

OPTIMALISASI MODEL KLASIFIKASI PENYAKIT DAUN MANGGA MENGUNAKAN ALGORITMA K-NEAREST NEIGHBOR

Arya Nugraha Ramdoni¹, Ade Irma Purnamasari², Denni Pratama³, Riri Narasati⁴.

Program Studi Teknik Informatika^{1,2,4}
Program Studi Komputerisasi Akuntansi³

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
nugrahaarya2212@gmail.com

(*) Corresponding Author : nugrahaarya2212@gmail.com.
Published : 30 Maret 2026

Abstract—This study aims to develop an effective classification model for mango leaf diseases by combining Local Binary Pattern (LBP) for texture feature extraction and the K-Nearest Neighbor (KNN) algorithm as a lightweight and computationally efficient classifier. The dataset consists of eight categories of mango leaf diseases, comprising a total of 4,000 images. All images underwent preprocessing steps, including resizing, grayscale conversion, and normalization, to ensure consistent input quality. Feature extraction was performed using LBP with commonly applied parameters, namely radius ($R = 3$) and sampling points ($P = 24$), producing stable texture histograms that serve as feature vectors for the classification process. In the baseline configuration, the KNN model was initialized using $K = 5$ and achieved an accuracy of 74.8%. The confusion matrix analysis indicated that several classes, such as Cutting Weevil, Bacterial Canker, and Die Back, were classified with relatively high precision, while other classes—particularly Anthracnose and Gall Midge—experienced misclassification due to the similarity of their texture patterns. Optimization was then carried out to determine the most suitable K value through cross-validation. The results showed that $K = 1$ provided the best and most stable performance. When the model was retrained using the optimal K value, the accuracy increased to 76.1% on the test set. This improvement demonstrates that the selection of K plays a critical role in KNN performance, especially when dealing with histogram-based texture features such as LBP. Overall, this study demonstrates that the combination of LBP and KNN is capable of producing an accurate and efficient classification model for detecting mango leaf diseases. The approach is computationally lightweight, making it suitable for further development into real-world applications such as mobile-based or field-deployable plant disease detection systems.

Keywords: Local Binary Pattern, K-Nearest Neighbor, Texture Extraction, Mango Leaf Disease, Classification.

Abstrak—Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit daun mangga menggunakan metode ekstraksi tekstur *Local Binary Pattern* (LBP) dan algoritma *K-Nearest Neighbor* (KNN) sebagai pendekatan yang ringan serta efisien secara komputasi. Dataset yang digunakan terdiri dari delapan kelas penyakit daun mangga dengan total 4.000 citra, masing-masing melalui tahapan preprocessing yang meliputi perubahan ukuran, konversi ke grayscale, dan normalisasi untuk memastikan konsistensi input. Proses ekstraksi fitur dilakukan menggunakan LBP dengan konfigurasi parameter umum, yaitu radius ($R = 3$) dan jumlah titik sampel ($P = 24$), sehingga menghasilkan representasi histogram tekstur yang stabil sebagai input bagi model KNN. Pada tahap baseline, model KNN dikonfigurasi menggunakan nilai $K = 5$ dan menghasilkan akurasi sebesar 74,8%. Analisis terhadap *confusion matrix* menunjukkan bahwa beberapa kelas seperti *Cutting Weevil*, *Bacterial Canker*, dan *Die Back* memiliki tingkat prediksi yang tinggi, sedangkan kelas seperti *Anthracnose* dan *Gall Midge* masih menunjukkan misklasifikasi akibat kemiripan pola tekstur. Proses optimasi selanjutnya difokuskan pada penentuan nilai K terbaik menggunakan pendekatan *cross-validation*. Hasil pengujian menunjukkan bahwa nilai $K = 1$ memberikan performa paling optimal dan stabil. Ketika model dilatih kembali menggunakan konfigurasi optimal tersebut, akurasi meningkat menjadi 76,1% pada data uji. Peningkatan ini menunjukkan bahwa pemilihan nilai K menempati peran penting dalam kinerja KNN, terutama pada data berbasis histogram tekstur seperti LBP. Secara keseluruhan, penelitian ini membuktikan bahwa kombinasi LBP dan KNN mampu menghasilkan model klasifikasi penyakit daun mangga yang akurat dan efisien tanpa memerlukan sumber daya komputasi tinggi.

Pendekatan ini berpotensi untuk dikembangkan lebih lanjut pada aplikasi praktis berbasis citra untuk mendukung proses deteksi penyakit tanaman di lapangan.

Kata Kunci : Local Binary Pattern, K-Nearest Neighbor, Ekstraksi Tekstur, Klasifikasi, Penyakit Daun Mangga.

INTRODUCTION

Mangga merupakan salah satu komoditas buah musiman yang telah lama dikenal dan digemari oleh masyarakat Indonesia. Tanaman ini berasal dari India dan memiliki beragam varietas yang banyak dibudidayakan di Indonesia. Pohon mangga dapat tumbuh dengan optimal pada daerah beriklim hangat dengan kondisi tanah datar. Dalam bidang pertanian, serangan penyakit tanaman masih menjadi tantangan serius karena dapat berdampak signifikan terhadap kualitas dan kuantitas hasil produksi. Oleh karena itu, penelitian ini dilakukan untuk mengembangkan sistem yang mampu mengklasifikasikan jenis penyakit pada daun mangga. Adapun jenis penyakit yang menjadi fokus klasifikasi dalam penelitian ini meliputi, Bacterial Canker, Cutting Weevil, Die Back, Gall Midge, Powdery Mildew, dan Sooty Mould [1], [2]

Beberapa penelitian terdahulu telah berhasil menerapkan kombinasi ekstraksi fitur Local Binary Pattern (LBP) dan algoritma K-Nearest Neighbor (KNN) untuk mendeteksi penyakit tanaman. Penelitian oleh Atmaja et al (2024) menggunakan LBP dan KNN untuk mengklasifikasikan penyakit pada buah tomat dan menunjukkan bahwa metode tersebut mampu memberikan performa yang baik pada citra pertanian. Penelitian tersebut menggunakan 140 citra tomat yang terdiri dari data latih dan data uji, dan berhasil menunjukkan efektivitas LBP sebagai metode ekstraksi fitur tekstur serta KNN sebagai algoritma klasifikasi. Temuan tersebut memberikan dasar yang kuat untuk menerapkan pendekatan serupa pada daun mangga dalam penelitian ini.

Sebelumnya, penelitian mengenai klasifikasi penyakit daun mangga telah dilakukan oleh Anggraeni et al (2025) penelitian tersebut menggunakan pendekatan machine learning klasik dengan menggabungkan metode ekstraksi fitur tekstur Gray Level Co-occurrence Matrix (GLCM) dan algoritma Adaptive Neuro-Fuzzy Inference System (ANFIS) untuk mendeteksi penyakit pada daun mangga. Mangga merupakan salah satu komoditas hortikultura penting di Indonesia dan banyak dibudidayakan oleh masyarakat. Berdasarkan data Badan Pusat Statistik, produksi mangga

nasional pada tahun 2023 mencapai 1,8 juta ton dan menunjukkan peningkatan dibandingkan tahun-tahun sebelumnya. Namun demikian, produktivitas tanaman mangga sering mengalami penurunan akibat serangan berbagai penyakit, terutama pada bagian daun, yang dapat mengganggu proses fotosintesis dan menyebabkan penurunan kualitas serta kuantitas hasil panen. Pada penelitian tersebut, penulis menggunakan dataset dari Kaggle yang terdiri dari tujuh kelas, yaitu enam kelas penyakit daun mangga dan satu kelas daun sehat, dengan total 500 citra untuk setiap kelas. Penyakit yang diamati meliputi, Bacterial Canker, Die Back, Gall Midge, Powdery Mildew, dan Sooty Mould. Seluruh citra kemudian dikonversi dari format RGB menjadi grayscale sebagai tahap praproses. Selanjutnya, proses ekstraksi fitur dilakukan menggunakan metode GLCM untuk memperoleh karakteristik tekstur. Citra yang telah diproses diubah menjadi bentuk array dua dimensi, kemudian dihitung matriks ko-okurensi dengan mempertimbangkan sudut dan piksel tertentu. Matriks tersebut dinormalisasi ke rentang 0 hingga 1 sebelum diambil empat parameter utama, yaitu kontras, homogenitas, korelasi, dan energi, sebagai masukan ke dalam model ANFIS. Hasil penelitian menunjukkan bahwa pendekatan ini mampu mencapai akurasi rata-rata sebesar 74,6%. Meskipun demikian, tingkat akurasi tersebut masih dapat ditingkatkan, sehingga membuka peluang penelitian lanjutan dengan memanfaatkan metode ekstraksi fitur tekstur lain, seperti Local Binary Pattern (LBP), serta algoritma klasifikasi yang berbeda. Beberapa kesalahan klasifikasi masih terjadi cukup signifikan, misalnya kelas yang salah diprediksi sebagai Die Back sebanyak 26 kasus dan sebagai Gall Midge sebanyak 22 kasus. Selain itu, terdapat 17 citra kelas Gall Midge yang salah diklasifikasikan sebagai kelas Healthy[3], [4].

Penelitian oleh Ramadhani & Tarigan (2025) Mangga merupakan salah satu komoditas hortikultura penting di Indonesia dengan produksi mencapai jutaan ton per tahun dan menjadi buah yang banyak digemari masyarakat. Namun dalam proses budidayanya, tanaman mangga rentan terserang berbagai penyakit, khususnya pada bagian daun, yang dapat menyebabkan penurunan kualitas maupun kuantitas hasil panen. Beberapa jenis penyakit daun mangga yang umum dijumpai antara lain, Bacterial Canker, Cutting Weevil, Die Back, Gall Midge, Powdery Mildew, dan Sooty

Mould. Oleh karena itu, deteksi dini penyakit daun mangga sangat diperlukan untuk mencegah kerugian lebih lanjut dan membantu petani dalam pengambilan keputusan. Seiring berkembangnya teknologi, metode kecerdasan buatan telah banyak digunakan dalam klasifikasi penyakit tanaman. Penelitian sebelumnya menunjukkan bahwa pendekatan berbasis Convolutional Neural Network (CNN) mampu menghasilkan tingkat akurasi yang sangat tinggi dalam mengidentifikasi penyakit daun mangga, yang mengimplementasikan metode Convolutional Neural Network (CNN) dengan arsitektur EfficientNetV2-S dan ResNet50 pada dataset berjumlah 4000 citra, masing-masing 500 citra per kelas penyakit. Hasil penelitian menunjukkan bahwa kedua arsitektur tersebut mampu menghasilkan performa klasifikasi yang sangat baik dan dapat diimplementasikan dalam bentuk aplikasi berbasis website. Dalam penelitian tersebut juga dikutip beberapa studi relevan lain yang mencapai tingkat akurasi tinggi, seperti akurasi 97,13% menggunakan CNN, hingga akurasi mencapai 100% pada kombinasi CNN dan Random Forest, serta lebih dari 99% menggunakan DenseNet dengan nilai precision 97,83%, recall 97,73%, dan F1-Score 98,29%. Hasil ini menunjukkan bahwa pendekatan berbasis pembelajaran mendalam memiliki kinerja unggul dalam deteksi penyakit daun mangga[5], [6].

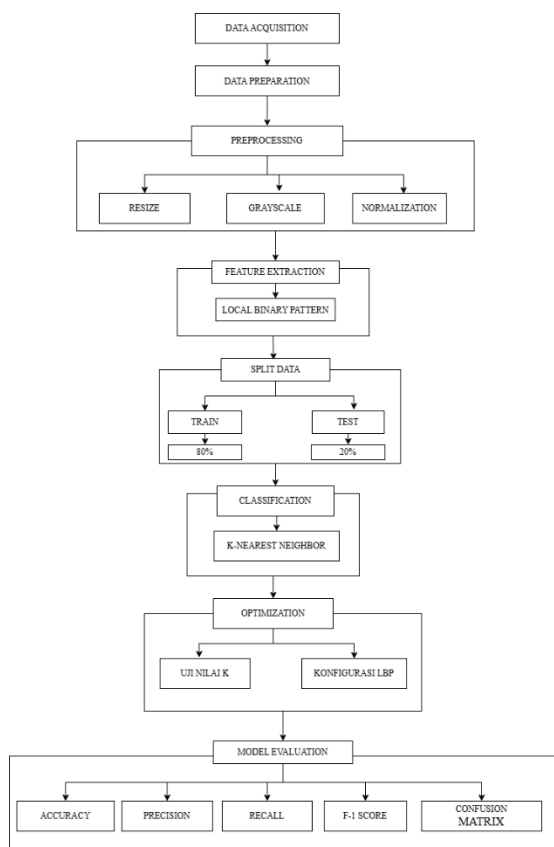
Penelitian Oleh Simangunsong (2021) Penelitian tersebut bertujuan untuk mengembangkan sistem identifikasi penyakit daun mangga berbasis deep learning guna membantu proses deteksi dini penyakit tanaman. Metode yang digunakan adalah arsitektur MobileNetV2, yang merupakan model Convolutional Neural Network ringan dengan kemampuan komputasi efisien sehingga cocok diimplementasikan pada perangkat dengan keterbatasan sumber daya. Dataset yang digunakan terdiri atas 1500 citra daun mangga, yang terbagi menjadi tiga kelas, yaitu capmodium, collectricum, dan daun sehat. Seluruh citra diolah melalui tahap pra-pemrosesan dan data augmentation untuk meningkatkan variasi data serta mencegah overfitting. Selanjutnya, data dibagi dengan rasio 80% untuk pelatihan, 10% untuk pengujian, dan 10% untuk validasi, dan model dilatih selama 50 epoch menggunakan optimizer Adam. Hasil penelitian menunjukkan bahwa model berhasil mencapai akurasi sebesar 90%, dengan nilai presisi 91%, recall 90%, dan F1-score 89%, sehingga membuktikan bahwa MobileNetV2 efektif dalam mengidentifikasi

penyakit daun mangga secara otomatis. Meskipun demikian, beberapa kesalahan klasifikasi masih ditemukan, terutama antara kelas capmodium dan daun sehat akibat kemiripan pola visual pada kedua jenis daun tersebut. Temuan ini mengindikasikan perlunya eksplorasi pendekatan lain atau pengembangan metode yang lebih optimal untuk meningkatkan akurasi dan mengurangi kesalahan identifikasi antar kelas penyakit yang memiliki karakteristik serupa.

Merujuk pada penelitian terdahulu, metode berbasis deep learning seperti CNN dan MobileNetV2 terbukti mampu memberikan tingkat akurasi yang sangat tinggi dalam mengklasifikasikan penyakit daun mangga. Namun demikian, model-model tersebut membutuhkan sumber daya komputasi yang besar baik pada tahap pelatihan maupun implementasi. Di sisi lain, pendekatan yang memanfaatkan ekstraksi fitur tekstur seperti GLCM juga menunjukkan kinerja yang cukup baik, meskipun masih ditemukan kesalahan klasifikasi pada beberapa kategori penyakit. Berdasarkan hal tersebut, penelitian ini memilih untuk menggunakan metode yang lebih ringan secara komputasi dengan menerapkan Local Binary Pattern (LBP) sebagai teknik ekstraksi fitur dan algoritma K-Nearest Neighbor (KNN) sebagai model klasifikasi. Pendekatan ini diharapkan dapat menghasilkan model yang efisien namun tetap memberikan tingkat akurasi yang kompetitif, serta memungkinkan penerapannya pada perangkat dengan keterbatasan sumber daya, sehingga dapat mendukung proses identifikasi penyakit daun mangga secara lebih efektif dan praktis[7], [8], [9].

MATERIALS AND METHODS

alur penelitian secara sistematis mulai dari tahap akuisisi data hingga evaluasi model. Setiap tahapan dirancang saling terintegrasi untuk memastikan proses klasifikasi berjalan terstruktur, mulai dari preprocessing, ekstraksi fitur LBP, pemodelan KNN, hingga optimasi parameter



Gambar 1. Alur penelitian

Tahap ini melibatkan proses pengambilan dan pengumpulan data citra daun mangga dari sumber dataset publik. Data terdiri dari beberapa kelas penyakit seperti Bacterial Canker, Cutting Weevil, Die Back, Gall Midge, Powdery Mildew, Sooty Mould, serta kelas Healthy. Seluruh citra diunduh, diperiksa kelengkapannya, kemudian disiapkan untuk tahap pengolahan berikutnya

Tahap data preparation dilakukan untuk memastikan seluruh citra berada dalam kondisi layak dan konsisten sebelum dianalisis. Proses ini mencakup penataan dataset berdasarkan delapan kelas penyakit daun mangga, pengecekan kualitas citra, serta identifikasi file yang tidak sesuai seperti gambar duplikat, kabur, atau penamaan yang tidak seragam

Tahap data preprocessing dilakukan untuk menstandarkan kualitas citra sebelum proses ekstraksi fitur. Pada tahap ini setiap citra mengalami proses resize, konversi warna ke grayscale, dan normalisasi intensitas piksel. Penyeragaman ini penting agar seluruh data memiliki format yang konsisten sehingga lebih mudah diproses oleh algoritma klasifikasi.

Resize dilakukan untuk menyeragamkan dimensi citra sehingga seluruh gambar memiliki ukuran yang konsisten. Penyeragaman ukuran ini penting untuk meningkatkan stabilitas

proses ekstraksi fitur, termasuk pada metode Local Binary Pattern. Studi terbaru menunjukkan bahwa resizing merupakan bagian penting dalam pipeline pengolahan citra pada sistem penglihatan komputer modern.

Konversi citra dari format RGB ke grayscale dilakukan untuk menyederhanakan informasi visual menjadi satu kanal intensitas. Metode Local Binary Pattern bekerja lebih efektif pada citra grayscale karena analisis tekstur dilakukan berdasarkan variasi intensitas piksel. Transformasi ini merupakan teknik dasar yang banyak digunakan dalam pengolahan citra digital.

Normalization dilakukan untuk menyeragamkan rentang nilai intensitas piksel pada setiap citra. Proses ini membantu mengurangi pengaruh perbedaan pencahayaan antar gambar sehingga fitur yang dihasilkan menjadi lebih stabil. Dengan normalisasi, proses ekstraksi fitur dan evaluasi model dapat dilakukan secara lebih konsisten

Ekstraksi fitur dilakukan menggunakan metode Local Binary Pattern untuk menangkap pola tekstur lokal pada citra daun mangga. Metode ini bekerja dengan membandingkan nilai intensitas piksel dengan piksel tetangganya dan membentuk histogram pola biner yang merepresentasikan karakteristik tekstur citra secara efektif.

Setelah fitur berhasil diekstraksi, dataset dibagi menjadi dua bagian yaitu data latih dan data uji dengan rasio 80:20. Pembagian ini bertujuan memastikan model dapat dilatih menggunakan sebagian data dan diuji menggunakan data yang belum pernah dilihat sebelumnya untuk mengukur kemampuan generalisasi model.

Tahap klasifikasi menggunakan metode K-Nearest Neighbor (KNN), yaitu algoritma pembelajaran terawasi yang menentukan label kelas berdasarkan kedekatan jarak antar data dalam ruang fitur. Algoritma ini mengklasifikasikan data baru dengan melihat sejumlah tetangga terdekat dari data latih yang telah diketahui labelnya.

Tahap optimization dilakukan untuk meningkatkan performa model klasifikasi melalui penyesuaian parameter penting. Parameter yang dioptimasi meliputi nilai K pada algoritma KNN serta konfigurasi Local Binary Pattern seperti radius dan jumlah titik sampel yang digunakan dalam proses ekstraksi fitur.

Pemilihan nilai K merupakan tahap penting dalam proses tuning algoritma KNN. Nilai K menentukan jumlah tetangga terdekat yang digunakan dalam proses klasifikasi. Oleh karena itu beberapa nilai K seperti 1, 3, 5, 7, 9, dan 11 diuji untuk menemukan konfigurasi yang menghasilkan performa terbaik.

RESULTS AND DISCUSSION

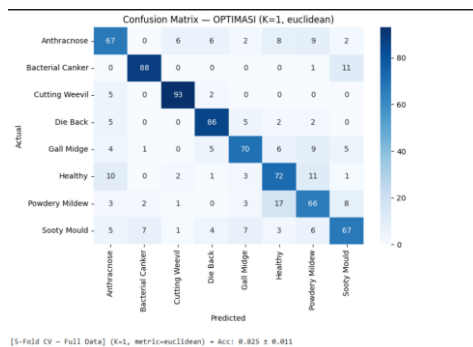
Pada tahap evaluasi, performa model dianalisis berdasarkan dua kondisi, yaitu sebelum dan setelah proses optimalisasi parameter. Gambar 2 menunjukkan *confusion matrix* model KNN setelah melalui tahap optimalisasi nilai K. Berdasarkan hasil uji *cross-validation* menggunakan skema *5-fold CV*, nilai K = 1 teridentifikasi sebagai konfigurasi terbaik dengan akurasi rata-rata mencapai 0.825 ± 0.011 . Model kemudian dievaluasi pada *test set* menggunakan konfigurasi optimal tersebut dengan metrik jarak Euclidean.

Secara umum, performa model setelah optimalisasi terlihat mengalami peningkatan dibandingkan baseline. Hal ini terlihat dari perbaikan distribusi prediksi yang semakin terkonsentrasi di diagonal utama, yang menandakan meningkatnya jumlah prediksi benar untuk sebagian besar kelas.

Beberapa kelas seperti *Cutting Weevil*, *Healthy*, dan *Die Back* memperlihatkan akurasi yang sangat baik, dengan jumlah prediksi tepat yang tinggi dan sangat sedikit kesalahan klasifikasi. Hal ini mengindikasikan bahwa pola tekstur pada kelas-kelas tersebut dapat dikenali dengan baik oleh model ketika nilai K diperkecil menjadi 1.

Sementara itu, kelas seperti *Gall Midge*, dan *Sooty Mould* masih menunjukkan beberapa kesalahan prediksi, meskipun jumlahnya lebih sedikit dibandingkan model baseline. Kesalahan ini mayoritas terjadi pada kelas yang memiliki kemiripan visual dan tekstur, sehingga batas antar kelas pada *feature space* menjadi kurang tegas.

Peningkatan performa setelah optimalisasi juga diperkuat oleh nilai akurasi *cross-validation* yang lebih tinggi dan stabil (0.825 ± 0.011), menunjukkan bahwa konfigurasi ini tidak hanya baik pada *test set*, tetapi juga konsisten pada berbagai pembagian data.



Gambar 2 Setelah optimalisasi

```
[OPTIMASI (K=1, euclidean)] Accuracy: 0.761
precision recall f1-score support
Anthracnose 0.677 0.670 0.673 100
Bacterial Canker 0.898 0.880 0.889 100
Cutting Weevil 0.903 0.930 0.916 100
Die Back 0.827 0.860 0.843 100
Gall Midge 0.778 0.700 0.737 100
Healthy 0.667 0.720 0.692 100
Powdery Mildew 0.635 0.660 0.647 100
Sooty Mould 0.713 0.670 0.691 100
accuracy 0.762 0.761 0.761 800
macro avg 0.762 0.761 0.761 800
weighted avg 0.762 0.761 0.761 800
Confusion Matrix:
[[67 0 6 6 2 8 9 2]
 [0 88 0 0 0 0 1 11]
 [5 0 93 2 0 0 0 0]
 [5 0 0 86 5 2 2 0]
 [4 1 0 5 70 6 9 5]
 [10 0 2 1 3 72 11 1]
 [3 2 1 0 3 17 66 8]
 [5 7 1 4 7 3 6 67]]
```

Gambar 3 Setelah Optimalisasi

Gambar 3 menampilkan *classification report* model KNN setelah proses optimalisasi nilai K, di mana nilai terbaik yang diperoleh adalah K = 1 dengan penggunaan metrik *Euclidean*. Berdasarkan hasil pengujian pada *test set*, model menghasilkan akurasi keseluruhan sebesar 0.761. Nilai ini menunjukkan peningkatan dari baseline dan menegaskan bahwa pemilihan K yang lebih kecil mampu memberikan kemampuan diskriminasi yang lebih baik pada dataset ini.

Nilai *f1-score* yang tinggi pada kelas-kelas tersebut menunjukkan bahwa tekstur daun yang menjadi ciri visual masing-masing kelas dapat dipelajari dengan baik oleh model ketika menggunakan K yang lebih kecil. Hal ini mengindikasikan bahwa pola-pola lokal hasil ekstraksi LBP memberikan representasi fitur yang cukup kuat bagi KNN untuk melakukan pencarian tetangga terdekat.

Sementara itu, beberapa kelas seperti *Gall Midge*, dan *Powdery Mildew* memiliki nilai *recall* yang lebih rendah (0.670, 0.700, dan 0.660). Hal ini dapat disebabkan oleh kemiripan pola tekstur antar kelas yang mengakibatkan sebagian sampel salah diarahkan ke kelas lain. Misalnya pada *gall midge* memiliki distribusi nilai *grayscale* yang cenderung mirip pada area bercak, sehingga menyebabkan ambiguitas pada proses klasifikasi.

Bagian *confusion matrix* memperlihatkan bagaimana setiap kelas diprediksi oleh model. Kotak diagonal utama menunjukkan jumlah prediksi benar, dan sebagian besar kelas memiliki nilai diagonal yang tinggi, misalnya: *Cutting Weevil* (93 benar) *Healthy* (72 benar) *Die Back* (86 benar) *Powdery Mildew* (66 benar) *Sooty Mould* (67 benar)

Nilai-nilai ini memperlihatkan bahwa model bekerja dengan sangat baik pada kelas dengan pola

tekstur yang lebih khas dan tidak mudah tertukar. Namun beberapa kesalahan masih terlihat pada kelas-kelas yang memiliki karakteristik bercak yang mirip, seperti , *Gall Midge*, dan *Powdery Mildew*.

Dengan nilai macro average f1-score = 0.761, model menunjukkan performa yang cukup seimbang antar kelas, meskipun masih terdapat beberapa kelas minor yang performanya dapat ditingkatkan pada penelitian selanjutnya.

CONCLUSION

Berdasarkan rangkaian proses penelitian yang meliputi tahapan preprocessing, ekstraksi fitur menggunakan *Local Binary Pattern* (LBP), klasifikasi menggunakan algoritma *K-Nearest Neighbor* (KNN), serta optimasi parameter model, maka dapat disimpulkan beberapa hal sebagai berikut :

1. Metode *Local Binary Pattern* (LBP) mampu mengekstraksi pola tekstur daun mangga secara efektif dan memberikan representasi fitur yang stabil untuk digunakan dalam proses klasifikasi. Konfigurasi LBP dengan radius 3 dan 24 titik sampel menghasilkan histogram fitur yang lebih informatif serta mampu membedakan sebagian besar pola penyakit daun mangga.
2. Proses ekstraksi fitur menggunakan metode *Local Binary Pattern* (LBP) telah berhasil menghasilkan representasi tekstur yang stabil dan informatif untuk setiap citra daun mangga. Dengan konfigurasi parameter umum yang digunakan, yakni radius ($R = 3$) dan jumlah titik sampel ($P = 8 \times R$), LBP mampu menangkap pola tekstur lokal secara konsisten dan efektif. Representasi histogram yang dihasilkan cukup membedakan sebagian besar kelas penyakit, dan menjadi dasar penting yang mendukung kinerja model KNN dalam tahap klasifikasi.
3. Optimasi parameter nilai K memberikan peningkatan performa yang jelas dibandingkan model baseline. Pada konfigurasi awal ($K = 5$, *Euclidean*), model memperoleh akurasi sebesar 74.8%, sedangkan setelah dilakukan optimasi nilai K dan diperoleh nilai terbaik ($K = 1$, *Euclidean*), akurasi meningkat menjadi 76.1%. Peningkatan ini menunjukkan bahwa pemilihan jumlah tetangga yang tepat berkontribusi pada stabilitas dan ketepatan prediksi model.

REFERENCE

- [1] A. Tangkelayuk And E. Mailoa, "Klasifikasi Kualitas Air Menggunakan Metode Knn, Naive Bayes Dan Decision Tree," Vol. 9, No. 2, Pp. 1109–1119, 2022, [Online]. Available: [Http://jurnal.mdp.ac.id](http://jurnal.mdp.ac.id)
- [2] L. Mutawali, W. Murniati, And K. Kunci, "Penerapan Knnimputer Dalam Mengolah Data Missing Value Untuk Membantu Meningkatkan Akurasi Support Vector Machine Klasifikasi Penyakit Tiroid," 2022. [Online]. Available: [Https://archive.ics.uci.edu/ml/datasets/Thyroid+Diseas](https://archive.ics.uci.edu/ml/datasets/Thyroid+Diseas)
- [3] F. Adi And E. Wintarti, "Komparasi Metode Svm, Knn, Dan Random Forest Untuk Prediksi Gagal Jantung Dengan Gui Aplikasi," 2022.
- [4] E. Mardiani *Et Al*, "Analisis Kompleksitas Password Dengan Metode Knn, Naive Bayes, Decision Tree, Ensemble Methods Dan Linear Regression," *Digital Transformation Technology*, Vol. 3, No. 2, Pp. 955–966, Jan. 2024, Doi: 10.47709/Digitech.V3i2.3513.
- [5] E. Mardiani *Et Al*, "Analisis Kompleksitas Password Dengan Metode Knn, Naive Bayes, Decision Tree, Ensemble Methods Dan Linear Regression," *Digital Transformation Technology*, Vol. 3, No. 2, Pp. 955–966, Jan. 2024, Doi: 10.47709/Digitech.V3i2.3513.
- [6] T. Ngongo, F. Elefri Neno, D. Reby Sabawaly, And S. Maris Sumba Jalankarya Kasih No, "Analisa Sentimen Masyarakat Pembayaran Pajak Kendaraan Bermotor Dengan Metode Knn," 2024.
- [7] D. Nasien, R. Syahputra, A. Akbar Marunduri, And R. Prawinata See, "Klasifikasi Penyakit Jantung Menggunakan Decision Tree Dan Knn Menggunakan Ekstraksi Fitur Pca," 2024.
- [8] J. Umamaheswari And A. Akila, "An Enhanced Human Speech Emotion Recognition Using Hybrid Of Prnn And Knn," In *Proceedings Of The International Conference On Machine Learning, Big Data, Cloud And Parallel Computing: Trends, Perspectives And Prospects, Comitcon 2019*, 2019, Pp. 177–183. Doi: 10.1109/Comitcon.2019.8862221.
- [9] J. Umamaheswari And A. Akila, "An Enhanced Human Speech Emotion Recognition Using Hybrid Of Prnn And Knn," In *Proceedings Of The International Conference On Machine Learning, Big Data, Cloud And Parallel Computing: Trends,*

*Prespectives And Prospects, Comitcon
2019, 2019, Pp. 177-183. Doi:
10.1109/Comitcon.2019.8862221.*