjJjMg==/produksi-tanaman-buah-buahan.html>
- [2] M. O. Dermawanov, A. P. Sunardi, H. T. Arifa, and R. Annaba, "Mitigasi Risiko Produksi Anggur: Studi Pada Pusat Bibit Dan Edukasi Budidaya Anggur Tangerang Selatan," *Sharia Agribus. J.*, vol. 4, no. 1, pp. 1–26, 2024.
- [3] R. Refnizuida, A. K. Nizam, F. I. Friski, and N. Salim, *Agribisnis Tanaman Anggur*. Sukoharjo: Tahta Media Group, 2023.



- [4] L. N. Sahenda, A. A. Ubaidillah, Z. E. Fitri, A. Madjid, and A. M. N. Imron, "Application of Feature Selection for Identification of Cucumber Leaf Diseases (*Cucumis sativa* L.)," *JISA (Jurnal Inform. dan Sains)*, vol. 04, no. 02, pp. 173–178, 2021.
- [5] Y. Sari, A. R. Baskara, and R. Wahyuni, "Classification of Chili Leaf Disease Using the Gray Level Co-occurrence Matrix (GLCM) and the Support Vector Machine (SVM) Methods," in *International Conference on Informatics and Computing (ICIC)*, 2021, pp. 1–4.
- [6] R. S. Septarini, M. Tonggihroh, and S. Nurhayati, "Identification of Potato Leaf Diseases Using Artificial Neural Networks With Extreme Learning Machine," *Pilar Nusa Mandiri J. Comput. Inf. Syst.*, vol. 20, no. 1, pp. 60–68, 2024, doi: 10.33480/pilar.v20i1.5307.
- [7] R. Gupta, "Tomato Leaf Disease Detection using Back Propagation Neural Network," *Int. J. Innov. Technol. Explor. Eng.*, vol. 3075, no. 8, pp. 529–538, 2020.
- [8] R. I. Borman, I. Ahmad, and Y. Rahmanto, "Klasifikasi Citra Tanaman Perdu Liar Berkhasiat Obat Menggunakan Jaringan Syaraf Tiruan Radial Basis Function," *Bull. Informatics Data Sci.*, vol. 1, no. 1, pp. 6–13, 2022.
- [9] C. Fragopoulos *et al.*, "Radial Basis Function Artificial Neural Network for the Investigation of Thyroid Cytological Lesions," *J. Thyroid Res.*, vol. 2020, pp. 1–14, Jan. 2020, doi: <https://doi.org/10.1155/2020/5464787>.
- [10] A. Agusriandi, E. Elihami, and W. Widiawati, "Identifikasi Bawang Merah dan Bombay dengan Pendekatan Radial Basis Function Neural Network (RBFNN)," *J. Media Inform. Budidarma*, vol. 4, no. 4, pp. 1043–1050, 2020, doi: 10.30865/mib.v4i4.2334.
- [11] R. I. Borman, F. Rossi, Y. Jusman, A. A. A. Rahni, S. D. Putra, and A. Herdiansah, "Identification of Herbal Leaf Types Based on Their Image Using First Order Feature Extraction and Multiclass SVM Algorithm," in *International Conference on Electronic and Electrical Engineering and Intelligent System (ICE3IS)*, 2021, pp. 12–17.
- [12] H. A. Iranga, "Leaf Disease Dataset," *Kaggle*, 2021. <https://www.kaggle.com/datasets/asheniranga/leaf-disease-dataset-combination>
- [13] R. I. Borman, D. E. Kurniawan, Styawati, I. Ahmad, and D. Alita, "Classification of Maturity Levels of Palm Fresh Fruit Bunches Using the Linear Discriminant Analysis Algorithm," *AIP Conf. Proc.*, vol. 2665, no. 1, pp. 30023.1–30023.8, 2023, doi: 10.1063/5.0126513.
- [14] H. Mayatopani, R. I. Borman, W. T. Atmojo, and A. Arisantoso, "Classification of Vehicle Types Using Backpropagation Neural Networks with Metric and Eccentricity Parameters," *J. Ris. Inform.*, vol. 4, no. 1, pp. 65–70, 2021, doi: 10.34288/jri.v4i1.293.
- [15] R. I. Borman, R. Napianto, N. Nugroho, D. Pasha, Y. Rahmanto, and Y. E. P. Yudoutomo, "Implementation of PCA and KNN Algorithms in the Classification of Indonesian Medicinal Plants," in *International Conference on Computer Science, Information Technology and Electrical Engineering (ICOMITEE)*, 2021, pp. 46–50.
- [16] R. Wang, D. Li, and K. Miao, "Optimized Radial Basis Function Neural Network Based Intelligent Control Algorithm of Unmanned Surface Vehicles," *J. Mar. Sci. Eng.*, vol. 8, no. 3, 2020, doi: 10.3390/jmse8030210.
- [17] Z. Abidin, R. I. Borman, F. B. Ananda, P. Prasetyawan, F. Rossi, and Y. Jusman, "Classification of Indonesian Traditional Snacks Based on Image Using Convolutional Neural Network (CNN) Algorithm," in *International Conference on Electronic and Electrical Engineering and Intelligent System (ICE3IS)*, 2022, pp. 18–23.
- [18] D. A. Tyas, S. Hartati, A. Harjoko, and T. Ratnaningsih, "Morphological, Texture, and Color Feature Analysis for Erythrocyte Classification in Thalassemia Cases," *IEEE Access*, vol. 8, pp. 69849–69860, 2020, doi: 10.1109/ACCESS.2020.2983155.
- [19] S.-H. Baek, K.-H. Park, J.-S. Jeon, and T.-Y. Kwak, "Using the CIELAB Color System for Soil Color Identification Based on Digital Image Processing," *J. Korean Geotech. Soc.*, vol. 38, no. 5, pp. 61–71, 2022.
- [20] A. Mathew, A. Antony, Y. Mahadeshwar, T. Khan, and A. Kulkarni, "Plant Disease Detection Using GLCM Feature Extractor and Voting Classification Approach," *Mater. Today Proc.*, vol. 58, pp. 407–415, 2022, doi: <https://doi.org/10.1016/j.matpr.2022.02.350>.
- [21] I. Ahmad, Y. Rahmanto, R. I. Borman, F. Rossi, Y. Jusman, and A. D. Alexander, "Identification of Pineapple Disease Based on Image Using Neural Network Self-Organizing Map (SOM) Model," in *International Conference on Electronic and Electrical Engineering and Intelligent System (ICE3IS)*, 2022, pp. 12–17.
- [22] A. Bemporad and D. Piga, "Global Optimization Based on Active Preference Learning with Radial Basis Functions," *Mach. Learn.*, vol. 110, no. 2, pp. 417–448, 2021, doi: 10.1007/s10994-020-05935-y.
- [23] R. I. Borman, F. Rossi, D. Alamsyah, R. Nuraini, and Y. Jusman, "Classification of Medicinal Wild Plants Using Radial Basis Function Neural Network with Least Mean Square," in *International Conference on Electronic and Electrical Engineering and Intelligent System (ICE3IS)*, 2022.