

# Pengembangan Model Klasifikasi Citra Penyakit Daun Lada Menggunakan Jaringan Syaraf Tiruan *Learning Vector Quantization* (LVQ)

Andrian Sah<sup>1\*</sup>, Mulyadi<sup>2</sup>, Allan Desi Alexander<sup>3</sup>, Adam M Tanniewa<sup>4</sup>

<sup>1</sup>Program Studi Sistem Informasi, Universitas Yapis Papua, Indonesia

<sup>2</sup>Program Studi Sistem Informasi, Universitas Nurdin Hamzah, Indonesia

<sup>3</sup>Program Studi Informatika, Universitas Bhayangkara Jakarta Raya, Indonesia

<sup>4</sup>Program Studi Sistem Informasi, Universitas Sulawesi Barat, Indonesia

<sup>1\*</sup>cyberdefance23@gmail.com, <sup>2</sup>mulyadirosly@gmail.com, <sup>3</sup>allan@ubharajaya.ac.id,

<sup>4</sup>adamtanniewa76@gmail.com

---

## Abstrak

<b>Kata Kunci:</b> Daun Lada; GLCM; <i>Learning Vector Quantization</i> ; <i>Mean Color</i> ; Pengolahan Citra;	Lada ( <i>Piper nigrum</i> ) adalah komoditas pertanian bernilai tinggi, namun rentan terhadap penyakit daun akibat infeksi jamur, bakteri, atau hama. Identifikasi dini penting untuk mencegah penurunan hasil panen, namun metode konvensional berbasis observasi visual sering subjektif dan membutuhkan keahlian khusus. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit daun lada menggunakan jaringan syaraf tiruan <i>Learning Vector Quantization</i> (LVQ) berbasis pengolahan citra digital. Proses penelitian dimulai dengan preprocessing, yang mencakup konversi ke ruang warna CIELAB untuk meningkatkan kontras, segmentasi menggunakan <i>Otsu Thresholding</i> , serta ekstraksi fitur warna dengan <i>Mean Color</i> dan fitur tekstur menggunakan <i>Gray Level Co-occurrence Matrix</i> (GLCM). Hasil ekstraksi fitur ini kemudian digunakan sebagai masukan untuk algoritma LVQ, yang melakukan klasifikasi berdasarkan pembelajaran vektor prototipe. Hasil evaluasi menunjukkan bahwa model LVQ yang dikembangkan mencapai tingkat akurasi keseluruhan sebesar 90,83%. Model menunjukkan performa terbaik dalam mengenali daun sehat dengan <i>precision</i> , <i>recall</i> , dan <i>F1-score</i> sebesar 96,67%. Sementara itu, kelas <i>Anthracnose</i> memiliki <i>precision</i> terendah sebesar 87,01%, dan kelas <i>Leaf Blight</i> menunjukkan <i>recall</i> terendah sebesar 86,67% serta <i>F1-Score</i> terendah sebesar 88,14%. Meskipun terdapat variasi kinerja antar kelas, model ini terbukti efektif dalam menangani dataset terbatas, memiliki kemampuan klasifikasi yang baik terhadap data non-linear, serta memungkinkan interpretasi keputusan klasifikasi yang lebih jelas.
--	--

---

## Abstract

<b>Keywords:</b> Pepper Leaf; GLCM; <i>Learning Vector Quantization</i> ; <i>Mean Color</i> ; Image Processing;	<i>Black Pepper (Piper nigrum)</i> is a high-value agricultural commodity but is susceptible to leaf diseases caused by fungal, bacterial, or pest infections. Early identification is crucial to prevent yield loss; however, conventional visual observation methods are often subjective and require specialized expertise. Therefore, this study aims to develop a black pepper leaf disease classification model using the <i>Learning Vector Quantization</i> (LVQ) artificial neural network based on digital image processing. The research process begins with preprocessing, which includes converting images to the CIELAB color space to enhance contrast, segmenting the images using <i>Otsu Thresholding</i> , and extracting color features using <i>Mean Color</i> and texture features using the <i>Gray Level</i>
--	--

---

Andrian Sah: \*Penulis Korespondensi



Copyright © 2025, Andrian Sah, Mulyadi, Allan Desi Alexander, Adam M Tanniewa.

*Co-occurrence Matrix (GLCM). The extracted features are then used as input for the LVQ algorithm, which classifies the data based on prototype vector learning. Evaluation results show that the developed LVQ model achieved an overall accuracy of 90.83%. The model performed best in recognizing healthy leaves, with precision, recall, and F1-score of 96.67%. Meanwhile, Anthracnose had the lowest Precision (87.01%), and Leaf Blight showed the lowest recall (86.67%) and F1-score (88.14%). Despite variations in class performance, the model proved effective in handling limited datasets, demonstrating strong classification capabilities for non-linear data while providing a clearer interpretation of classification decisions.*

---

## 1. PENDAHULUAN

Tanaman lada (*Piper nigrum*) merupakan salah satu komoditas pertanian bernilai ekonomi tinggi, terutama di negara-negara penghasil rempah seperti Indonesia. Lada memiliki beragam manfaat dan digunakan secara luas dalam industri makanan, farmasi, serta kosmetik, sehingga permintaan global terhadap komoditas ini terus meningkat [1]. Namun, produktivitas tanaman lada sering kali mengalami penurunan akibat serangan berbagai jenis penyakit daun, yang dapat berdampak signifikan terhadap hasil panen [2]. Penyakit-penyakit ini umumnya disebabkan oleh infeksi jamur, bakteri, atau serangan hama, yang dapat merusak struktur daun, menghambat proses fotosintesis, dan pada akhirnya mempengaruhi kualitas serta kuantitas produksi lada [3]. Deteksi dini dan klasifikasi penyakit pada daun lada menjadi aspek krusial dalam upaya pencegahan serta pengelolaan yang efektif. Metode konvensional yang digunakan oleh petani atau pakar pertanian umumnya mengandalkan observasi visual, yang sering kali bersifat subjektif dan membutuhkan keahlian khusus. Dengan kemajuan teknologi di bidang pengolahan citra digital dan kecerdasan buatan, pendekatan berbasis komputasi dapat menjadi solusi yang lebih akurat, cepat, dan efisien dalam mengidentifikasi serta mengklasifikasikan penyakit daun lada.

Penelitian tentang identifikasi atau klasifikasi penyakit tanaman berdasarkan citra daun telah dilakukan dengan berbagai algoritma. Beberapa studi sebelumnya telah menerapkan metode *K-Nearest Neighbors* (KNN) untuk mengidentifikasi penyakit pada daun mentimun, mencapai akurasi pengujian sebesar 76,67% [4]. Metode ini mengklasifikasikan berdasarkan jarak antara titik data, tetapi algoritma KNN cenderung sensitif terhadap outlier dan memerlukan sumber daya komputasi yang besar untuk kumpulan data yang lebih kompleks. Penelitian lain menggunakan pendekatan *Support Vector Machine* (SVM) untuk mengklasifikasikan penyakit pada daun mangga, menghasilkan akurasi hingga 80% [5]. Namun, efektivitas SVM sangat bergantung pada pemilihan parameter yang tepat, yang dapat mempengaruhi kinerja model. Selain itu, pendekatan jaringan saraf *Extreme Learning Machine* (ELM) telah diterapkan dalam identifikasi penyakit pada daun tomat, dengan tingkat akurasi sebesar 84,667% [6]. Meskipun demikian, algoritma ELM bergantung pada bobot input yang ditetapkan secara acak, yang dapat menyebabkan hasil klasifikasi yang kurang optimal. Pendekatan lain yang digunakan adalah jaringan saraf *Backpropagation*, yang diterapkan untuk mengidentifikasi penyakit bercak daun padi dengan akurasi 85,8% [7]. Algoritma ini bekerja melalui lapisan tersembunyi yang menghasilkan keluaran klasifikasi sesuai dengan label gambar. Namun, metode ini dapat mengalami kendala dalam proses konvergensi, yang menyebabkan pelatihan menjadi lambat atau terjebak dalam minimum lokal yang tidak optimal.

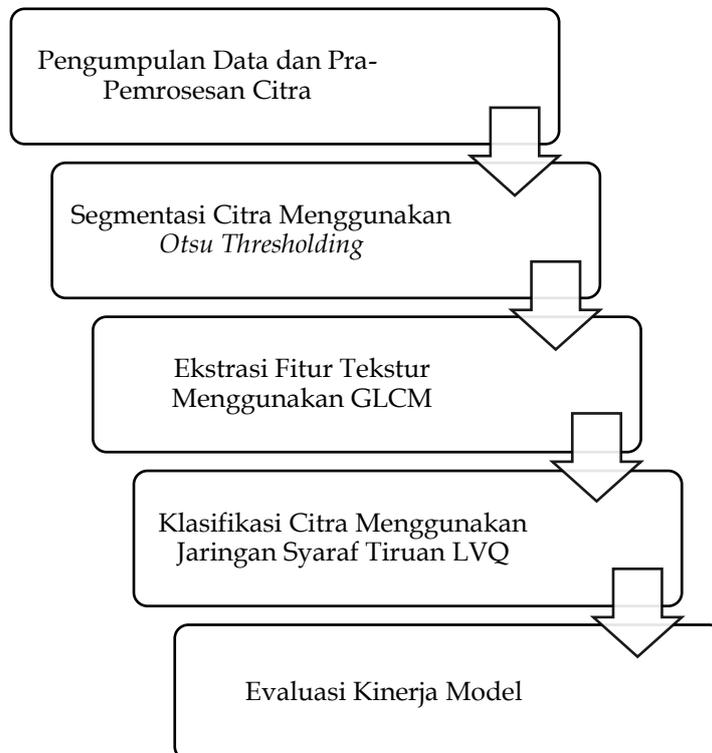
Penelitian sebelumnya menunjukkan bahwa jaringan saraf tiruan memiliki keunggulan dalam mempelajari dan mengenali pola kompleks dari data pelatihan. Namun, mengingat kompleksitas citra daun dan keterbatasan data berlabel, diperlukan metode yang tidak hanya dapat mengklasifikasikan penyakit dengan akurasi tinggi tetapi juga memberikan interpretabilitas dalam pengambilan keputusan. *Learning Vector Quantization* (LVQ) menjawab tantangan ini melalui pendekatan klasifikasi berbasis prototipe. Metode ini merepresentasikan setiap kelas menggunakan vektor prototipe, sehingga menyediakan mekanisme klasifikasi yang transparan dan mudah diinterpretasikan [8]. Melalui pembelajaran pola fitur dari data latih, LVQ mampu mengelompokkan data ke dalam kelas-kelas yang

telah ditentukan dengan cara yang sistematis dan terukur [9]. Teknik ini memiliki keunggulan dalam hal kemampuan adaptasi terhadap variasi data serta efisiensi dalam proses klasifikasi [10].

Tujuan dari penelitian ini adalah untuk merancang dan mengembangkan model klasifikasi citra penyakit daun lada menggunakan jaringan syaraf tiruan LVQ (*Learning Vector Quantization*). Dalam penelitian ini, proses *preprocessing* akan dilakukan dengan mengonversi citra ke dalam model warna CIELAB untuk meningkatkan kontras dan mempertajam perbedaan antar warna. Selanjutnya, citra akan disegmentasi menggunakan teknik *Otsu Thresholding* untuk memisahkan objek daun dari latar belakangnya. Setelah segmentasi, fitur warna dan tekstur akan diekstraksi untuk mendapatkan informasi yang ada pada citra. Untuk ekstraksi fitur warna digunakan metode *Mean Color* dengan menghitung nilai rata-rata komponen  $L^*$ ,  $a^*$ , dan  $b^*$  dalam ruang warna CIELAB. Sedangkan fitur tekstur diperoleh melalui metode *Gray Level Co-occurrence Matrix (GLCM)*, yang menganalisis pola distribusi intensitas piksel dalam citra pada jarak dan orientasi tertentu. Fitur yang diperoleh digunakan sebagai masukan untuk algoritma LVQ, yang mengklasifikasikan data berdasarkan pembelajaran vektor prototipe. Dengan demikian, penelitian ini memiliki kontribusi utama yaitu dalam pengembangan sistem klasifikasi penyakit daun lada berbasis jaringan syaraf tiruan LVQ yang mampu melakukan identifikasi penyakit secara otomatis, mempercepat proses diagnosis bagi petani dan peneliti, serta menyediakan metode yang lebih efisien dalam pengolahan citra penyakit tanaman. Selain itu, penelitian ini juga mendukung penerapan teknologi kecerdasan buatan dalam sektor pertanian guna meningkatkan produktivitas dan keberlanjutan budidaya lada.

## 2.METODE PENELITIAN

Metode penelitian berfungsi sebagai panduan sistematis yang mengarahkan peneliti selama proses berlangsung, memastikan pendekatan yang terstruktur dan logis [11]. Penelitian ini bertujuan untuk mengembangkan model klasifikasi berbasis gambar untuk mendeteksi penyakit daun lada, dengan tahapan penelitian yang ditunjukkan pada Gambar 1.



**Gambar 1.** Tahapan Penelitian

Berdasarkan Gambar 1, setiap tahap yang dilakukan dijelaskan secara rinci sebagai berikut.

### A. Pengumpulan Data dan Pra-Pemrosesan Citra

Tahap awal penelitian ini dilakukan dengan mengumpulkan citra daun lada, baik yang sehat maupun yang terinfeksi penyakit. Kumpulan citra ini membentuk dataset terstruktur yang digunakan untuk pelatihan, pengujian, dan evaluasi model *machine learning*. Dataset menjadi penting karena menjadi landasan utama dalam pengembangan dan evaluasi model *machine learning* [12]. Dataset diperoleh melalui observasi langsung dan dokumentasi dari perkebunan lada. Pelabelan data dilakukan dengan bantuan ahli botani atau ahli penyakit tanaman untuk memastikan keakuratan dalam identifikasi penyakit. Setiap citra diberi label sesuai dengan jenis penyakit yang diidentifikasi. Dataset yang digunakan mencakup empat kelas, yaitu Daun Sehat, *Leaf Blight*, *Yellow Mottle Virus*, dan *Anthracoese*, dengan total 400 citra yang telah dikumpulkan. Data ini kemudian dibagi menjadi data pelatihan (70%) dan data pengujian (30%), menghasilkan 280 citra untuk pelatihan dan 120 citra untuk pengujian. Proporsi ini dipilih untuk memastikan model memperoleh informasi yang cukup dalam proses pembelajaran [13].

Setelah dataset terkumpul, tahap berikutnya adalah pra-pemrosesan citra, yang bertujuan meningkatkan kualitas citra dan mempersiapkannya untuk tahap segmentasi dan ekstraksi fitur. Citra dikonversi dari ruang warna RGB ke ruang warna CIELAB karena lebih sesuai untuk analisis pola berbasis warna. Ruang warna ini memisahkan komponen warna menjadi tiga saluran independen: L\* (luminansi), a\* (hijau ke merah), dan b\* (biru ke kuning), yang memungkinkan analisis warna yang lebih stabil di berbagai kondisi pencahayaan [14]. Perubahan warna akibat penyakit lebih terlihat pada saluran a\* dan b\*, sehingga memudahkan diferensiasi antara area sehat dan terinfeksi.

### B. Segmentasi Citra Menggunakan Otsu Thresholding

Pada tahap segmentasi, citra yang telah diproses sebelumnya dibagi menjadi objek utama dan latar belakang menggunakan metode *Otsu Thresholding*. Teknik ini dipilih karena kemampuannya dalam menentukan nilai ambang optimal berdasarkan distribusi intensitas piksel [15]. Segmentasi bertujuan untuk menghilangkan elemen yang tidak relevan, seperti *noise* latar belakang, sehingga fitur yang diekstraksi lebih fokus pada area yang relevan untuk klasifikasi [16].

Metode *Otsu Thresholding* bekerja dengan mencari nilai ambang optimal  $T$  yang meminimalkan varians intra-kelas dan memaksimalkan varians antar-kelas. Nilai ambang  $T$  ditentukan dengan mengoptimalkan fungsi melalui persamaan (1).

$$\sigma_B^2(T) = w_1(T)\sigma_1^2(T) + w_2(T)\sigma_2^2(T) \quad (1)$$

di mana  $\sigma_B^2(T)$  adalah varians antar-kelas,  $w_1(T)$  dan  $w_2(T)$  adalah probabilitas piksel dalam kelas 1 dan kelas 2,  $\sigma_1^2(T)$  dan  $\sigma_2^2(T)$  adalah varians intensitas piksel dalam masing-masing kelas.

Metode ini menghitung semua kemungkinan nilai ambang dan memilih nilai  $T$  yang memberikan nilai varians antar-kelas maksimum, memastikan bahwa citra dibagi secara optimal antara objek utama dan latar belakang.

### C. Ekstraksi Fitur Tekstur Menggunakan GLCM

Ekstraksi fitur bertujuan untuk memperoleh informasi yang relevan dari citra guna mendukung proses klasifikasi [17]. Dalam penelitian ini, fitur yang digunakan terdiri dari fitur warna dan fitur tekstur. Fitur warna diekstraksi menggunakan metode *Mean Color* dengan menghitung nilai rata-rata komponen L\*, a\*, dan b\* dalam ruang warna CIELAB [18]. Metode ini efektif dalam mendeteksi perubahan warna yang merupakan indikator utama penyakit daun.

Sementara itu, fitur tekstur diekstraksi menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM). GLCM menganalisis hubungan spasial antara pasangan piksel dengan intensitas tertentu dalam citra, menghasilkan metrik seperti *contrast*, *dissimilarity*, *homogeneity*, *energy*, dan *correlation* [19]. Fitur ini penting karena penyakit daun sering menyebabkan perubahan tekstur yang khas, seperti bintik atau pola tidak beraturan, yang dapat dideteksi dengan GLCM.

### D. Klasifikasi Citra Menggunakan Jaringan Syaraf Tiruan LVQ

Algoritma jaringan syaraf tiruan *Learning Vector Quantization* (LVQ) merupakan metode pembelajaran terawasi yang mengklasifikasikan pola berdasarkan konsep kompetisi antar *neuron* [20].

Metode ini bekerja dengan membandingkan kedekatan vektor input dengan vektor bobot setiap kelas untuk menentukan kelas yang paling representatif dari pola input yang diberikan [21]. Tujuan utama dari LVQ adalah mempelajari vektor prototipe untuk setiap kelas sehingga mampu mengklasifikasikan data baru secara akurat [10]. Inti dari metode LVQ adalah pembaruan vektor prototipe berdasarkan data pelatihan. Untuk menentukan prototipe yang paling dekat dengan vektor input, LVQ menghitung jarak Euclidean antara dan setiap prototipe, sebagaimana ditunjukkan dalam persamaan (2).

$$d(x, w_j) = \sqrt{\sum_{i=1}^n (x_i - w_{ji})^2} \quad (2)$$

di mana  $d(x, w_j)$  adalah jarak Euclidean antara vektor input  $x$  dan prototipe  $w_j$ ,  $x_i$  merupakan komponen ke- $i$  dari vektor input  $x$ ,  $w_{ji}$  adalah komponen ke- $i$  dari prototipe  $w_j$ ,  $n$  dan adalah jumlah fitur dalam vektor  $x$ .

Setelah jarak dihitung, prototipe diperbarui berdasarkan apakah klasifikasi yang dilakukan benar atau salah. Jika klasifikasi benar, prototipe diperbarui dengan bergerak lebih dekat ke data yang benar. Sebaliknya, jika klasifikasi salah, prototipe diperbarui dengan menjauh dari data yang salah guna meningkatkan akurasi model. Vektor prototipe secara bertahap beradaptasi sehingga dapat lebih baik merepresentasikan pola data dari setiap kelas. Pembaruan prototipe untuk klasifikasi yang benar ditunjukkan dalam persamaan (3).

$$w_j^{new} = w_j^{old} + \alpha(x - w_j^{old}) \quad (3)$$

Sedangkan untuk klasifikasi yang salah, pembaruan dilakukan sesuai dengan persamaan (4).

$$w_j^{new} = w_j^{old} - \alpha(x - w_j^{old}) \quad (4)$$

di mana  $w_j^{new}$  adalah vektor prototipe setelah pembaruan,  $w_j^{old}$  adalah vektor prototipe sebelum pembaruan,  $x$  adalah vektor input, dan  $\alpha$  adalah laju pembelajaran yang mengontrol sejauh mana prototipe diperbarui berdasarkan data input.

LVQ menggunakan jarak Euclidean untuk memilih prototipe terdekat dan memperbaruinya berdasarkan hasil klasifikasi, memastikan bahwa vektor prototipe semakin akurat dalam merepresentasikan karakteristik masing-masing kelas.

### E. Evaluasi Kinerja Model

Setelah model LVQ dilatih, tahap evaluasi dilakukan untuk menilai kinerjanya. Sebelum mengukur performa model, terlebih dahulu dibuat confusion matrix yang berfungsi sebagai alat analisis klasifikasi dengan menyajikan perbandingan antara hasil prediksi model dan label sebenarnya. *Confusion matrix* menyusun jumlah klasifikasi benar dan salah dalam empat kategori utama, yaitu *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN) [22]. Dari *confusion matrix* ini diperoleh berbagai metrik evaluasi kinerja, seperti *accuracy*, *precision*, *recall*, dan *F1-score*.

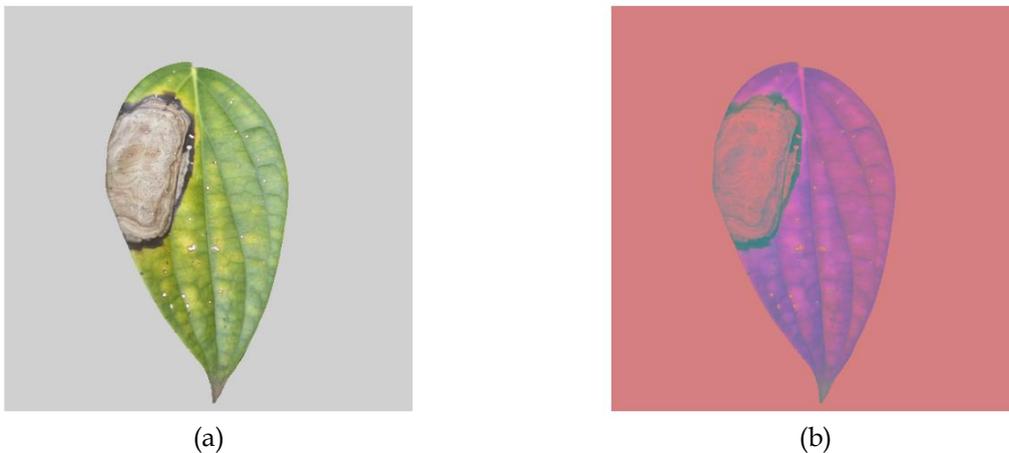
Akurasi digunakan untuk mengukur sejauh mana model mampu mengklasifikasikan citra dengan benar dengan membandingkan jumlah prediksi yang benar terhadap keseluruhan sampel yang diuji [23]. *Precision* mengukur kemampuan model dalam menghindari kesalahan klasifikasi positif palsu, yang sangat penting untuk mencegah kesalahan diagnosis yang dapat menyebabkan tindakan yang tidak perlu [24]. *Recall* mengevaluasi sejauh mana model dapat mengenali seluruh sampel yang benar-benar mengandung penyakit, memastikan bahwa tidak ada kasus yang terlewatkan dalam deteksi [25]. *F1-score*, yang merupakan rata-rata harmonik antara *precision* dan *recall*, digunakan sebagai indikator keseimbangan antara kedua metrik tersebut, terutama ketika dataset tidak seimbang [26].

## 3. HASIL DAN PEMBAHASAN

Pada pengembangan model klasifikasi penyakit daun lada menggunakan *Learning Vector Quantization* (LVQ), langkah awal yang dilakukan adalah menyiapkan dataset untuk pelatihan dan evaluasi. Dataset dikumpulkan melalui observasi langsung dan dokumentasi dari perkebunan lada. Proses pelabelan data dilakukan dengan bantuan ahli botani atau ahli penyakit tanaman untuk memastikan akurasi dalam identifikasi setiap jenis penyakit. Setiap citra yang dikumpulkan

diklasifikasikan berdasarkan kategori penyakit yang teridentifikasi. Dataset yang digunakan dalam penelitian ini mencakup empat kelas, yaitu Daun Sehat, *Leaf Blight*, *Yellow Mottle Virus*, dan *Anthracnose*, dengan total 400 citra yang diperoleh. Data tersebut kemudian dibagi menjadi dua bagian utama: data pelatihan (70%) dan data pengujian (30%), yang menghasilkan 280 citra untuk pelatihan dan 120 citra untuk pengujian. Pembagian ini bertujuan untuk memastikan model memiliki cukup data untuk belajar sekaligus mengevaluasi performanya secara akurat.

Langkah selanjutnya adalah pra-pemrosesan citra, yang melibatkan konversi dari ruang warna RGB ke CIELAB. Transformasi ini meningkatkan ketahanan analisis terhadap variasi pencahayaan serta memungkinkan pemisahan warna dari intensitas pencahayaan. Ruang warna CIELAB lebih representatif dalam menganalisis perubahan warna yang terjadi akibat penyakit tanaman. Sampel hasil konversi dari RGB ke CIELAB, yang membantu meningkatkan ketajaman warna dan mengurangi efek pencahayaan yang tidak diinginkan diperlihatkan pada Gambar 2.



**Gambar 2.** (a) Citra RGB; (b) Hasil Konversi Citra CIELAB

Gambar 2 menunjukkan konversi dari RGB ke CIELAB yang memperjelas perbedaan antara area yang sehat dan area yang terdampak penyakit. Setelah konversi, tahap berikutnya adalah segmentasi citra untuk memisahkan daun dari latar belakang serta menghilangkan elemen yang tidak relevan, seperti *noise* dan bayangan. Teknik *Otsu Thresholding* diterapkan untuk menentukan nilai ambang optimal yang memungkinkan pemisahan latar depan (daun) dari latar belakang dengan memaksimalkan varians antar-kelas. Hasil segmentasi ditampilkan dalam Gambar 3.



**Gambar 3.** (a) Hasil Segmentasi Citra Biner; (b) Hasil Segmentasi Citra CIELAB

Gambar 3 menunjukkan bagaimana metode *Otsu Thresholding* memisahkan daun dari latar belakangnya. Proses segmentasi memastikan bahwa objek utama dapat dipisahkan dengan jelas dari latar belakang. Setelah segmentasi selesai, tahap berikutnya adalah ekstraksi fitur warna dan tekstur

guna mendapatkan informasi yang relevan untuk proses klasifikasi. Fitur warna dianalisis menggunakan metode *Mean Color*, yang menghitung rata-rata intensitas warna untuk masing-masing saluran dalam ruang warna CIELAB. Dalam metode ini, nilai rata-rata  $L^*$ ,  $a^*$ , dan  $b^*$  dihitung untuk mendapatkan informasi tentang perubahan warna akibat penyakit tanaman. Hasil ekstraksi fitur warna disajikan dalam Tabel 1.

**Tabel 1.** Sampel Hasil Ekstraksi Fitur Warna dengan *Mean Color*

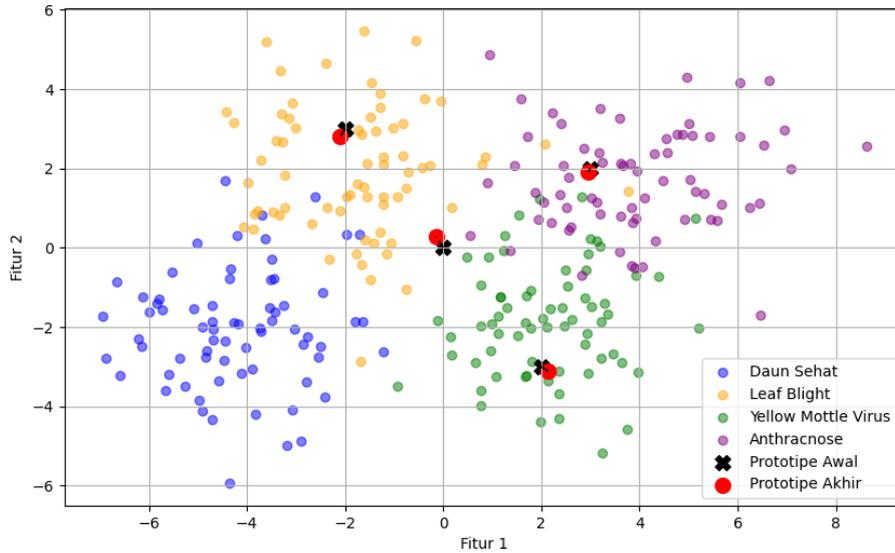
Citra CIELAB	Ekstraksi Fitur Warna	
	Color Channel	Mean Value
	$L^*$	163.3313
	$a^*$	157.5765
	$b^*$	134.6633

Pada Tabel 1 menunjukkan sampel citra yang diekstraksi fitur menggunakan *Mean Color* untuk mendapatkan informasi tentang perubahan warna. Selain fitur warna, karakteristik tekstur juga diekstraksi menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM). Teknik ini mengevaluasi hubungan spasial antara pasangan piksel dengan intensitas tertentu dalam jarak dan orientasi yang telah ditentukan. Parameter utama yang dihitung meliputi *contrast*, *dissimilarity*, *homogeneity*, *energy*, dan *correlation*. Fitur-fitur ini memberikan wawasan tentang variasi tekstur yang terjadi pada daun yang sehat dan yang terinfeksi penyakit. Hasil ekstraksi fitur tekstur disajikan dalam Tabel 2.

**Tabel 2.** Sampel Hasil Ekstraksi Fitur Tekstur dengan GLCM

Citra Tersegmentasi	Ekstraksi Fitur Tekstur	
	Parameter	Nilai
	Contrast	455.1176
	Dissimilarity	0.9727
	Homogeneity	0.8047
	Energy	3.8857
	Correlation	0.0024

Fitur warna dan tekstur yang diperoleh dalam Tabel 2 dan 3 menjadi input penting dalam tahap klasifikasi. Setelah nilai fitur dikumpulkan, model *Learning Vector Quantization* (LVQ) dilatih dengan memanfaatkan fitur yang paling relevan untuk membangun model klasifikasi. Algoritma LVQ bekerja dengan memetakan setiap vektor fitur yang telah direduksi ke dalam prototipe yang mewakili masing-masing kelas. Prototipe awalnya dipilih secara acak atau berasal dari data pelatihan, kemudian diperbarui secara iteratif berdasarkan perbandingan dengan sampel input menggunakan jarak Euclidean. Jika klasifikasi benar, prototipe diperbarui dengan bergerak lebih dekat ke sampel tersebut, sedangkan jika klasifikasi salah, prototipe diperbarui dengan menjauh dari data yang salah. Distribusi data serta pergerakan prototipe selama proses pelatihan diilustrasikan pada Gambar 4.

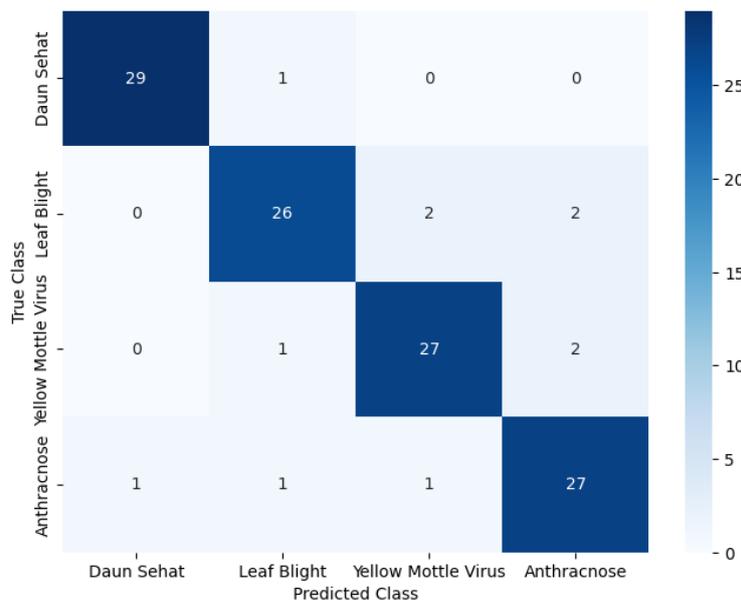


Gambar 4. Visualisasi Pergerakan Prototipe LVQ

Gambar 4 merupakan representasi distribusi data dan pergerakan prototipe selama proses pelatihan pada algoritma *Learning Vector Quantization* (LVQ). Setiap titik dalam *scatter plot* merepresentasikan sampel dalam dataset dengan pola penyebaran data pada ruang fitur. Pada awal pelatihan, prototipe untuk setiap kelas, ditandai dengan "X" hitam, berfungsi sebagai referensi awal bagi model. Selama pelatihan, prototipe diperbarui dengan mendekati sampel yang benar dan menjauhi sampel yang salah agar lebih sesuai dengan distribusi kelasnya. Pergerakan prototipe divisualisasikan dengan garis putus-putus hitam, sementara prototipe akhir, ditandai dengan lingkaran merah, menunjukkan posisi yang telah diperbarui untuk lebih merepresentasikan kelasnya.

Model yang telah dilatih dievaluasi menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*

. Evaluasi dilakukan dengan menggunakan dataset uji yang terpisah dari dataset pelatihan guna memastikan kemampuan model dalam menggeneralisasi data baru. Set data uji terdiri dari 120 gambar yang telah dibagi berdasarkan empat kelas penyakit. Tahap pertama dalam evaluasi model adalah pembentukan *confusion matrix*, yang merepresentasikan jumlah prediksi benar dan salah dalam setiap kelas. Hasil *confusion matrix* pada dataset uji ditampilkan pada Gambar 5.



Gambar 5. Confusion Matrix Model LVQ

Gambar 6 menyajikan *confusion matrix* yang memberikan gambaran rinci tentang kemampuan klasifikasi model dengan menampilkan distribusi prediksi yang benar dan salah untuk setiap kelas. Berdasarkan matriks ini, berbagai metrik evaluasi, seperti *Accuracy*, *Precision*, *Recall*, dan *F1-Score*, dapat dihitung untuk memberikan pemahaman yang lebih mendalam mengenai keunggulan dan keterbatasan model dalam mengklasifikasikan setiap jenis penyakit daun lada. Hasil evaluasi kinerja model yang dikembangkan disajikan dalam Tabel 3.

**Tabel 3.** Hasil Evaluasi Kinerja Model

Kelas	<i>Precision</i> (%)	<i>Recall</i> (%)	<i>F1-Score</i> (%)	<i>Accuracy</i> (%)
Daun Sehat	96,67	96,67	96,67	90,83
<i>Leaf Blight</i>	89,66	86,67	88,14	
<i>Yellow Mottle Virus</i>	90,00	90,00	90,00	
<i>Anthracnose</i>	87,01	90,00	88,52	

Tabel 3 menyajikan hasil evaluasi model LVQ, yang menunjukkan akurasi keseluruhan sebesar 90,83%. Nilai ini mengindikasikan bahwa model memiliki kinerja yang baik dalam mengklasifikasikan penyakit pada daun lada. Kelas Daun Sehat menunjukkan performa terbaik dengan nilai *precision*, *recall*, dan *F1-score* sebesar 96,67%, yang menunjukkan bahwa model mampu mengenali daun sehat dengan sangat baik. Kelas *Anthracnose* memiliki nilai *precision* terendah sebesar 87,01%, sedangkan kelas *Leaf Blight* memiliki nilai *recall* terendah sebesar 86,67% dan *F1-score* terendah sebesar 88,14%. Meskipun terdapat variasi antar kelas, performa model secara keseluruhan masih berada dalam kategori yang baik.

Metode LVQ memiliki beberapa keunggulan, seperti kemampuannya dalam menangani data non-linear melalui representasi vektor prototipe serta kemudahan dalam interpretasi karena representasi kelas yang lebih jelas. Selain itu, LVQ efektif untuk dataset yang terbatas, sehingga metode ini menjadi pilihan yang tepat dalam penelitian ini. Namun, model ini juga memiliki beberapa keterbatasan, terutama sensitivitas terhadap inisialisasi prototipe yang dapat menyebabkan konvergensi ke lokal minimum. Selain itu, model memiliki kesulitan dalam menangani dataset dengan tumpang tindih antar kelas, sebagaimana terlihat pada kelas *Leaf Blight* dan *Anthracnose*, di mana kesamaan fitur antar kelas menyebabkan penurunan akurasi klasifikasi. Pemilihan *learning rate* yang tidak optimal juga dapat menyebabkan model terlalu cepat atau terlalu lambat dalam memperbarui prototipe, yang berakibat pada stabilitas kinerja model.

Untuk meningkatkan performa model, beberapa strategi dapat diterapkan. Optimasi inisialisasi prototipe dengan *K-Means Clustering* sebelum pelatihan dapat membantu menentukan posisi awal yang lebih representatif bagi setiap kelas. Selain itu, penggunaan pendekatan reduksi dimensi seperti *Principal Component Analysis* (PCA) atau *Linear Discriminant Analysis* (LDA) juga dapat membantu meningkatkan pemisahan antar kelas sehingga model dapat lebih akurat dalam melakukan klasifikasi. Selain itu, penerapan *adaptive learning rate* dapat digunakan untuk menyesuaikan kecepatan pembaruan prototipe agar lebih stabil dan optimal.

## 4. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi penyakit daun lada menggunakan *Learning Vector Quantization* (LVQ) dengan tingkat akurasi keseluruhan sebesar 90,83%. Model menunjukkan performa terbaik dalam mengenali daun sehat, dengan *precision*, *recall*, dan *F1-score* sebesar 96,67%. Sementara itu, kelas *Anthracnose* memiliki *precision* terendah sebesar 87,01%, sedangkan kelas *Leaf Blight* menunjukkan *recall* terendah sebesar 86,67% dan *F1-score* terendah sebesar 88,14%. Meskipun terdapat variasi performa antar kelas, model secara keseluruhan masih berada dalam kategori "baik". Hasil evaluasi menunjukkan bahwa LVQ efektif dalam menangani dataset terbatas, memiliki kemampuan klasifikasi yang baik terhadap data non-linear, serta memungkinkan interpretasi yang lebih jelas melalui representasi prototipe. Penelitian selanjutnya dapat mengoptimalkan inisialisasi prototipe menggunakan *K-means clustering*, menerapkan reduksi dimensi dengan *Principal*

*Component Analysis* (PCA) atau *Linear Discriminant Analysis* (LDA) untuk meningkatkan pemisahan antar kelas, serta menyesuaikan *adaptive learning rate* guna meningkatkan stabilitas model. Dengan strategi ini, model LVQ diharapkan lebih andal dalam mendeteksi dan mengklasifikasikan penyakit daun lada secara otomatis, sehingga mendukung pengambilan keputusan yang lebih efektif dalam pengelolaan tanaman.

## 5.REFERENSI

- [1] Y. I. Nurhakim, *Budidaya & Bisnis Lada: Skala Kecil & Besar*. Jakarta Selatan: BCI Media, 2021.
- [2] R. Ropalia, R. Apriyadi, and H. M. Saputra, "Penyakit Utama Tanaman Lada di Kabupaten Bangka Selatan," *Argosaintek Jurnal Ilmu dan Teknol. Pertan.*, vol. 6, no. 1, pp. 53–60, 2022, doi: 10.33019/agrosaintek.v6i1.217.
- [3] R. Rosmiati, *Penanganan dan Pengendalian Jamur Phytophthora Capsici: Implementasi Pada Tanaman Lada*. Gowa: CV. Ruang Tentor, 2024.
- [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)*, IEEE, 2021, pp. 1–4.
- [6] R. S. Septarini, M. Tonggiroh, 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] Y. Lu *et al.*, "Recognition of rice sheath blight based on a backpropagation neural network," *Electron.*, vol. 10, no. 23, 2021, doi: 10.3390/electronics10232907.
- [8] R. I. Borman, Y. Fernando, and Y. Egi Pratama Yudoutomo, "Identification of Vehicle Types Using Learning Vector Quantization Algorithm with Morphological Features," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 6, no. 2, pp. 339–345, 2022, doi: 10.29207/resti.v6i2.3954.
- [9] R. I. Borman, Y. Fernando, and Y. E. P. Yudoutomo, "Identification of Vehicle Types Using Learning Vector Quantization Algorithm with Morphological Features," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 158, pp. 339–345, 2022, doi: 10.29207/resti.v6i2.3954.
- [10] K. Azhari, "Klasifikasi Jenis-Jenis Bauh Nanas Menggunakan Learning Vector Quantization (LVQ)," *KONSTELASI Konvergensi Teknol. dan Sist. Inf.*, vol. 1, no. 2, pp. 357–368, 2021, doi: 10.24002/konstelasi.v1i2.4261.
- [11] A. Sah, S. Suhardi, and S. Nurhayati, "Geographic Information System of Patient Development in Jayapura Hospital During Pandemic," *J. Teknol. Dan Open Source*, vol. 4, no. 2, pp. 149–154, 2021, doi: 10.36378/jtos.v4i2.1412.
- [12] R. I. Borman and M. Wati, "Penerapan Data Mining Dalam Klasifikasi Data Anggota Kopdit Sejahtera Bandar Lampung Dengan Algoritma Naïve Bayes," *J. Ilm. Fak. Ilmu Komput.*, vol. 9, no. 1, pp. 25–34, 2020.
- [13] 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)*, IEEE, 2022, pp. 12–17.
- [14] R. Nuraini, T. G. Soares, P. Dayurni, and M. Mulyadi, "Tomato Ripeness Detection Using Linear Discriminant Analysis Algorithm with CIELAB and HSV Color Spaces," *Build. Informatics, Technol. Sci.*, vol. 5, no. 2, pp. 523–531, 2023, doi: 10.47065/bits.v5i2.4192.
- [15] V. Veriarinal and C. Gunawan, "Identifikasi Nilai Mata Uang Logam Menggunakan Metode Otsu Thresholding," *Kohesi J. Multidisiplin Sainstek*, vol. 2, no. 11, pp. 1–9, 2024, doi: 10.3785/kohesi.v2i11.2670.
- [16] 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.
- [17] 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)*, IEEE, 2021, pp. 12–17.
- [18] D. Ayuningtyas, E. Suryani, and W. Wiharto, "Identification of Tomato Maturity Based on HIS Color Space Using The K-Nearest Neighbour Method," in *International Conference on Artificial Intelligence and Computer Science Technology (ICAICST)*, IEEE, 2021, pp. 73–78. doi: 10.1109/ICAICST53116.2021.9497843.
- [19] A. Herdiansah, R. I. Borman, D. Nurnaningsih, A. A. J. Sinlae, and R. R. Al Hakim, "Klasifikasi Citra Daun

---

Andrian Sah: \*Penulis Korespondensi



Copyright © 2025, Andrian Sah, Mulyadi, Allan Desi Alexander, Adam M Tanniewa.

- Herbal Dengan Menggunakan Backpropagation Neural Networks Berdasarkan Ekstraksi Ciri Bentuk," *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 2, pp. 388–395, 2022, doi: 10.30865/jurikom.v9i1.3846.
- [20] M. Kaden *et al.*, "Learning vector quantization as an interpretable classifier for the detection of SARS-CoV-2 types based on their RNA sequences," *Neural Comput. Appl.*, vol. 34, no. 1, pp. 67–78, 2022, doi: 10.1007/s00521-021-06018-2.
- [21] M. S. Sormin, H. Rumapea, I. K. Jaya, and D. R. Manalu, "Penerapan Metode Learning Vector Quantization Pada Sistem Pakar Identifikasi Penyakit Dan Hama Tanaman Kubis Berdasarkan Citra Daun Berbasis Mobile," *METHOTIKA J. Ilm. Tek. Inform.*, vol. 2, no. 1, pp. 61–67, 2022.
- [22] 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)*, IEEE, 2022.
- [23] 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.
- [24] 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)*, IEEE, 2022, pp. 18–23.
- [25] R. I. Borman, Y. Fernando, and Y. E. P. Yudoutomo, "Identification of Vehicle Types Using Learning Vector Quantization Algorithm with Morphological Features," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 2, pp. 339–345, 2022.
- [26] R. R. Wahid, F. T. Anggraeni, and B. Nugroho, "Implementasi Metode Extreme Learning Machine untuk Klasifikasi Tumor Otak pada Citra Magnetic Resonance Imaging," in *Seminar Nasional Informatika Bela Negara (SANTIKA)*, 2023, pp. 16–20. doi: 10.33005/santika.v1i0.45.