

# Klasifikasi Penyakit Tanaman Cabai Berdasarkan Seleksi Fitur GLCM dan Algoritma K-Nearest Neighbor

## *Classification of Chili Plant Diseases Using GLCM Feature Selection and the K-Nearest Neighbor Algorithm*

Ratna A.Fi'Nawu  
Prodi Teknik Informatika  
Universitas Ichsan Gorontalo  
Gorontalo, Indonesia  
ratnapinau8@gmail.com

Irvan Abraham Salihi  
Prodi Teknik Informatika  
Universitas Ichsan Gorontalo  
Gorontalo, Indonesia  
irvanabrahams@gmail.com

Zulfrainto Y Lamasigi\*  
Prodi Tekknik Informatik  
Universitas Ichsan Gorontalo  
Gorontalo, Indonesia  
zulfrianto.dsn.unisan@gmail.com

Irma Surya Kumala Idris  
Prodi Teknik Informatika  
Universitas Ichsan Gorontalo  
Gorontalo, Indonesia  
mhaladp@gmail.com

Diterima : Oktober 2025  
Disetujui : Desember 2025  
Dipublikasi : Januari 2026

**Abstrak**— Cabai (*Capsicum annum* L.) merupakan komoditas hortikultura strategis di Indonesia dengan nilai ekonomi yang tinggi. Namun, tanaman cabai seringkali diserang penyakit seperti Antraknosa, Layu Fusarium, Lalat Buah, dan Thrips yang dapat menyebabkan kehilangan hasil panen yang signifikan. Identifikasi dini dan akurat terhadap penyakit-penyakit ini sangat penting untuk pengendalian yang efektif. Penelitian ini bertujuan untuk mengklasifikasikan penyakit tanaman cabai berdasarkan citra daun menggunakan Gray Level Co-occurrence Matrix (GLCM) untuk ekstraksi fitur dan algoritma K-Nearest Neighbor (K-NN) untuk klasifikasi. Sebanyak 736 citra daun digunakan, yang dibagi ke dalam empat kelas penyakit. Tahapan pra-pemrosesan meliputi perubahan ukuran citra menjadi 300×300 piksel, augmentasi rotasi (0°, 45°, 75°, 90°), dan konversi ke skala keabuan. Fitur tekstur diekstraksi menggunakan GLCM pada empat sudut, dan K-NN diaplikasikan dengan nilai K=5, 7, dan 9. Akurasi klasifikasi tertinggi sebesar 88,19% dicapai pada sudut GLCM 0° dan K=5, dengan akurasi rata-rata keseluruhan di semua sudut sebesar 85,06%. Temuan ini tidak hanya memperkuat temuan sebelumnya tentang keefektifan GLCM dan K-NN, tetapi juga memberikan kontribusi dengan mengidentifikasi konfigurasi parameter optimal (sudut 0° dan K=5) untuk dataset penyakit cabai yang spesifik. Hasil penelitian ini berpotensi untuk diaplikasikan sebagai dasar dalam pengembangan sistem deteksi penyakit tanaman secara otomatis di lapangan.

**Kata Kunci**—Klasifikasi Citra; GLCM; K-Nearest Neighbor; Penyakit Cabai; Augmentasi Data

**Abstract**— *Chili pepper (Capsicum annum L.) is a strategic horticultural commodity in Indonesia with high economic value. However, chili plants are often infected by diseases such as Anthracnose, Fusarium Wilt, Fruit Fly, and Thrips, which can lead to significant yield losses. Early and accurate identification of these diseases is crucial for effective control measures. This study aims to classify chili plant diseases based on leaf images using the Gray Level Co-occurrence Matrix (GLCM) for feature extraction and the K-Nearest Neighbor (K-NN) algorithm for classification. A total of 736 leaf images were used, divided into*

*four disease classes. The pre-processing stages included resizing the images to 300×300 pixels, rotation augmentation (0°, 45°, 75°, 90°), and conversion to grayscale. Textural features were extracted using GLCM at four angles, and K-NN was applied with K values of 5, 7, and 9. The highest classification accuracy of 88.19% was achieved at a GLCM angle of 0° and K=5, with an overall average accuracy across all angles of 85.06%. These findings not only reinforce previous findings on the effectiveness of GLCM and K-NN but also contribute by identifying the optimal parameter configuration (angle 0° and K=5) for the specific chili disease dataset. The results have the potential to be applied as a foundation for developing an automated plant disease detection system in the field.*

**Keywords**—Image Classification; GLCM; K-Nearest Neighbor; Chili Disease; Data Augmentation

### I. PENDAHULUAN (HEADING 1)

Cabai (*Capsicum annum* L.) merupakan komoditas hortikultura strategis di Indonesia dengan nilai ekonomi yang signifikan [1]. Sebagai negara agraris, Indonesia memiliki kondisi iklim dan lahan yang ideal untuk budidaya cabai, menjadikannya salah satu tanaman prioritas dalam sektor pertanian [2]. Nilai ekonomis cabai tidak hanya terletak pada fungsinya sebagai bahan pangan dan bumbu, tetapi juga sebagai bahan baku industri yang mampu menyerap tenaga kerja [3]. Namun, budidaya tanaman ini seringkali menghadapi kendala utama berupa serangan hama dan penyakit, seperti Antraknosa, Layu Fusarium, Thrips, dan Lalat Buah, yang dapat menyebabkan kegagalan panen dan kerugian ekonomi mencapai 50-90% [1], [4]. Identifikasi dini penyakit pada tanaman cabai dapat dilakukan melalui pengamatan gejala visual pada daun, dimana perubahan morfologi daun menjadi indikator utama untuk mendiagnosis penyakit seperti virus kuning, keriting, dan bercak daun [3] [5].

Secara konvensional, diagnosis penyakit tanaman memerlukan tenaga ahli dan proses identifikasi yang

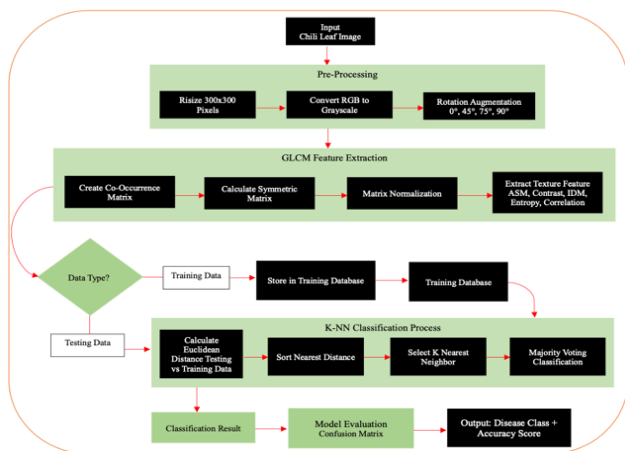
memakan waktu cukup lama. Metode identifikasi manual oleh petani juga seringkali tidak akurat akibat kemiripan visual gejala antar penyakit pada daun [3]. Metode ini tidak hanya memakan waktu tetapi juga rentan terhadap subjektivitas dan kesalahan diagnosis akibat kemiripan gejala visual pada daun yang terinfeksi [1], [2], [4], [5].

Perkembangan terkini dalam bidang computer vision menawarkan alternatif yang menjanjikan untuk klasifikasi penyakit tanaman secara terotomatisasi dan objektif [6]. Hal ini memungkinkan analisis citra digital daun untuk mendeteksi pola-pola khas tekstur dan warna yang unik dari suatu penyakit tertentu. Di antara berbagai metode ekstraksi fitur, Gray-Level Co-Occurrence Matrix (GLCM) telah terbukti efektif untuk mengkuantifikasi fitur tekstur statistik orde kedua dari data citra [7], [8], [9]. Fitur-fitur yang dihasilkan GLCM selanjutnya dapat diklasifikasikan menggunakan algoritma K-Nearest Neighbor (K-NN) [10], [11]. KNN dipilih karena kesederhanaannya, kemudahan implementasi, dan kemampuan dalam menangani berbagai jenis dataset tanpa memerlukan asumsi distribusi data yang ketat [8], [12], [13]. Beberapa penelitian terdahulu telah berhasil mengimplementasikan KNN untuk klasifikasi penyakit tanaman dengan hasil yang memadai, seperti pada tanaman kopi arabika (80%) [14].

Meskipun hasil-hasil ini menjanjikan, kombinasi spesifik antara ekstraksi fitur GLCM dan algoritma K-NN standar untuk identifikasi penyakit multi-kelas pada daun cabai masih relatif kurang dieksplorasi dan memerlukan investigasi lebih lanjut untuk mengoptimalkan kinerjanya [15].

## II. METODE

Penelitian ini merupakan penelitian terapan (applied research) dengan pendekatan kuantitatif. Secara metodologis, penelitian dikategorikan sebagai penelitian konfirmatori yang bertujuan menguji efektivitas kombinasi metode Gray Level Co-occurrence Matrix (GLCM) dan K-Nearest Neighbor (KNN) [16], [17], [18], [19] untuk klasifikasi penyakit tanaman cabai. Dalam penelitian ini, total data citra daun cabai yang digunakan adalah 736 citra dengan menggunakan 4 kelas penyakit: Antrakosa (228 training, 52 testing), Layu Fusarium (112 training, 28 testing), Lalat Buah (112 training, 28 testing), dan Thrips (140 training, 36 testing). Berikut pada gambar 1, merupakan proses kerja metode yang digunakan.



Gambar 1. Model Diagram Blok Arsitektur Sistem

Sistem pemrosesan data ini diimplementasikan menggunakan kerangka kerja yang terintegrasi, terdiri dari dua modul komputasi utama. Modul pertama, CLICK Feature Extraction, melakukan ekstraksi fitur melalui eksekusi kueri SQL terstruktur untuk mengambil data training dari pathology database. Modul ini mengelola katalog dan status sekuensing secara sistematis, dengan antarmuka API yang terhubung ke lingkungan komputasi lokal.

Modul kedua, K-NN Classification Process, memanfaatkan toolbox Machine Learning MATLAB untuk memproses data testing melalui pipeline klasifikasi yang dioptimalkan. Sistem melakukan konfigurasi vektor endpoint dan parameter klasifikasi secara dinamis, menghasilkan output kelas diagnostik yang dilengkapi dengan skor akurasi terkuantifikasi. Validasi akhir dilakukan melalui mekanisme pemeriksaan dataset terintegrasi untuk memastikan reliabilitas hasil.

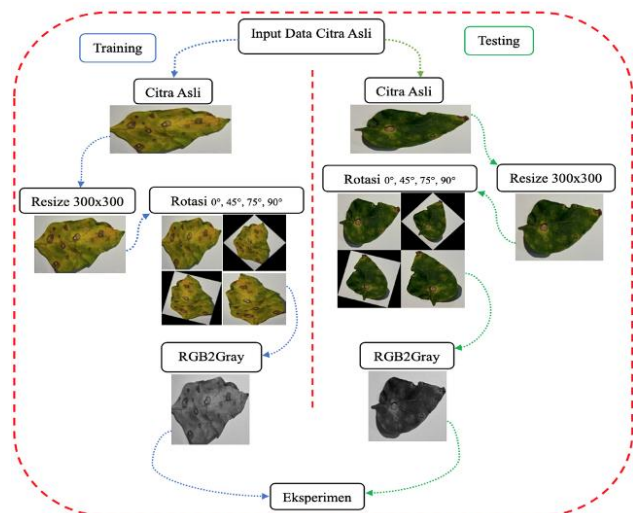
Arsitektur ini menyajikan implementasi komprehensif yang memanfaatkan kapabilitas pemrosesan data dan komputasi numerik MATLAB, menyediakan solusi terintegrasi untuk klasifikasi penyakit tanaman berbasis citra dengan validasi empiris yang rigor.

### A. Pra-Pemrosesan Citra

Pada tahapan pra-proses ini dimulai dengan tahap penginputan data citra asli daun cabai dan kemudian akan dilakukan proses resize kedalam ukuran 300 x 300 piksel setelah tahapan resize citra selesai, citra akan di rotasi dengan sudut 0°, 45°, 75°, dan 90°. Selanjutnya setelah proses rotasi selesai dilakukan, citra yang awalnya RGB akan di konversi kedalam bentuk citra *Grayscale* menggunakan persamaan [19], [21]:

$$\text{Gray} = 0.2989 \times R + 0.5870 \times G + 0.1140 \times B \quad (1)$$

Adapun kerangkang kerja Preprocessing dapat dilihat pada gambar 2 berikut.



Gambar 2. Pre-Processing Data Citra

Proses pre-processing data citra ini dilakukan secara terstruktur melalui dua jalur paralel untuk data training dan testing. Pada kedua jalur tersebut, citra asli menjalani serangkaian transformasi yang identik. Tahapan awal meliputi standarisasi dimensi citra melalui resizing menjadi 300×300 piksel untuk memastikan keseragaman input. Selanjutnya, dilakukan augmentasi data melalui rotasi citra pada empat sudut berbeda (0°, 45°, 75°, dan 90°) untuk

meningkatkan variasi dataset dan robustnes model. Proses dilanjutkan dengan konversi ruang warna dari RGB ke grayscale (RGB2Gray) yang berfungsi untuk menyederhanakan kompleksitas komputasi sekaligus mempertahankan informasi tekstural yang esensial untuk analisis berikutnya.

Pipeline pre-processing yang sistematis ini menghasilkan dataset yang terstandarisasi dan teraugmentasi, yang siap untuk proses ekstraksi fitur dan klasifikasi dalam kerangka kerja machine learning. Pendekatan ini tidak hanya memastikan konsistensi input model tetapi juga berkontribusi dalam peningkatan generalisasi kemampuan klasifikasi.

### B. Ekstraksi Fitur GLCM

Fitur tekstur diekstraksi menggunakan GLCM dengan jarak ( $d$ ) = 1 piksel dan empat sudut ( $\theta$ ) =  $0^\circ$ ,  $45^\circ$ ,  $75^\circ$ ,  $90^\circ$ . Lima fitur statistik dihitung dari matriks ko-okurensi yang telah dinormalisasi [17], [22]:

- Angular Second Moment (ASM) untuk mengukur homogenitas citra
- Kontras untuk mengukur variasi intensitas lokal
- Inverse Different Moment (IDM untuk mengukur kedekatan local distribusi elemen GLCM terhadap diagonal
- Entropi untuk mengukur kekacauan tekstur
- Korelasi untuk mengukur ketergantungan linier derajat keabuan pada piksel tetangga

### C. Klasifikasi K-Nearest Neighbor

Algoritma KNN digunakan untuk mengklasifikasikan citra uji berdasarkan kemiripan fitur dengan data training berdasarkan sudut  $0^\circ$ ,  $45^\circ$ ,  $75^\circ$ , dan  $90^\circ$  pada 4 kelas yang telah ditentukan yaitu kelas Antaraknosa, Fusarium, Lalat Buah, dan Thrips. Langkah-langkahnya adalah [9], [12], [23]:

- 1) Menentukan nilai K (tetangga terdekat). Dalam penelitian ini, diuji nilai K=5, 7, dan 9.
- 2) Menghitung jarak Euclidean antara fitur citra uji dan semua fitur data training menggunakan Persamaan 2.

$$d(x, y) = \sqrt{\left[\sum(x_j - y_j)^2\right]} \quad (2)$$

Keterangan:

$d(x,y)$  = Jarak Euclidean antara titik x dan titik y

$x_j$  = Nilai koordinat titik x pada dimensi ke-j

$y_j$  = Nilai koordinat titik y pada dimensi ke-j

$\sum$  = Operasi penjumlahan untuk semua dimensi j

$\sqrt{\quad}$  = Akar kuadrat

- 3) Mengurutkan jarak dan memilih K tetangga terdekat
- 4) Menetapkan kelas citra uji berdasarkan kelas mayoritas dari K tetangga terdekat

Adapun untuk evaluasi kinerja model menggunakan *confusion Matrix*, untuk mendapatkan nilai akurasi kinerja model maka persamaan (3) digunakan [8], [16], [24], [25].

$$\text{Akurasi} = \frac{\sum_i^n \frac{TP_i + TN_i}{TP_i + FP_i + TN_i + FN_i}}{n} \quad (3)$$

Keterangan:

$TP_i$  (True Positive): Data kelas i yang benar diklasifikasikan sebagai kelas i

$TN_i$  (True Negative): Data bukan kelas i yang benar diklasifikasikan bukan kelas i

$FP_i$  (False Positive): Data bukan kelas i yang salah diklasifikasikan sebagai kelas i

$FN_i$  (False Negative): Data kelas i yang salah diklasifikasikan bukan kelas i

n: Jumlah total kelas

i: Indeks kelas (1, 2, 3, ..., n)

## III. HASIL DAN PEMBAHASAN

### A. Klasifikasi dan Evaluasi

Hasil pengujian menunjukkan variasi kinerja model pada empat sudut GLCM ( $\theta$ ) dan nilai K yang berbeda. Proses augmentasi dengan rotasi pada data training terbukti meningkatkan robustitas model terhadap variasi orientasi citra, sementara konversi grayscale dan standardisasi ukuran citra berperan penting dalam efisiensi komputasi dan konsistensi ekstraksi fitur tekstur.

### B. Analisis Pengaruh Sudut GLCM dan Nilai K

Berdasarkan pengujian terhadap 144 citra testing, diperoleh hasil bahwa sudut GLCM  $0^\circ$  dengan nilai K=5 menghasilkan akurasi tertinggi sebesar 88.19%. Hasil ini secara signifikan lebih tinggi dibandingkan dengan sudut lainnya ( $45^\circ$ : 84.72%,  $75^\circ$ : 83.33%,  $90^\circ$ : 84.03%). Keunggulan sudut  $0^\circ$  dapat dijelaskan melalui karakteristik biologis penyakit daun cabai yang cenderung menunjukkan pola tekstur horizontal akibat penyebaran spora dan perkembangan lesi searah pertumbuhan daun. Temuan ini sejalan dengan penelitian [7] yang menyebutkan bahwa sudut  $0^\circ$  pada GLCM paling efektif dalam menangkap pola tekstur mikroskopis pada permukaan daun.

### C. Hasil Klasifikasi Pada Variasi Sudut GLCM dan Nilai K

Dari hasil pengujian terhadap 144 citra testing menunjukkan bahwa kinerja model dipengaruhi oleh sudut GLCM dan nilai K yang digunakan. Tabel 1 merangkum akurasi tertinggi untuk setiap sudut yang digunakan.

Tabel 1. Akurasi Tertinggi untuk setiap sudut GLCM

Sudut GLCM	Akurasi	Nilai K
$0^\circ$	88.19%	5
$45^\circ$	84.72%	5
$75^\circ$	83.33	5
$90^\circ$	84.03%	5

Berdasarkan tabel 1, dapat disimpulkan bahwa Nilai K=5 secara konsisten menghasilkan performa terbaik pada semua sudut GLCM, sementara nilai K=7 dan K=9 menunjukkan penurunan akurasi. Fenomena ini mengindikasikan bahwa nilai K yang lebih kecil mampu menangkap pola lokal dengan lebih baik tanpa memasukkan noise dari tetangga yang terlalu jauh. Namun, perlu diwaspadai potensi overfitting pada nilai K yang terlalu kecil, khususnya jika dataset memiliki variasi intra-class yang tinggi.



Gambar 3. Grafik Akurasi Tertinggi Setiap Sudut GLCM

Pengaruh Sudut GLCM: Sudut 0° menghasilkan kinerja terbaik, diikuti oleh sudut 45°, 90°, dan 75°. Hal ini menunjukkan bahwa informasi tekstur horisontal (pada sudut 0°) paling discriminatif dalam membedakan keempat penyakit daun cabai. Hasil evaluasi kinerja klasifikasi menggunakan algoritma K-Nearest Neighbor (K=5) pada fitur *Gray Level Co-occurrence Matrix* (GLCM) sudut 0° disajikan dalam Tabel 2 dalam bentuk confusion matrix.

Tabel 2. Confusion Matriks Sudut 0° dan K=5

Pred True \	Antaraknosa	Fusarium	Lalat Buah	Thrips
Antaraknosa	47	2	0	7
Fusarium	1	25	0	2
Lalat Buah	2	0	28	0
Thrips	2	1	0	27

$$akurasi = 100 * \frac{(47 + 25 + 28 + 27)}{144} = 88,19444$$

Berdasarkan Tabel 2, model menunjukkan kinerja terbaik dalam mengklasifikasikan Lalat Buah (100% akurasi) dan Antraknosa (83.93%), sementara Fusarium dan Thrips mengalami sedikit misklasifikasi. Kesalahan klasifikasi antara Antraknosa dan Thrips dapat disebabkan oleh kemiripan visual berupa bercak-bercak kecil pada permukaan daun.

#### D. Perbandingan dengan Penelitian Sebelumnya

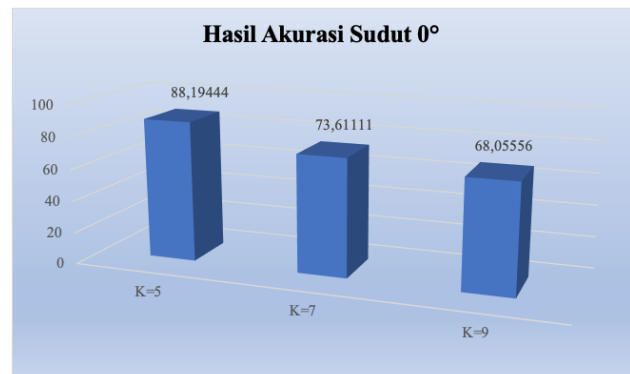
Hasil penelitian ini (rata-rata akurasi 85.06%) menunjukkan peningkatan yang signifikan dibandingkan penelitian sebelumnya pada daun jeruk (70%) [10] dan daun kentang (80%) [11]. Keunggulan ini membuktikan efektivitas kombinasi GLCM dan K-NN untuk klasifikasi penyakit tanaman, khususnya pada daun cabai. Penelitian [8] dan [9] juga mengonfirmasi kehandalan fitur GLCM dalam mengkuantifikasi karakteristik tekstural lesi penyakit tanaman, dengan kemampuan membedakan pola sporulasi dan nekrosis yang menjadi pembeda utama antar penyakit.

#### E. Keterbatasan dan Potensi Pengembangan

Meskipun menunjukkan hasil yang memuaskan, pendekatan K-NN memiliki keterbatasan dalam skalabilitas untuk dataset yang lebih besar akibat kompleksitas komputasi yang meningkat secara linear. Selain itu, metode ini rentan terhadap ketidakseimbangan dataset dan noise. Untuk penelitian lanjutan, disarankan eksplorasi metode ensemble learning atau deep learning untuk meningkatkan generalisasi model, serta incorporasi fitur tambahan seperti bentuk dan

warna untuk menangkap karakteristik penyakit yang lebih komprehensif.

Gambar 4 hingga 7 memvisualisasikan hasil evaluasi kinerja algoritma K-NN dengan variasi nilai K=5, 7, dan 9 pada ekstraksi fitur GLCM dengan sudut 0°, 45°, 75°, dan 90°.



Gambar 4. Akurasi Sudut 0° Pada Nilai K=5, 7, 9



Gambar 5. Akurasi Sudut 45° Pada Nilai K=5, 7, 9



Gambar 6. Akurasi Sudut 75° Pada Nilai K=5, 7, 9



Gambar 7. Akurasi Sudut 90° Pada Nilai K=5, 7, 9

Rata-rata akurasi tertinggi yang dicapai pada semua sudut dengan  $K=5$  adalah 85.06%. Hasil ini lebih tinggi dibandingkan penelitian serupa yang menggunakan KNN untuk identifikasi penyakit daun jeruk (70%) [10] dan daun kentang (80%) [11], serta sebanding dengan penelitian pada kopi Arabika (80%) [6]. Keberhasilan ini membuktikan efektivitas fitur GLCM dalam merepresentasikan pola tekstur penyakit dan kemampuan KNN dalam melakukan klasifikasi.

#### IV. KESIMPULAN

Berdasarkan penelitian yang dilakukan, dapat disimpulkan bahwa implementasi ekstraksi fitur Gray Level Co-occurrence Matrix (GLCM) dan klasifikasi K-Nearest Neighbor (K-NN) berhasil mengklasifikasikan penyakit tanaman cabai dengan akurasi tinggi. Hasil evaluasi menunjukkan bahwa kombinasi parameter sudut GLCM  $0^\circ$  dan nilai  $K=5$  menghasilkan akurasi tertinggi sebesar 88,19%, dengan rata-rata akurasi keseluruhan 85,06% dalam mengidentifikasi empat jenis penyakit (Antraknosa, Layu Fusarium, Lalat Buah, dan Thrips). Studi ini membuktikan efektivitas kombinasi GLCM dan K-NN dalam klasifikasi multi-kelas penyakit daun cabai berdasarkan pola tekstur. Tahapan proses yang terdiri dari akuisisi citra, pra-pemrosesan (konversi RGB ke grayscale, resize, dan augmentasi rotasi), ekstraksi fitur tekstur, hingga klasifikasi dengan perhitungan jarak Euclidean terbukti menghasilkan kinerja yang konsisten. Untuk penelitian lanjutan, disarankan pengembangan sistem deteksi otomatis berbasis mobile yang dapat diimplementasikan langsung di tingkat petani guna mendukung praktik pertanian presisi.

#### REFERENSI

- [1] M. Anwar, Y. Kristian, and E. Setyati, "Klasifikasi Penyakit Tanaman Cabai Rawit Dilengkapi Dengan Segmentasi Citra Daun dan Buah Menggunakan Yolo v7," *INTECOMS*, vol. 6, no. 1, pp. 540–548, June 2023, doi: 10.31539/intecom.v6i1.6071.
- [2] W. G. Akbari, N. Hidayat, and N. Santoso, "Diagnosis Penyakit Cabai Menggunakan Metode Fuzzy K-Nearest Neighbor (FKNN)".
- [3] H. D. A. Hamid, N. Hidayat, and R. K. Dewi, "Diagnosis Penyakit Tanaman Cabai Menggunakan Metode Modified K-Nearest Neighbor (MKNN)".
- [4] D. Avianto and I. E. Handayani, "Klasifikasi Penyakit Antraknosa Pada Cabai Merah Teropong "Inko Hot" Dengan Metode Convolutional Neural Network," *SINTECH Journal*, vol. 6, no. 2, pp. 76–88, Aug. 2023, doi: 10.31598/sintechjournal.v6i2.1377.
- [5] N. Hafidhoh, "Identifikasi Penyakit Daun Tanaman Cabai Merah Dengan Ekstraksi Fitur Dan Klasifikasi Support Vector Machine," vol. 5, 2023.
- [6] V. G. Dhanya *et al.*, "Deep learning based computer vision approaches for smart agricultural applications," *Artificial Intelligence in Agriculture*, vol. 6, pp. 211–229, 2022, doi: 10.1016/j.aiaa.2022.09.007.
- [7] Z. Y. Lamasigi and A. Bode, "Influence of gray level co-occurrence matrix for texture feature extraction on identification of batik motifs using k-nearest neighbor," *Ilk. J. Ilm.*, vol. 13, no. 3, pp. 322–333, Dec. 2021, doi: 10.33096/ilkom.v13i3.1025.322-333.
- [8] Z. Y. Lamasigi, S. Serwin, and Y. Malago, "Identification of the Freshness Level of Tuna based on Discrete Cosine Transform on Feature Extraction of Gray Level Co-Occurrence Matrix using K-Nearest Neighbor," *Ilk. J. Ilm.*, vol. 15, no. 1, pp. 153–164, Apr. 2023, doi: 10.33096/ilkom.v15i1.1426.153-164.
- [9] Z. Y. Lamasigi, "DCT Untuk Ekstraksi Fitur Berbasis GLCM Pada Identifikasi Batik Menggunakan K-NN," *JJEEE*, vol. 3, no. 1, pp. 1–6, Jan. 2021, doi: 10.37905/jjee.v3i1.7113.
- [10] Y. Adhitya, S. W. Prakosa, M. Köppen, and J.-S. Leu, "Feature Extraction for Cocoa Bean Digital Image Classification Prediction for Smart Farming Application," *Agronomy*, vol. 10, no. 11, p. 1642, Oct. 2020, doi: 10.3390/agronomy10111642.
- [11] - Istiadi *et al.*, "Classification of Tempeh Maturity Using Decision Tree and Three Texture Features," *JOIV : Int. J. Inform. Visualization*, vol. 6, no. 4, p. 883, Dec. 2022, doi: 10.30630/joiv.6.4.983.
- [12] M. Kurniawan, G. E. Yuliasuti, A. Rachman, A. P. Budi, and H. N. Zaqiyah, "Implementing K-Nearest Neighbors (k-NN) Algorithm and Backward Elimination on Cardiotocography Datasets," *JOIV : Int. J. Inform. Visualization*, vol. 8, no. 3, p. 1239, Sept. 2024, doi: 10.62527/joiv.8.3.1996.
- [13] A. Bode, Z. Y. Lamasigi, and I. C. R. Drajana, "The K-Nearest Neighbor Algorithm using Forward Selection and Backward Elimination in Predicting the Student's Satisfaction Level of University Ichsan Gorontalo toward Online Lectures during the COVID-19 Pandemic," *Ilk. J. Ilm.*, vol. 15, no. 1, pp. 118–123, Apr. 2023, doi: 10.33096/ilkom.v15i1.1381.118-123.
- [14] S. Matarru, G. A. N. Pongdatu, and J. Rusman, "Klasifikasi Penyakit pada Tanaman Kopi Arabika Menggunakan Metode K-Nearest Neighbor (KNN) Berbasis Citra," *ijcs*, vol. 12, no. 2, Apr. 2023, doi: 10.33022/ijcs.v12i2.3172.
- [15] Z. Y. Lamasigi, M. Hasan, and Y. Lasena, "Local Binary Pattern untuk Pengenalan Jenis Daun Tanaman Obat menggunakan K-Nearest Neighbor," *Ilk. J. Ilm.*, vol. 12, no. 3, pp. 208–218, Dec. 2020, doi: 10.33096/ilkom.v12i3.667.208-218.
- [16] A. E. Minarno, I. Soesanti, and H. A. Nugroho, "Batik Classification using Microstructure Co-occurrence Histogram," *JOIV : Int. J. Inform. Visualization*, vol. 8, no. 1, p. 134, Mar. 2024, doi: 10.62527/joiv.8.1.2152.
- [17] J. Pardede and R. Dwianto, "The Effect of Feature Selection on Machine Learning Classification".
- [18] T. O. Qadir, N. S. A. Taujuddin, and N. Fuad, "A New Feature Extraction Approach in Classification for Improving the Accuracy in Iris Recognition".
- [19] Z. Y. Lamasigi and A. Bode, "Influence of gray level co-occurrence matrix for texture feature extraction on identification of batik motifs using k-nearest neighbor," *Ilk. J. Ilm.*, vol. 13, no. 3, pp. 322–333, Dec. 2021, doi: 10.33096/ilkom.v13i3.1025.322-333.
- [20] K. Meethongjan, V. T. Hoang, and T. Surinwarangkoon, "Data augmentation by combining feature selection and color features for image classification," *IJECE*, vol. 12, no. 6, p. 6172, Dec. 2022, doi: 10.11591/ijece.v12i6.pp6172-6177.
- [21] D. P. Prabowo *et al.*, "Adaptive Inertia Weight Particle Swarm Optimization for Augmentation Selection in Coral Reef Classification with Convolutional Neural

- Networks,” *JOIV: Int. J. Inform. Visualization*, vol. 9, no. 1, p. 216, Jan. 2025, doi: 10.62527/joiv.9.1.2726.
- [22] N. R. Romadhon, R. Sigit, and B. S. B. Dewantara, “Classification of Intraoral Images in Dental Diagnosis Based on GLCM Feature Extraction Using Support Vector Machine”.
- [23] B. Satria, N. Afrianto, L. Ningsih, P. Sakinah, A. Sidauruk, and L. Mayola, “Comparative Analysis of Weighted-KNN, Random Forest, and Support Vector Machine Models for Beef and Pork Image Classification Using Machine Learning”.
- [24] Y. Azhar and D. R. Akbi, “Performance Comparison of GLCM Features and Preprocessing Effect on Batik Image Retrieval,” *JOIV: Int. J. Inform. Visualization*, vol. 8, no. 3, p. 1339, Sept. 2024, doi: 10.62527/joiv.8.3.2179.
- [25] L. L. González, I. Arias-Serrano, F. Villalba-Meneses, P. Navas-Boada, and J. Cruz-Varela, “Deep learning neural network development for the classification of bacteriocin sequences produced by lactic acid bacteria,” *F1000Res*, vol. 13, p. 981, Aug. 2024, doi: 10.12688/f1000research.154432.1.