

Perbandingan Metode Ekstraksi Fitur LBP, GLCM, dan Canny dalam Klasifikasi Penyakit Daun Padi dengan KNN

Roy Jordy^{1*}, Dhani Ariatmanto²

^{1,2}Magister Informatika, Universitas AMIKOM Yogyakarta

Jln. Ring Road Utara, Ngiringin, Condongcatur, Depok, Sleman, Yogyakarta, Indonesia

¹royjordy@student.amikom.ac.id

²dhaniari@amikom.ac.id

Intisari— Penentuan jenis penyakit daun padi secara cepat dan akurat sangat penting dalam mendukung upaya pengendalian penyakit secara dini di sektor pertanian. Penelitian ini bertujuan untuk membandingkan kinerja tiga metode ekstraksi fitur citra digital Local Binary Pattern (LBP), Gray Level Co-occurrence Matrix (GLCM), dan Canny Edge Detection dalam klasifikasi tiga jenis penyakit daun padi: Bacterial leaf blight, Brown spot, dan Leaf smut. Setiap metode dievaluasi berdasarkan confusion matrix serta metrik akurasi, presisi, recall, dan F1-score. Hasil eksperimen menunjukkan bahwa metode LBP memberikan performa tertinggi dengan akurasi mencapai 92,06%, diikuti oleh GLCM sebesar 78,57% dan Canny sebesar 66,67%. Selain akurasi, LBP juga unggul dalam seluruh metrik evaluasi lainnya. Temuan ini menunjukkan bahwa fitur tekstur lokal yang dihasilkan oleh LBP lebih efektif dalam membedakan jenis penyakit dibandingkan dengan fitur global dari GLCM maupun fitur tepi dari Canny. Oleh karena itu, LBP dapat direkomendasikan sebagai metode ekstraksi fitur yang lebih unggul untuk sistem klasifikasi otomatis penyakit daun padi berbasis citra digital.

Kata kunci— Deteksi Penyakit; Daun Padi; Ekstraksi Fitur; KNN; Digital

Abstract— Accurate and timely identification of rice leaf diseases plays a crucial role in supporting early disease control efforts in agriculture. This study aims to compare the performance of three image feature extraction methods—Local Binary Pattern (LBP), Gray Level Co-occurrence Matrix (GLCM), and Canny Edge Detection—in classifying three types of rice leaf diseases: Bacterial leaf blight, Brown spot, and Leaf smut. Each method was evaluated based on its confusion matrix as well as key performance metrics, including accuracy, precision, recall, and F1-score. Experimental results show that LBP achieved the highest classification performance with an accuracy of 92.06%, followed by GLCM at 78.57% and Canny at 66.67%. In addition to accuracy, LBP also outperformed the other methods across all evaluation metrics. These findings indicate that the local texture features captured by LBP are more effective in distinguishing disease types compared to the global texture features from GLCM and edge-based features from Canny. Therefore, LBP is recommended as a superior feature extraction method for automated classification systems of rice leaf diseases based on digital imagery.

Keywords— Disease Detection; Rice Leaf; Feature Extraction; KNN; Digital

I. PENDAHULUAN

Penyakit pada daun padi merupakan masalah yang signifikan di banyak negara penghasil padi termasuk Indonesia, karena dapat menurunkan hasil panen secara drastis dan mengurangi kualitas produksi padi [1], [2]. Beberapa penyakit umum yang menyerang daun padi, seperti Bacterial Leaf Blight (BLB), Brown Spot, dan Leaf Smut, dapat menyebabkan kerusakan besar pada tanaman padi, yang jika tidak segera ditangani, dapat menyebar ke lahan pertanian yang lebih luas [3]. Berdasarkan penelitian terbaru, penyakit BLB dapat menurunkan hasil panen hingga 20-30%, sementara Brown Spot dapat menyebabkan kerugian hingga 45% pada kondisi epidemi yang parah [4]. Oleh karena itu, identifikasi dini terhadap penyakit ini sangat penting untuk meminimalkan kerugian ekonomi bagi petani [5].

Metode konvensional untuk mendeteksi penyakit tanaman biasanya dilakukan secara manual oleh petani atau ahli pertanian melalui pengamatan visual [6]. Namun, pendekatan ini memerlukan waktu yang cukup banyak, serta rentan terhadap kesalahan manusia, sehingga deteksi penyakit

menjadi tidak efisien [7]. Sebuah studi menunjukkan bahwa akurasi deteksi manual hanya mencapai 60-70% bahkan oleh ahli berpengalaman [8]. Untuk itu, teknologi berbasis computer vision dan machine learning telah digunakan untuk mengidentifikasi penyakit daun padi secara otomatis dengan menganalisis citra daun yang terinfeksi [9] [10].

Pada sistem deteksi penyakit tanaman berbasis citra, ekstraksi fitur adalah langkah penting yang mengubah citra daun menjadi data yang dapat digunakan oleh algoritma klasifikasi [11]. Fitur yang diekstraksi dari citra ini, seperti tekstur, bentuk, atau tepi daun, memungkinkan model untuk membedakan antara daun yang sehat dan yang terinfeksi penyakit [12]. Penelitian oleh Alsakar et al. [1] menunjukkan bahwa penggunaan multi-level multi-channel Local Binary Pattern (MCLBP) dapat mencapai akurasi hingga 99.53% dalam mendeteksi penyakit daun padi. Oleh karena itu, pemilihan metode ekstraksi fitur yang efisien, akurat, dan tahan terhadap gangguan pencahayaan dan noise sangat penting untuk mendapatkan hasil klasifikasi yang optimal [13].

Tiga pendekatan ekstraksi fitur yang banyak digunakan dalam deteksi penyakit tanaman adalah Local Binary Patterns

(LBP), Gray Level Co-occurrence Matrix (GLCM), dan Canny Edge Detection [14], [15]. LBP dikenal efektif untuk mendeteksi pola tekstur lokal dan tahan terhadap perubahan pencahayaan, menghasilkan histogram 256-dimensi yang merepresentasikan distribusi pola tekstur dalam neighborhood circular, sehingga cocok untuk deteksi penyakit pada daun padi [16]. GLCM memberikan analisis tekstur yang lebih mendalam dengan menghitung empat statistik tekstur global (contrast, homogeneity, energy, correlation) yang menghasilkan fitur 16-dimensi, meskipun memerlukan waktu komputasi yang lebih lama dan sensitif terhadap variasi orientasi [3]. Penelitian menggunakan GLCM pada deteksi penyakit kritis tanaman padi bahkan mencapai akurasi 100% pada 84 sampel uji [17]. Canny Edge Detection menghasilkan binary edge map yang fokus pada deteksi tepi dan struktur geometris, berperan penting dalam mengidentifikasi batas dan kontur area yang terinfeksi, namun kehilangan informasi tekstur internal yang krusial untuk diferensiasi penyakit [18]. Ketiga metode ini menghasilkan jenis dan jumlah fitur yang berbeda, sehingga memiliki kelebihan dan kekurangan masing-masing dalam mendeteksi penyakit daun padi. Untuk mengetahui metode mana yang terbaik, diperlukan perbandingan yang adil menggunakan algoritma klasifikasi yang sama.

Algoritma klasifikasi digunakan untuk mengidentifikasi jenis penyakit yang ada pada daun padi. K-Nearest Neighbor (KNN) adalah algoritma klasifikasi yang populer karena kesederhanaannya, efektivitasnya, dan kemampuannya dalam menangani data yang tidak terstruktur, seperti citra tanaman [19]. Untuk evaluasi objektif terhadap metode ekstraksi fitur, KNN dipilih sebagai classifier tunggal karena sifat non-parametriknya yang tidak membuat asumsi distribusi data, sehingga cocok untuk mengevaluasi berbagai jenis representasi fitur dengan karakteristik berbeda [20]. KNN bekerja dengan cara mengklasifikasikan data berdasarkan kedekatannya dengan data yang sudah diberi label dalam ruang fitur, dimana korelasi dengan metode ekstraksi fitur terletak pada bagaimana setiap metode menghasilkan feature space yang unik untuk distance computation: histogram LBP memungkinkan similarity matching berbasis distribusi pola, fitur statistik GLCM memfasilitasi comparison berbasis korelasi spasial, sedangkan binary edge map Canny mendukung structural similarity matching [21]. Dengan kata lain, KNN akan melihat K tetangga terdekat dari data yang ingin diklasifikasikan dan memberikan label yang paling banyak muncul dari tetangga tersebut. Salah satu keuntungan dari KNN adalah tidak memerlukan pelatihan model yang rumit, sehingga mempercepat proses implementasi dan memungkinkan evaluasi fair terhadap kualitas representasi fitur tanpa bias dari kompleksitas model [22]. Namun, performa KNN sangat bergantung pada pemilihan nilai K (jumlah tetangga yang diperhitungkan) dan pengukuran jarak antar data [23]. Perbedaan dimensional dan tipe representasi dari ketiga metode ekstraksi fitur akan mempengaruhi meaningfulness dari distance metrics dan optimal hyperparameter selection, dengan Manhattan distance terbukti superior untuk aplikasi agricultural

spatial [24]. Pemilihan nilai K yang tepat sangat penting untuk memastikan akurasi klasifikasi yang optimal, karena nilai K yang terlalu kecil dapat menyebabkan overfitting, sedangkan nilai K yang terlalu besar dapat menyebabkan underfitting [25]. Penelitian menunjukkan bahwa nilai K=1 sering memberikan hasil terbaik dengan akurasi 98.84% menggunakan correlation-based feature selection [5]. Selain itu, pemilihan metrik jarak, seperti Euclidean, Manhattan, atau Minkowski, juga dapat mempengaruhi performa klasifikasi. Oleh karena itu, dalam penelitian ini, optimasi hyperparameter KNN dilakukan untuk menemukan kombinasi terbaik yang dapat meningkatkan hasil klasifikasi.

Penelitian ini bertujuan untuk membandingkan ketiga metode ekstraksi fitur LBP, GLCM, dan Canny Edge Detection dan mengevaluasi performanya dalam klasifikasi penyakit daun padi menggunakan KNN. Dengan melakukan optimasi hyperparameter pada KNN dan memilih fitur terbaik untuk digunakan, diharapkan penelitian ini dapat memberikan solusi yang lebih efisien dan akurat dalam mendeteksi penyakit pada tanaman padi, yang dapat digunakan oleh petani untuk mengurangi kerugian akibat penyakit tanaman.

II. STUDI PUSTAKA

Berbagai pendekatan telah dikembangkan untuk mengekstraksi fitur tekstur dan struktur dari citra tanaman, mulai dari metode berbasis local texture descriptors hingga teknik analisis statistik spasial dan ekstraksi tepi. Studi-studi terkini secara konsisten menekankan pentingnya pemilihan metode ekstraksi fitur yang tidak hanya akurat tetapi juga efisien secara komputasi dan toleran terhadap noise serta variasi pencahayaan. Oleh karena itu, dalam bagian ini akan dibahas tiga pendekatan ekstraksi fitur utama yang sering digunakan dalam deteksi penyakit tanaman, yaitu Local Binary Patterns (LBP), Gray Level Co-occurrence Matrix (GLCM), dan Canny Edge Detection, serta analisis komparatif terhadap performa dan efisiensinya dalam berbagai konfigurasi dan kombinasi.

Deteksi penyakit tanaman padi menggunakan pendekatan computer vision dan machine learning telah menjadi area penelitian yang sangat aktif dalam beberapa tahun terakhir. Keberhasilan sistem deteksi sangat bergantung pada pemahaman karakteristik visual penyakit target: Bacterial Leaf Blight (BLB) yang disebabkan *Xanthomonas oryzae* pv. *oryzae* menampilkan lesi bergelombang berwarna kekuningan-putih dengan tepi water-soaked [26], Brown Spot oleh *Bipolaris oryzae* menghasilkan lesi konsentris dengan pusat abu-abu dikelilingi margin cokelat dan halo kuning, sedangkan Leaf Smut akibat *Entyloma oryzae* menghasilkan bintik-bintik hitam kecil tersebar yang memberikan tampilan seperti ditaburi merica hitam [27]. Sebuah tinjauan sistematis oleh Seelwal et al. [25] menunjukkan evolusi signifikan dari metode tradisional berbasis ekstraksi fitur manual menuju pendekatan deep learning. Namun, metode ekstraksi fitur tradisional seperti Local Binary Patterns (LBP), Gray Level Co-occurrence Matrix (GLCM), dan deteksi tepi masih memiliki relevansi

penting, terutama dalam konteks komputasi yang terbatas dan kebutuhan interpretabilitas model yang tinggi [7].

Local Binary Patterns (LBP) telah terbukti menjadi metode ekstraksi fitur tekstur yang sangat efektif untuk deteksi penyakit daun tanaman. Penelitian oleh Singh dan Kaur [16] mendemonstrasikan bahwa kombinasi LBP dengan deep convolutional neural networks dapat mencapai akurasi keseluruhan sebesar 98.73% dalam mendeteksi berbagai penyakit daun tanaman. Keunggulan utama LBP terletak pada kemampuannya untuk menangkap pola tekstur lokal yang invariant terhadap perubahan pencahayaan, sebuah karakteristik yang sangat penting mengingat kondisi pencahayaan yang bervariasi dalam pengambilan gambar di lapangan [14]. Alsakar et al. [1] mengembangkan pendekatan multi-level multi-channel LBP (MCLBP) yang dikombinasikan dengan Color Correlogram, mencapai akurasi luar biasa sebesar 99.53% pada dataset yang mencakup penyakit BLB, Brown Spot, dan Leaf Smut pada tanaman padi.

Saputra et al. [3] melakukan studi komprehensif menggunakan ekstraksi fitur GLCM yang mencakup contrast, energy, entropy, homogeneity, dan correlation untuk klasifikasi penyakit daun padi menggunakan KNN. Meskipun hanya mencapai akurasi 65.83% dengan $k=11$, penelitian ini memberikan wawasan penting tentang parameter GLCM yang paling diskriminatif untuk deteksi penyakit padi. Penelitian terbaru juga menunjukkan bahwa kombinasi GLCM dengan metode lain dapat meningkatkan performa secara signifikan [17].

Canny Edge Detection, meskipun kurang populer dibandingkan LBP dan GLCM untuk deteksi penyakit tanaman, memainkan peran penting dalam mengidentifikasi batas-batas area yang terinfeksi pada daun. Xizhen et al. [18] mengembangkan algoritma Canny yang dimodifikasi khusus untuk pemrosesan gambar daun tanaman, meningkatkan kemampuan deteksi tepi pada kondisi pencahayaan yang tidak ideal. Ketika dikombinasikan dengan metode deep learning modern, seperti yang ditunjukkan oleh Zhang et al. [13], integrasi Canny edge detection dengan DenseNet201 dan EfficientNetB3 dapat mencapai akurasi 99.03%, menunjukkan potensi sinergi antara teknik tradisional dan modern.

K-Nearest Neighbor (KNN) sebagai algoritma klasifikasi yang sangat efektif untuk deteksi penyakit tanaman padi. Sebuah studi komparatif komprehensif oleh Udmale et al. [19] menganalisis berbagai varian KNN dan mengidentifikasi faktor-faktor kunci yang mempengaruhi performanya, termasuk pemilihan nilai k , metrik jarak, dan teknik pembobotan. Penelitian oleh Purnamawati et al. [28] membandingkan lima algoritma (KNN, Decision Tree, Random Forest, Naïve Bayes, dan SVM) untuk mendeteksi penyakit pada daun padi. Hasilnya menunjukkan bahwa KNN memberikan akurasinya sebesar 87%, lebih baik dibandingkan algoritma lainnya yang cenderung mengalami overfitting (Random Forest, Decision Tree, Naïve Bayes) atau underfitting (SVM). Dengan demikian, KNN dianggap sebagai metode


yang paling andal dan stabil dalam klasifikasi penyakit daun padi di antara yang diuji.

Perbandingan langsung antara berbagai metode ekstraksi fitur untuk deteksi penyakit padi telah dilakukan dalam beberapa penelitian. Sethy et al. [2] membandingkan LBP + SVM, HOG + SVM, dan GLCM + SVM dengan metode deep learning pada 5932 gambar lapangan yang mencakup bacterial blight, blast, dan brown spot. Hasil mereka menunjukkan bahwa meskipun metode deep learning umumnya unggul, kombinasi fitur tradisional masih kompetitif untuk aplikasi dengan sumber daya terbatas. Penelitian [14] yang menggabungkan fitur LBP dan GLCM untuk meningkatkan kekuatan diskriminasi, dengan aplikasi potensial untuk data penyakit tanaman volumetrik.

Optimasi hyperparameter menjadi aspek krusial dalam meningkatkan performa sistem deteksi. Penelitian menunjukkan bahwa pemilihan nilai k yang optimal dalam KNN sangat bergantung pada karakteristik dataset dan distribusi kelas penyakit. Untuk dataset penyakit padi, nilai k yang lebih kecil (1-5) cenderung memberikan hasil yang lebih baik, kemungkinan karena pola penyakit yang distingtif dan clustering alami dalam ruang fitur [6]. Selain itu, pemilihan metrik jarak juga memainkan peran penting, dengan Euclidean distance sering menjadi pilihan default, meskipun Manhattan dan Minkowski distance dapat memberikan hasil yang lebih baik untuk fitur tertentu [19].

III. METODOLOGI PENELITIAN


Bab ini membahas metode yang akan digunakan dalam penelitian ini. Metode penelitian terdiri dari beberapa tahap yang dilakukan secara berurutan, yaitu dataset collection, data preprocessing, feature extraction, classification, dan evaluasi performa. Gambar 1 menunjukkan langkah-langkah yang diambil dalam penelitian dan memberikan gambaran yang lebih baik tentang prosesnya.



Gambar 1. Diagram alir metodologi penelitian klasifikasi penyakit daun padi

A. Dataset dan Preparasi Data

1) *Dataset Collection* : Dataset berupa 120 citra daun padi dengan format JPG. Dataset terbagi menjadi 3 kelas, yaitu bacterial leaf blight, brown spot, dan leaf smut untuk lebih detail jenis penyakit nya bisa dilihat pada Gambar 2. Dataset citra diperoleh dari website UCI Machine Learning Repository (diakses pada 9 Juli 2025) [29]. Semua data gambar yang diperoleh dalam penelitian ini disimpan dalam format JPG.



Gambar 2. Jenis-jenis penyakit pada daun padi; (a) Bacterial leaf blight, (b) Leaf smut, (c) Brown spot

TABEL I
DATASET AWAL

No.	Original	Jumlah
1	Bacterial leaf blight	40
2	Brown spot	40
3	Leaf smut	40
	Total	120

Dataset awal ini total keseluruhan berjumlah 120 dari 3 kelas, masing – masing kelas terdiri dari 40 gambar.

2) *Preparasi Data* : Lalu Tahap preparasi data merupakan langkah penting sebelum proses ekstraksi fitur dilakukan. Langkah awal dilakukan Proses augmentasi dilakukan menggunakan beberapa teknik transformasi citra, seperti rotasi, flipping, penyesuaian kecerahan, dan blur. Tabel 2 berikut merangkum jenis augmentasi yang digunakan beserta parameter dan jumlah variasi yang dihasilkan.

TABEL II
JENIS AUGMENTASI

No.	Jenis Augmentasi	Value
1	Rotation	10°, 20°, 30°, 45°
2	Horizontal Flip	axis=1
3	Vertical Flip	axis=2
4	Brightness Up	alpha=1.2, beta=+20
5	Brightness Down	alpha=0.8, beta=-20
6	Gaussian Blur	kernel=(5,5), sigma=0

TABEL II
SETELAH AUGMENTASI

No.	Jenis Penyakit	Jumlah
1	Bacterial leaf blight	400
2	Brown spot	400
3	Leaf smut	400
	Total	1200

Total data setelah augmentasi yang digunakan dalam penelitian ini terdiri dari 1200 citra daun padi dengan resolusi 224×224 piksel yang dikumpulkan dari tiga jenis penyakit utama: Bacterial Leaf Blight (400 citra), Brown Spot (400 citra), dan Leaf Smut (400 citra). Setiap kategori penyakit memiliki 280 citra untuk data training dan 120 citra untuk data testing dengan rasio pembagian 70:30. Tahap preparasi data meliputi normalisasi intensitas piksel ke rentang 0-1. Selanjutnya dilakukan konversi citra dari format RGB ke grayscale dengan R, G, B adalah komponen warna merah, hijau, dan biru.

Pemilihan resolusi 224×224 piksel dalam penelitian ini memerlukan justifikasi yang lebih mendalam mengingat dampak signifikan resolusi terhadap performa algoritma K-Nearest Neighbor (KNN) dan efisiensi komputasi secara keseluruhan. Resolusi yang dipilih ini memberikan keseimbangan optimal antara preservasi informasi visual penting untuk deteksi penyakit dan kecepatan komputasi yang diperlukan dalam implementasi praktis. Oleh karena itu, pemilihan resolusi 224×224 piksel bertujuan untuk menghindari dimensionalitas yang terlalu tinggi sambil tetap mempertahankan informasi visual yang cukup untuk membedakan karakteristik spesifik dari setiap jenis penyakit daun padi, sehingga algoritma KNN dapat bekerja secara efisien untuk aplikasi real-time di lapangan.

B. Ekstraksi Fitur dan Klasifikasi

1) *Local Binary Patterns (LBP)* : Metode LBP diimplementasikan dengan radius 1 piksel dan 8 sampling points untuk mengekstraksi fitur tekstur lokal. Algoritma LBP menghitung nilai biner untuk setiap piksel dengan membandingkan intensitas piksel pusat dengan piksel tetangga. Histogram LBP dengan 256 bins digunakan sebagai vektor fitur untuk setiap citra.

$$LBP(x, y) = \sum_{p=0}^N 2^p (g(B_p - B(x_c, y_c))) \quad (1)$$

Pada persamaan 1 rumus LBP, Di mana LBP (xc, yc) mewakili fitur LBP pada piksel pusat x_c, y_c . $B(x_c, y_c)$ adalah nilai dari piksel pusat, dan B_p adalah nilai dari piksel tetangga. Indeks p merujuk pada indeks piksel tetangga. Jika x kurang dari 0, fungsi g (x) akan sama dengan nol, jika tidak, akan sama dengan satu.

2) *Gray Level Co-occurrence Matrix (GLCM)* : Fitur GLCM diekstraksi pada empat arah (0° , 45° , 90° , 135°) dengan jarak piksel $d=1$ untuk menganalisis hubungan spasial antar piksel [30]. Empat fitur statistik utama dihitung dari setiap matriks GLCM: contrast, dissimilarity, homogeneity, dan energy menggunakan persamaan (2)-(6):

$$\text{Contrast} = \sum_{i,j=0}^{N-1} P_{ij}(i-j)^2 \quad (2)$$

$$\text{Energy} = \sum_{i,j=0}^{n-1} (P_{ij})^2 \quad (3)$$

$$\text{Entropy} = \sum_{i,j=0}^{N-1} -\ln(P_{ij}) P_{ij} \quad (4)$$

$$\text{Homogeneity} = \sum_{i,j=0}^{N-1} \frac{P_{ij}}{1+(j-i)^2} \quad (5)$$

$$\text{Correlation} = \sum_{i,j=0} \frac{(i-\mu_i)(j-\mu_j)p(i,j)}{\sigma_i \sigma_j} \quad (6)$$

dengan $P(i,j)$ adalah probabilitas co-occurrence untuk intensitas i dan j . Total 16 fitur ($4 \text{ fitur} \times 4 \text{ arah}$) digunakan sebagai vektor fitur untuk setiap citra.

3) *Canny Edge Detection* : Deteksi tepi Canny diterapkan dengan threshold rendah 50 dan threshold tinggi 150 untuk mengidentifikasi struktur tepi daun. Algoritma Canny menggunakan filter Gaussian dengan $\sigma=1.4$ untuk reduksi noise, gradien Sobel untuk deteksi tepi, dan non-maximum suppression untuk penipisan tepi. Fitur yang diekstraksi meliputi jumlah piksel tepi, rasio piksel tepi terhadap total piksel, dan momen geometri (area, perimeter, eccentricity) dari kontur tepi yang terdeteksi.

4) *Algoritma K-Nearest Neighbors (KNN)* : Klasifikasi dilakukan menggunakan algoritma KNN dengan optimasi hyperparameter melalui Grid Search Cross-Validation. Parameter yang dioptimasi meliputi nilai k (1, 3, 5, 7, 9, 11), metrik jarak (Euclidean, Manhattan, Minkowski), dan weight function (uniform, distance). Fungsi jarak Euclidean. Evaluasi performa dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score.

5) *Evaluasi* : Untuk mengevaluasi kinerja masing-masing metode ekstraksi fitur (LBP, GLCM, dan Canny), kami menggunakan beberapa metrik evaluasi yang meliputi akurasi,

presisi, recall, dan F1 score. Metrik ini berdasarkan pada perbandingan antara hasil prediksi dan kondisi sebenarnya. True Positives (TP) merujuk pada jumlah kasus di mana model berhasil memprediksi kelas positif dengan benar. Sebaliknya, True Negatives (TN) adalah jumlah kasus di mana model berhasil memprediksi kelas negatif dengan tepat. False Positives (FP) terjadi ketika model salah mengklasifikasikan data negatif sebagai positif, sedangkan False Negatives (FN) adalah ketika model gagal mengidentifikasi kelas positif dan mengklasifikasikannya sebagai negatif.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$


$$\text{Presisi} = \frac{TP}{TP + FP} \quad (8)$$

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

$$\text{F1-Score} = 2x \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \quad (10)$$

IV. HASIL DAN PEMBAHASAN

Hasil penelitian ini menguji tiga metode ekstraksi fitur untuk klasifikasi penyakit tanaman, yaitu LBP (Local Binary Patterns), GLCM (Gray-Level Co-occurrence Matrix), dan Canny edge detection. Disini untuk algoritma KNN dengan optimasi hyperparameter melalui Grid Search Cross-Validation. Parameter yang dioptimasi meliputi nilai k (1, 3, 5, 7, 9, 11), metrik jarak (Euclidean, Manhattan, Minkowski), dan weight function (uniform, distance).




Gambar 3. Confusion matrix dari ketiga ekstraksi fitur. (a) LBP, (b) GLCM, (c) Canny Edge Detection

Gambar 3 menunjukkan confusion matrix dari hasil klasifikasi menggunakan tiga metode ekstraksi fitur. Berdasarkan hasil tersebut, metode LBP menghasilkan performa klasifikasi terbaik dengan akurasi sebesar 92,06%. karena metode ini mampu menangkap pola tekstur kecil pada daun yang tidak berubah meskipun ada perubahan cahaya. LBP bekerja dengan melihat area kecil di sekitar setiap piksel dan menghasilkan 256 jenis fitur yang dapat menggambarkan pola tekstur dengan detail. Hal ini sangat cocok untuk mendeteksi ciri-ciri khas setiap penyakit: Bacterial Leaf Blight yang memiliki luka bergelombang, Brown Spot dengan pola melingkar, dan Leaf Smut dengan bintik-bintik kecil tersebar. LBP dapat menangkap perbedaan-perbedaan kecil ini dengan baik karena metode ini peka terhadap perubahan tekstur dalam area yang sempit.

Hasil GLCM dengan akurasi 78,57% menunjukkan performa yang lebih rendah dibandingkan LBP. Temuan ini kontras dengan penelitian Iqbal et al. [17] yang melaporkan akurasi 100% menggunakan GLCM pada 84 sampel uji untuk deteksi penyakit kritis tanaman padi. Perbedaan signifikan ini dapat dijelaskan oleh beberapa faktor. Pertama, penelitian Iqbal et al. menggunakan dataset yang lebih kecil dan terfokus pada penyakit kritis saja, sedangkan penelitian ini menguji tiga jenis penyakit dengan karakteristik visual yang lebih beragam. Kedua, penelitian ini menggunakan dataset yang telah diaugmentasi menjadi 1200 citra, yang mungkin memperkenalkan variasi orientasi dan transformasi yang menantang bagi GLCM yang sensitif terhadap perubahan arah.

Metode Metode Canny Edge Detection memberikan hasil terendah dengan akurasi 66,67%. Hasil ini konsisten dengan literatur yang menunjukkan bahwa deteksi tepi saja tidak cukup untuk klasifikasi penyakit tanaman. Penelitian Zhang et al. [13] menunjukkan bahwa Canny dapat mencapai akurasi tinggi (99,03%) hanya ketika dikombinasikan dengan deep learning networks seperti DenseNet201 dan EfficientNetB3. Ketika digunakan secara independen seperti dalam penelitian ini, Canny hanya menghasilkan binary edge map yang kehilangan informasi tekstur krusial. Xizhen et al. [18] mengembangkan Canny yang dimodifikasi untuk tanaman dan menekankan bahwa metode ini lebih cocok sebagai preprocessing untuk segmentasi daripada sebagai ekstraksi fitur utama untuk klasifikasi.

Perbandingan ketiga metode ini mengungkapkan pola yang konsisten dengan meta-analisis oleh Seelwal et al. [25] yang menunjukkan bahwa local texture descriptors seperti LBP umumnya mengungguli metode global untuk deteksi penyakit tanaman. Penelitian Sethy et al. [2] yang membandingkan LBP+SVM, HOG+SVM, dan GLCM+SVM pada 5932 citra lapangan juga menunjukkan bahwa LBP memberikan performa terbaik di antara metode tradisional, meskipun masih kalah dari deep learning. Namun, keunggulan LBP dalam penelitian ini (92,06%) yang mendekati performa deep learning menjadi menarik mengingat efisiensi komputasinya yang jauh lebih baik.



Gambar 4. Perbandingan hasil evaluasi kinerja dari tiga metode ekstraksi fitur

Gambar 4 memperkuat hasil ini dengan menunjukkan bahwa LBP konsisten unggul di semua metrik evaluasi (presisi, recall, F1-score). Konsistensi ini sejalan dengan temuan Pradhan et al. [16] yang menekankan robustness LBP terhadap variasi kondisi pengambilan gambar. Analisis mendalam terhadap hubungan antara resolusi gambar 224×224 piksel dan performa setiap metode mengungkapkan dampak yang berbeda-beda. Untuk LBP, resolusi ini optimal karena memberikan keseimbangan antara detail tekstur dan efisiensi komputasi, konsisten dengan rekomendasi dalam literatur untuk aplikasi real-time di lapangan. Gambar 4 memperkuat hasil ini dengan menunjukkan bahwa LBP konsisten unggul di semua metrik evaluasi (presisi, recall, F1-score). Konsistensi ini sejalan dengan temuan Pradhan et al. [16] yang menekankan robustness LBP terhadap variasi kondisi pengambilan gambar. Analisis mendalam terhadap hubungan antara resolusi gambar 224×224 piksel dan performa setiap metode mengungkapkan dampak yang berbeda-beda. Untuk LBP, resolusi ini optimal karena memberikan keseimbangan antara detail tekstur dan efisiensi komputasi, konsisten dengan rekomendasi dalam literatur untuk aplikasi real-time di lapangan..

Jumlah Implikasi dari augmentasi data yang menghasilkan 400 citra per kelas juga perlu dianalisis dalam konteks penelitian sebelumnya. Penelitian Ahmed et al. [6] menunjukkan bahwa augmentasi data dapat meningkatkan akurasi klasifikasi penyakit padi hingga 15-20%. Dalam penelitian ini, kombinasi 10 jenis augmentasi (rotasi, flipping, brightness adjustment, Gaussian blur) tidak hanya meningkatkan kuantitas data tetapi juga robustness model terhadap variasi visual. Hal ini terutama menguntungkan LBP yang dapat mempertahankan invariance-nya terhadap transformasi geometris sederhana, berbeda dengan GLCM yang performanya menurun akibat sensitivitas terhadap orientasi.

Temuan bahwa LBP mencapai performa optimal dengan nilai $k=1$ dalam KNN sejalan dengan penelitian Tawde et al. [5] yang melaporkan hasil serupa dengan akurasi 98,84% menggunakan correlation-based feature selection. Hal ini mengindikasikan bahwa fitur LBP menghasilkan clustering yang baik dalam feature space, dimana sampel dari kelas yang sama cenderung berkumpul berdekatan. Sebaliknya, GLCM

dan Canny memerlukan nilai k yang lebih besar, menunjukkan distribusi fitur yang lebih tersebar dan overlapping antar kelas.

Secara keseluruhan, hasil penelitian ini mengkonfirmasi tren dalam literatur bahwa metode ekstraksi fitur berbasis tekstur lokal seperti LBP lebih efektif untuk klasifikasi penyakit daun dibandingkan metode global atau struktural. Namun, penelitian ini juga menunjukkan bahwa dengan optimasi yang tepat, metode tradisional masih dapat mencapai performa yang kompetitif dengan pendekatan modern, sambil mempertahankan keunggulan dalam hal interpretabilitas dan efisiensi komputasi. Temuan ini memberikan kontribusi penting untuk pengembangan sistem deteksi penyakit yang praktis dan dapat diimplementasikan pada perangkat dengan sumber daya terbatas, sesuai dengan kebutuhan aplikasi pertanian di lapangan.

V. KESIMPULAN

Berdasarkan hasil evaluasi terhadap tiga metode ekstraksi fitur Local Binary Pattern (LBP), Gray Level Co-occurrence Matrix (GLCM), dan Canny Edge Detection dapat disimpulkan bahwa metode LBP memberikan performa terbaik dalam klasifikasi penyakit daun padi. Hal ini ditunjukkan dari hasil confusion matrix dan visualisasi metrik evaluasi yang secara konsisten menunjukkan bahwa LBP memiliki nilai akurasi, presisi, recall, dan F1-score tertinggi dibandingkan dua metode lainnya, dengan rata-rata mendekati 0,92. Metode GLCM berada di urutan kedua dengan skor evaluasi sekitar 0,78, sementara metode Canny menunjukkan performa terendah dengan skor rata-rata hanya sekitar 0,66.

Perbedaan performa ini menunjukkan bahwa LBP lebih unggul dalam mengekstraksi ciri-ciri tekstur lokal yang relevan dan mampu merepresentasikan variasi visual antar jenis penyakit daun secara lebih efektif. Di sisi lain, fitur tekstur global dari GLCM dan fitur tepi dari Canny kurang memberikan kontribusi yang optimal dalam konteks klasifikasi multi-kelas penyakit daun padi. Analisis lebih mendalam terhadap hasil pembahasan menunjukkan bahwa keunggulan LBP disebabkan oleh kemampuannya dalam menangkap pola tekstur mikro yang menjadi karakteristik unik setiap jenis penyakit, seperti pola bercak pada Brown spot, tekstur bergelombang pada Leaf smut, dan area nekrotik pada Bacterial leaf blight.

Implementasi teknik augmentasi data dengan 10 variasi transformasi berhasil meningkatkan ukuran dataset menjadi 10 kali lipat dari dataset asli, yang secara signifikan berkontribusi terhadap peningkatan performa klasifikasi. Hasil pembahasan menunjukkan bahwa augmentasi dengan rotasi (10° - 45°), flipping horizontal dan vertikal, penyesuaian kecerahan, dan Gaussian blur tidak hanya memperbanyak jumlah data tetapi juga meningkatkan kemampuan generalisasi model dalam mengenali penyakit pada berbagai kondisi visual. Kombinasi augmentasi data dengan ekstraksi fitur LBP menghasilkan sistem yang robust dan mampu mengatasi variasi pencahayaan, orientasi, dan kualitas gambar yang berbeda-beda.

Perbandingan dengan penelitian terdahulu menunjukkan bahwa hasil akurasi 92% yang dicapai oleh metode LBP dalam penelitian ini kompetitif dengan studi serupa dalam domain klasifikasi penyakit tanaman. Keunggulan pendekatan yang digunakan terletak pada efisiensi komputasi yang tinggi dibandingkan metode deep learning, sehingga lebih sesuai untuk implementasi pada perangkat dengan keterbatasan resource. Selain itu, interpretabilitas fitur LBP memberikan keuntungan dalam memahami dasar keputusan klasifikasi, yang penting untuk aplikasi di bidang pertanian dimana kepercayaan pengguna terhadap sistem sangat krusial.

Hasil penelitian ini memberikan kontribusi signifikan dalam pengembangan sistem deteksi dini penyakit daun padi yang dapat membantu petani mengidentifikasi masalah kesehatan tanaman sebelum menyebar luas. Implementasi sistem berbasis LBP berpotensi mengurangi kerugian ekonomi akibat penyakit tanaman dan mendukung praktik pertanian berkelanjutan. Namun demikian, penelitian ini memiliki keterbatasan pada cakupan dataset yang terbatas pada tiga jenis penyakit dengan kondisi pengambilan gambar yang relatif terkontrol. Penelitian selanjutnya disarankan untuk mengeksplorasi kombinasi multiple features extraction, memperluas dataset dengan variasi kondisi lingkungan yang lebih beragam, serta mengimplementasikan sistem pada platform mobile untuk meningkatkan aksesibilitas bagi petani di lapangan. Dengan demikian, dapat disimpulkan bahwa LBP merupakan metode ekstraksi fitur yang paling tepat untuk diterapkan dalam sistem klasifikasi otomatis penyakit daun padi berbasis citra digital.

REFERENSI

- [1] Y. M. Alsakar, N. A. Sakr, dan M. Elmogy, "An enhanced classification system of various rice plant diseases based on multi-level handcrafted feature extraction technique," *Sci. Rep.*, vol. 14, no. 1, hal. 1–33, 2024, doi: 10.1038/s41598-024-81143-1.
- [2] P. K. Sethy, N. K. Barpanda, A. K. Rath, dan S. K. Behera, "Deep feature based rice leaf disease identification using support vector machine," *Comput. Electron. Agric.*, vol. 175, no. May, hal. 105527, 2020, doi: 10.1016/j.compag.2020.105527.
- [3] R. A. Saputra, Suharyanto, S. Wasiyanti, D. F. Saefudin, A. Supriyatna, dan A. Wibowo, "Rice Leaf Disease Image Classifications Using KNN Based on GLCM Feature Extraction," *J. Phys. Conf. Ser.*, vol. 1641, no. 1, 2020, doi: 10.1088/1742-6596/1641/1/012080.
- [4] J. R. F. Mirandilla, M. Yamashita, M. Yoshimura, dan E. C. Paringit, "Leaf Spectral Analysis for Detection and Differentiation of Three Major Rice Diseases in the Philippines," *Remote Sens.*, vol. 15, no. 12, 2023, doi: 10.3390/rs15123058.
- [5] T. Tawde, K. Deshmukh, L. Verekar, A. Reddy, S. Aswale, dan P. Shetgaonkar, "Rice Plant Disease Detection and Classification technique A survey," *Int. J. Eng. Res. Technol.*, vol. 10, no. 07, hal. 560–567, 2021.
- [6] K. Ahmed, T. R. Shahidi, S. M. Irfanul Alam, dan S. Momen, "Rice leaf disease detection using machine learning techniques," *2019 Int. Conf. Sustain. Technol. Ind. 4.0, STI 2019*, no. May 2020, hal. 1–5, 2019, doi: 10.1109/STI47673.2019.9068096.
- [7] C. G. Simhadri, H. K. Kondaveeti, V. K. Vatsavayi, A. Mitra, dan P. Ananthachari, "Deep learning for rice leaf disease detection: A systematic literature review on emerging trends, methodologies and techniques," *Inf. Process. Agric.*, vol. 12, no. 2, hal. 151–168, 2025, doi: 10.1016/j.inpa.2024.04.006.
- [8] B. S. Bari *et al.*, "A real-time approach of diagnosing rice leaf disease using deep learning-based faster R-CNN framework," *PeerJ*

- [9] *Comput. Sci.*, vol. 7, hal. 1–27, 2021, doi: 10.7717/PEERJ-CS.432.
- [10] M. F. D. S. R. U. J. B. D. E. Dolatabadian, Aria Ting Xiang Neik, “Image-based crop disease detection using machine learning,” *plant pathology*, 2024.
- [11] J. Liu dan X. Wang, “Plant diseases and pests detection based on deep learning: a review,” *Plant Methods*, vol. 17, no. 1, hal. 1–18, 2021, doi: 10.1186/s13007-021-00722-9.
- [12] M. A. Azim, M. K. Islam, M. M. Rahman, dan F. Jahan, “An effective feature extraction method for rice leaf disease classification,” *Telkonnika (Telecommunication Comput. Electron. Control.*, vol. 19, no. 2, hal. 463–470, 2021, doi: 10.12928/TELKOMNIKA.v19i2.16488.
- [13] M. Yogeshwari dan G. Thailambal, “Automatic feature extraction and detection of plant leaf disease using GLCM features and convolutional neural networks,” *sciencedirect*, 2023, doi: <https://doi.org/10.1016/j.matpr.2021.03.700>.
- [14] D. Senanu Ametefe *et al.*, “Enhancing leaf disease detection accuracy through synergistic integration of deep transfer learning and multimodal techniques,” *Inf. Process. Agric.*, no. September, 2024, doi: 10.1016/j.inpa.2024.09.006.
- [15] S. Barburiceanu, R. Terebes, dan S. Meza, “3D Texture Feature Extraction and Classification Using Glcm and Lbp-Based Descriptors,” *Appl. Sci.*, vol. 11, no. 5, hal. 1–26, 2021, doi: 10.3390/app11052332.
- [16] W. B. Demilie, “Plant disease detection and classification techniques: a comparative study of the performances,” *J. Big Data*, vol. 11, no. 1, 2024, doi: 10.1186/s40537-023-00863-9.
- [17] P. Pradhan, B. Kumar, K. Kumar, dan R. Bhutiani, “Plant leaf disease detection using local binary pattern and deep convolutional neural networks,” *Environ. Conserv. J.*, vol. 26, no. 1, hal. 66–78, 2025, doi: 10.36953/ECJ.29292943.
- [18] N. Iqbal, R. Mumtaz, U. Shafi, dan S. M. H. Zaidi, “Gray level co-occurrence matrix (GLCM) texture based crop classification using low altitude remote sensing platforms,” *PeerJ Comput. Sci.*, vol. 7, hal. 1–26, 2021, doi: 10.7717/PEERJ-CS.536.
- [19] S. Xizhen, Z. Wei, G. Yiling, dan Y. Shengyang, “Edge detection algorithm of plant leaf image based on improved Canny,” *2021 IEEE 6th Int. Conf. Intell. Comput. Signal Process. ICSP 2021*, vol. 5, no. Ics, hal. 342–345, 2021, doi: 10.1109/ICSP51882.2021.9408929.
- [20] S. Uddin, I. Haque, H. Lu, M. A. Moni, dan E. Gide, “Comparative performance analysis of K-nearest neighbour (KNN) algorithm and its different variants for disease prediction,” *Sci. Rep.*, vol. 12, no. 1, hal. 1–11, 2022, doi: 10.1038/s41598-022-10358-x.
- [21] R. K. Halder, M. N. Uddin, M. A. Uddin, S. Aryal, dan A. Khraisat, “Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications,” *J. Big Data*, vol. 11, no. 1, 2024, doi: 10.1186/s40537-024-00973-y.
- [22] S. Vijayan dan C. L. Chowdhary, “Hybrid feature optimized CNN for rice crop disease prediction,” *Sci. Rep.*, vol. 15, no. 1, hal. 7904, Mar 2025, doi: 10.1038/s41598-025-92646-w.
- [23] S. M. Darwish, R. A. Ali, dan A. A. Elzoghbi, “Quantum-inspired K-nearest neighbors classifier for enhanced printer source identification in forensic document analysis,” *Sci. Rep.*, vol. 15, no. 1, hal. 4097, Feb 2025, doi: 10.1038/s41598-025-86558-y.
- [24] H. Wang, P. Xu, dan J. Zhao, “Improved KNN Algorithm Based on Preprocessing of Center in Smart Cities,” *Complexity*, vol. 2021, 2021, doi: 10.1155/2021/5524388.
- [25] A. Ali, Z. Khan, H. Du, dan S. Aldahmani, “Double weighted k nearest neighbours for binary classification of high dimensional genomic data,” *Sci. Rep.*, vol. 15, no. 1, hal. 12681, Apr 2025, doi: 10.1038/s41598-025-97505-2.
- [26] P. Seelwal, P. Dhiman, Y. Gulzar, A. Kaur, S. Wadhwa, dan C. W. Onn, “A systematic review of deep learning applications for rice disease diagnosis: current trends and future directions,” *Front. Comput. Sci.*, vol. 6, no. September, 2024, doi: 10.3389/fcomp.2024.1452961.
- [27] O. Ritbamrung, P. Inthima, K. Ratanasut, K. Sujipuli, T. Rungrat, dan K. Buddhachat, “Evaluating *Xanthomonas oryzae* pv. *oryzae* (Xoo) infection dynamics in rice for distribution routes and environmental reservoirs by molecular approaches,” *Sci. Rep.*, vol. 15, no. 1, hal. 1408, Jan 2025, doi: 10.1038/s41598-025-85422-3.
- [28] K. H. Kaboré, A. I. Kassankogno, dan D. Tharreau, “Brown Spot of Rice: Worldwide Disease Impact, Phenotypic and Genetic Diversity of the Causal Pathogen *Bipolaris oryzae*, and Management of the Disease,” *Plant Pathol.*, vol. 74, no. 4, hal. 908–922, Mei 2025, doi: 10.1111/ppa.14075.
- [29] A. Purnamawati, W. Nugroho, D. Putri, dan W. F. Hidayat, “Deteksi Penyakit Daun pada Tanaman Padi Menggunakan Algoritma Decision Tree, Random Forest, Naïve Bayes, SVM dan KNN,” *InfoTekJar J. Nas. Inform. dan Teknol. Jar.*, vol. 5, no. 1, hal. 212–215, 2020, [Daring]. Tersedia pada: <https://doi.org/10.30743/infotekjar.v5i1.2934>
- [29] H. B. Prajapati, J. P. Shah, dan V. K. Dabhi, “Detection and classification of rice plant diseases,” *Intell. Decis. Technol.*, vol. 11, no. 3, hal. 357–373, 2017, doi: 10.3233/IDT-170301.