

DETEKSI DINI PENYAKIT DAUN PADI MENGGUNAKAN INTEGRASI GLCM DAN KNN

Nila Farihah^{1*}, Restu Lestari Mulianingrum², Margareta Valencia Suci Handayani³, Safara Risda Agastya⁴, Fadillah Zalsa Dira⁵, Mutiara Zhavira⁶, Muhammad Naufal⁷, Ricardus Anggi Pramunendar⁸

^{1,2,3,4,5,6} Research Center for Intelligent Distributed Surveillance and Security, Universitas Dian Nuswantoro, Semarang; Jalan Imam Bonjol No. 207, Kec. Semarang Tengah, Kota Semarang, Jawa Tengah, 50131; (024) 3517261

Keywords:
daun padi;
KNN;
GLCM;
deteksi penyakit.

Correspondent Email:
ricardus.anggi@dsn.dinus.ac.id

Abstrak. Produktivitas panen padi di Indonesia masih terganggu oleh penyakit daun yang sulit dikenali secara visual. Penelitian ini bertujuan untuk mengembangkan sistem deteksi dini berbasis citra digital menggunakan ekstraksi fitur *Gray Level Co-occurrence Matrix* (GLCM) dan klasifikasi *K-Nearest Neighbor* (KNN). Dataset terdiri dari 4684 citra tiga kelas penyakit daun padi. Proses mencakup konversi RGB ke HSV, segmentasi, ekstraksi enam fitur tekstur, dan klasifikasi. Hasil terbaik diperoleh pada k senilai 5 dengan akurasi, presisi, *recall*, dan *F1-score* sebesar 94,2%. Metode ini efektif membedakan daun sehat dan terinfeksi, serta dapat meningkatkan kualitas hasil panen padi sehingga dapat mendukung program pemerintah melalui Makan Bergizi Gratis (MBG). Penelitian ini juga membuka peluang pengembangan sistem berbasis *mobile* dengan integrasi kecerdasan buatan untuk kemudahan penggunaan di lapangan.

Abstract. Rice crop productivity in Indonesia remains hindered by leaf diseases that are difficult to detect visually. This study develops an early detection system using *Gray Level Co-occurrence Matrix* (GLCM) feature extraction and *K-Nearest Neighbor* (KNN) classification. The dataset consists of 4,684 images across three rice leaf disease classes. The process includes RGB to HSV conversion, segmentation, extraction of six texture features, and classification. The best performance was achieved with $k = 5$, yielding 94.2% accuracy, precision, recall, and *F1-score*. This method effectively distinguishes between healthy and infected leaves and can enhance rice yield quality to support government programs such as Free Nutritious Meals (MBG). The study also opens opportunities for mobile-based system development with AI integration for practical field use.

1. PENDAHULUAN

Salah satu negara produksi beras terbesar di dunia adalah Indonesia, dengan kontribusi sekitar 40% dari total produksi [1]. Namun, ironisnya, Indonesia masih menjadi negara pengimpor beras sejak tahun 1980 hingga sekarang [2]. Salah satu penyebab utama menurunnya produktivitas padi adalah penyakit daun, seperti *Bacterialblight*, *Brownspot*, dan *Leafsmut*, yang dapat menyebabkan kerugian hasil panen hingga 37% setiap tahun [3]. Salah

satu yang memengaruhi rendahnya hasil panen adalah serangan penyakit pada daun padi, yang mengganggu proses fotosintesis dan menurunkan produktivitas. Masalahnya, gejala penyakit daun padi seringkali sulit dikenali secara kasat mata, terutama jika gejala sudah memasuki tahap lanjut [1]. Deteksi manual oleh petani cenderung lambat dan kurang akurat, sehingga dibutuhkan sistem deteksi otomatis berbasis teknologi untuk mengidentifikasi penyakit secara dini dan tepat [4]. Selain itu,

program Makan Bergizi Gratis (MBG) yang diinisiasi pemerintah memerlukan ketersediaan beras berkualitas untuk mendukung pemenuhan gizi anak-anak serta motivasi belajar siswa di berbagai wilayah [5].

Penggunaan *Gray Level Co-occurrence Matrix* (GLCM) terbukti efektif dalam membedakan jenis penyakit secara visual berdasarkan tekstur gambar terutama untuk mendukung akurasi klasifikasi dalam kondisi pencahayaan dan latar yang bervariasi [4], [6]. GLCM digunakan karena kemampuannya dalam mengekstraksi tekstur dari citra dengan cara menghitung seberapa sering pasangan unit gambar dengan nilai intensitas tertentu muncul pada arah dan jarak tertentu [7], [8]. Informasi tekstur ini penting karena gejala penyakit pada daun padi biasanya terlihat dalam bentuk bercak atau pola warna yang tidak merata.

Penelitian sebelumnya membuktikan akan keandalan algoritma *K-Nearest Neighbor* (KNN) dalam melakukan klasifikasi citra berbasis tekstur [6], [9]. Dengan melakukan perhitungan *Euclidean Distance* untuk menentukan nilai K menghasilkan akurasi mencapai 75,00% dengan $K = 3$ [7]. Oleh karena itu, KNN dipilih karena efektif dalam klasifikasi berbasis citra, sehingga dapat membantu permasalahan negara yang sedang terjadi dengan menghasilkan padi dengan kualitas yang mumpuni.

2. TINJAUAN PUSTAKA

2.1. Padi

Salah satu tanaman utama yang menjadi sumber makanan pokok bagi penduduk Indonesia adalah padi [1], [2]. Namun, terdapat tantangan seperti serangan penyakit yang dapat menurunkan kualitas padi. Oleh karena itu, dilakukan deteksi dini sebagai bentuk preventif dalam mengatasi serangan penyakit.


2.2. *Gray Level Co-occurrence Matrix* (GLCM)

Fitur ekstraksi yang digunakan, yaitu GLCM, berfungsi untuk menghitung frekuensi kemunculan pasangan nilai piksel pada jarak dan arah tertentu dalam suatu citra [4], [6]. Fitur ini terbukti efektif dalam mengekstraksi ciri ataupun menganalisis tekstur, terutama ketika digunakan dengan ruang warna HSV [7], [10].

2.3. *K-Nearest Neighbor*

KNN adalah algoritma klasifikasi berbasis jarak dengan membandingkan fitur dari data uji terhadap data latih terdekat [6], [11], [12]. Algoritma ini bersifat non-parametrik dan cocok digunakan untuk data visual seperti citra daun karena kemampuannya mengenali pola sederhana secara efektif.

3. METODE PENELITIAN



Gambar 1. Alur Penelitian

Pendekatan yang diterapkan menggunakan GLCM sebagai fitur ekstraksi dan algoritma KNN untuk klasifikasi. Alur proses penelitian digambarkan melalui diagram alir dan dijelaskan dalam beberapa tahapan utama seperti dalam Gambar 1.

3.1. Dataset



Gambar 2. Dataset daun padi

Penelitian ini menggunakan dataset dari situs *Kaggle*, yang tersedia melalui tautan <https://www.kaggle.com/datasets/jay7080dev/rice-plant-diseases-dataset>. Dataset terdiri dari tiga kelas yaitu, *Bacterialblight*, *Brownspot*, dan *Leafsmut*. Secara keseluruhan dalam dataset tersebut terdapat 4684 citra daun padi yang dapat dilihat pada Gambar 2. Dataset ini digunakan untuk melatih dan menguji model klasifikasi berbasis GLCM dan KNN.

3.2. *Preprocessing*

Pada tahap ini, citra daun diubah yang semula berformat warna RGB menjadi ruang

warna HSV yaitu corak (Hue/H), (Saturation/S), dan nilai (Value/V) [7]. Proses ini dilakukan untuk mengurangi atau meratakan noise latar belakang dan meningkatkan akurasi segmentasi [13], sehingga bercak penyakit dapat dibedakan lebih akurat dari daun yang sehat.

3.3. Segmentasi

Dalam penelitian ini, segmentasi dilakukan menggunakan metode *thresholding* berbasis warna HSV melalui penetapan ambang batas spesifik pada saluran Hue, Saturation, dan Value. Proses ini menghasilkan integrasi ketiga komponen warna menjadi citra biner. Penerapan operasi morfologi juga dilakukan untuk memperhalus batas wilayah terdeteksi [14], [15] sehingga dapat diidentifikasi bagian-bagian spesifik dari tanaman, seperti daun yang sehat atau yang terinfeksi [16].

3.4. Ekstraksi Fitur

Teknik pengambilan fitur yang diterapkan adalah GLCM. Penelitian terdahulu menunjukkan fitur GLCM dapat meningkatkan akurasi klasifikasi penyakit tanaman, serta konsisten dalam mendeteksi penyakit daun padi [4], [9], [17]. Pendekatan proses GLCM bekerja dengan membentuk matriks ko-okurensi dari data citra *grayscale* [8], [17]. Dalam penelitian ini, sudut yang diterapkan adalah 0, 45, 90, dan 135 derajat, dengan jarak piksel ($d = 1$). Parameter dalam penelitian ini pada rumus (1)-(6).

$$Contrast = \sum_{i=0}^{255} \sum_{j=0}^{255} p_{i,j} (i-j)^2 \quad (1)$$

$$Dissimilarity = \sum_{i=0}^{255} \sum_{j=0}^{255} p_{i,j} |i-j| \quad (2)$$

$$Homogeneity = \sum_{i=0}^{255} \sum_{j=0}^{255} \frac{p(i,j)}{1+(i-j)^2} \quad (3)$$

$$ASM = \sum_{i=0}^{255} \sum_{j=0}^{255} [p(i-j)]^2 \quad (4)$$

$$Energy = \sqrt{\sum_{i=0}^{255} \sum_{j=0}^{255} p(i,j)^2} \quad (5)$$

$$Correlation = \sum_{i=0}^{255} \sum_{j=0}^{255} p(i,j) \frac{(i-\mu)(j-\mu)}{\sigma^2} \quad (6)$$

Keterangan

p : probabilitas/peluang (0-1) elemen matriks

(i, j) : pada baris ke- i serta kolom ke- j

μ : rata-rata nilai intensitas

σ : varians dari nilai intensitas

Semua citra dihitung menggunakan setiap fitur pada tiap sudut yang digunakan dan hasilnya disimpan dalam bentuk table data. Metode GLCM dipilih karena terbukti efektif dalam menggambarkan pola tekstur pada permukaan daun yang terdampak penyakit [6], [17], serta didukung pada penelitian lainnya efektif terhadap tanaman padi berbasis citra [4].

3.5. Klasifikasi

Pada tahap klasifikasi, penelitian ini menerapkan algoritma KNN. Metode tersebut digunakan untuk mengelompokkan objek baru dengan merujuk pada data pelatihan yang memiliki jarak paling dekat dengan objek tersebut [11], [12]. Konsep utama dari algoritma ini yakni objek dengan kemiripan pada nilai parameter yang relevan cenderung berdekatan satu sama lain. Jarak *Euclidean* sering digunakan untuk mengukur kedekatan antara dua objek dalam ruang fitur [18]. Jarak *Euclidean* antara dua titik, yaitu x_1 dan x_2 , dihitung dengan mengukur perbedaan antara dua titik berdasarkan perbedaan nilai pada tiap dimensi, seperti rumus (7).

$$d_{Euclidean} = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \quad (7)$$

Keterangan

n : dimensi data

x_{1i} : vektor 1 (data uji)

x_{2i} : vektor 2 (sampel data)

Tahap akhir dari proses klasifikasi, dilakukan evaluasi terhadap kinerja model menggunakan *confusion matrix*. Matriks tersebut menyajikan hasil klasifikasi berdasarkan empat kategori utama yakni prediksi benar dan salah untuk masing-masing kelas positif dan negatif. Evaluasi ini memungkinkan untuk menghitung matrik kinerja model seperti pada rumus (8)-(11).

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (8)$$

$$Presisi = \frac{TP}{TP+FP} \quad (9)$$

$$Recall = \frac{TP}{TP+FN} \quad (10)$$

$$F_{1-Score} = 2 \cdot \frac{Presisi \cdot Recall}{Presisi + Recall} \quad (11)$$

Keterangan

TP : True Positive FP : False Positive





TN : True Negative FN : False Negative

4. HASIL DAN PEMBAHASAN


4.1. Preprocessing

Sesuai tahapan pada metode penelitian diatas, preprocessing dilakukan dengan konversi citra RGB ke HSV. Hasil konversi menunjukkan bahwa komponen hue mampu menonjolkan perbedaan warna pada daun, yang berguna untuk membedakan bagian yang sehat dan terinfeksi. Hasil dari konversi citra dapat ditemukan pada Tabel 1.

Tabel 1. Tabel hasil konversi ke HSV

	Gambar asli	Gambar HSV
<i>Bacterialblight</i>		
<i>Leafsmut</i>		
<i>Brownspot</i>		

4.2. Segmentasi



Gambar 3. Hasil segmentasi dengan thresholding

Segmentasi dilakukan dengan memanfaatkan warna bercak pada citra daun yang telah dikonversi ke dalam ruang warna

HSV. Proses segmentasi dilakukan melalui kode Python dengan bantuan pustaka OpenCV. Bercak daun padi umumnya memiliki rentang warna tertentu pada spektrum HSV, sehingga proses segmentasi dilakukan melalui penetapan nilai ambang batas (*threshold*) pada rentang tertentu yang ditunjukkan pada Gambar 3.

4.3. Ekstraksi Fitur

Ekstraksi fitur dilakukan melalui pendekatan GLCM pada sudut yaitu 0, 45, 90, dan 135 derajat, yang diterapkan pada citra daun padi hasil segmentasi. Setiap citra dianalisis dengan parameter *distances* = (1) dan *angles* = (0), di mana 0 mewakili sudut orientasi GLCM. Dari parameter tersebut menghasilkan enam fitur tekstur yaitu, *contrast*, *dissimilarity*, *homogeneity*, *ASM (Angular Second Moment)*, *energy*, dan *correlation*. Hasil ekstraksi fitur tersaji pada Gambar 4-7.

Hasil Ekstraksi Fitur Angle_0:

	Contrast	Dissimilarity	Homogeneity	ASM	Energy	Correlation	Class
0	185.513467	2.948294	0.768974	0.420565	0.64851	0.957435	Bacterialblight
1	199.964928	3.204749	0.708112	0.331218	0.575516	0.977035	Bacterialblight
2	332.553378	3.881137	0.736947	0.371563	0.609559	0.958452	Bacterialblight
3	190.909064	3.774169	0.695576	0.336284	0.5799	0.977447	Bacterialblight
4	660.174337	4.904638	0.838885	0.579307	0.761122	0.904008	Bacterialblight
0	...	...	...	...	...	...	...
4500	10.856366	0.117101	0.992142	0.973608	0.986716	0.928427	Brownspot

Gambar 4. Ekstraksi fitur sudut 0 derajat

Hasil Ekstraksi Fitur Angle_45:

	Contrast	Dissimilarity	Homogeneity	ASM	Energy	Correlation	Class
0	383.983289	5.250702	0.742261	0.410823	0.640955	0.912118	Bacterialblight
1	389.289225	5.698974	0.663247	0.327318	0.572117	0.955293	Bacterialblight
2	637.944408	6.864286	0.707651	0.361831	0.601524	0.920411	Bacterialblight
3	385.510263	6.413318	0.656757	0.331691	0.575926	0.954486	Bacterialblight
4	832.262391	5.897361	0.833755	0.574408	0.757897	0.879043	Bacterialblight
0	...	...	...	...	...	...	...
4500	11.935683	0.127381	0.991606	0.972551	0.98618	0.921572	Brownspot

Gambar 5. Ekstraksi fitur sudut 45 derajat

Hasil Ekstraksi Fitur Angle_90:

	Contrast	Dissimilarity	Homogeneity	ASM	Energy	Correlation	Class
0	255.440936	3.927781	0.754412	0.416582	0.645432	0.941505	Bacterialblight
1	192.762285	3.501104	0.687067	0.332306	0.57646	0.977825	Bacterialblight
2	376.323434	4.768428	0.722289	0.367903	0.60655	0.95302	Bacterialblight
3	185.426232	3.917938	0.679149	0.336024	0.579676	0.978083	Bacterialblight
4	219.361962	1.961338	0.863365	0.591611	0.769162	0.968057	Bacterialblight
0	...	...	...	...	...	...	...
4500	12.44107	0.132241	0.991923	0.973322	0.986571	0.917979	Brownspot

Gambar 6. Ekstraksi fitur sudut 90 derajat

Hasil Ekstraksi Fitur Angle_135:

	Contrast	Dissimilarity	Homogeneity	ASM	Energy	Correlation	Class
0	315.792094	4.462556	0.751431	0.412797	0.642492	0.927725	Bacterialblight
1	226.741815	3.631693	0.690329	0.329297	0.573844	0.97396	Bacterialblight
2	479.653158	5.419984	0.719686	0.364686	0.603893	0.940159	Bacterialblight
3	183.443675	3.651548	0.686812	0.333246	0.577275	0.978343	Bacterialblight
4	712.81196	5.186318	0.835975	0.575143	0.758382	0.896403	Bacterialblight
0	...	...	...	...	...	...	...
4500	21.521325	0.213577	0.990869	0.972374	0.98609	0.858586	Brownspot

Gambar 7. Ekstraksi fitur sudut 135 derajat

Pada Gambar 4 yang menunjukkan hasil ekstraksi fitur pada sudut 0° , terlihat bahwa fitur seperti *contrast* dan *dissimilarity* memiliki nilai yang lebih tinggi pada kelas daun yang terinfeksi berat, menandakan adanya perubahan intensitas tajam antar piksel. Gambar 5, menampilkan pola fitur yang relatif mirip namun dengan intensitas nilai berbeda. Hal ini menunjukkan bahwa orientasi sudut berpengaruh terhadap sensitivitas GLCM dalam menangkap pola tekstur, di mana beberapa fitur (terutama *correlation*) tampak lebih stabil dan tinggi pada daun yang masih sehat.

Gambar 6 dan 7 memperlihatkan bahwa orientasi tekstur memang memengaruhi perhitungan fitur. Terlihat bahwa *energy* dan ASM mengalami fluktuasi antar kelas penyakit, yang mengindikasikan bahwa semakin tidak seragam tekstur daun, semakin rendah nilai kekompakan piksel yang ditunjukkan. Oleh karenanya, nilai *energy* dan ASM cenderung rendah pada daun padi yang mengalami kerusakan jaringan akibat penyakit. Eksperimen ini menegaskan bahwa metode GLCM memiliki efisiensi dan efektivitas tinggi sebagai dasar dalam mengidentifikasi penyakit daun padi secara otomatis.

4.4. Klasifikasi


Dalam penelitian ini, dilakukan eksperimen untuk menentukan nilai k optimal pada algoritma KNN yang dapat memberikan akurasi tertinggi. Pengujian dilakukan dengan berbagai nilai k dari 1 hingga 10 untuk mengevaluasi pengaruhnya terhadap kinerja klasifikasi. Tabel berikut menunjukkan hasil matrik evaluasi untuk setiap nilai k yang diuji

Tabel 2. Performa Klasifikasi KNN dengan berbagai Nilai K

k	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
1	97.4	97.4	97.4	97.4
2	95.8	95.9	95.8	95.8
3	95.9	95.9	95.9	95.9
4	94.2	94.3	94.2	94.2
5	94.2	94.2	94.2	94.2
6	92.3	92.4	92.3	92.3
7	92.0	90.5	92.0	92.0
8	90.4	90.6	90.4	90.4
9	90.6	89.6	90.6	90.6


10	89.3	89.6	89.3	89.3
----	------	------	------	------

Berdasarkan Tabel 2, nilai k sebesar 5 dipilih sebagai parameter optimal dengan akurasi 94.2%, presisi 94.2%, *recall* 94.2%, dan *F1-Score* 94.2%. Meskipun $k = 1$ memberikan performa tertinggi 97.4% untuk semua metrik, $k = 5$ dipilih karena memiliki stabilitas performa yang lebih baik, menghindari *overfitting* pada k kecil seperti 1 dan *underfitting* pada k besar seperti 9 atau 10. Hubungan antara nilai k dan matrik evaluasi divisualisasikan pada Gambar 8.



Gambar 8. Hubungan nilai k dengan metrik evaluasi

Visualisasi pada Gambar 8 memperjelas hubungan k dengan metrik evaluasi yang menunjukkan tren penurunan performa seiring peningkatan nilai k . Pemilihan $k = 5$ sebagai parameter optimal merepresentasikan keseimbangan terbaik antara bias dan variansi model, menghindari *overfitting* atau *underfitting*.



Gambar 9. *Confusion Matrix*

Confusion Matrix pada Gambar 9 menunjukkan hasil klasifikasi untuk tiga kelas penyakit daun padi dengan k sebesar 5. Matriks ini menggambarkan jumlah *True Positives* (TP), *True Negatives* (TN), *False Positives* (FP), dan *False Negatives* (FN). Model menunjukkan akurasi tinggi, dengan sebagian besar citra diklasifikasikan dengan benar. Kelas *Bacterialblight* memiliki TP yang tinggi, menunjukkan kemampuan model mengenali pola penyakit ini. Namun, terdapat beberapa kesalahan klasifikasi pada *Leafsmut*, kemungkinan karena kemiripan tekstur dengan kelas lain.

Tabel 3. Metrik Evaluasi Klasifikasi untuk Setiap Kelas

	Presisi (%)	Recall (%)	F1-Score (%)
Bacterialblight	94	96	95
Brownspot	94	94	94
Leafsmut	94	93	93

Tabel 3 menunjukkan performa per kelas dengan k sebesar 5. Kelas *Bacterialblight* memiliki recall tertinggi (96%), menunjukkan kemampuan model mendeteksi sebagian besar kasus penyakit ini. Kelas *Leafsmut* memiliki recall sedikit lebih rendah (93%), konsisten dengan sedikit kesalahan klasifikasi pada *Confusion Matrix*.

5. KESIMPULAN

Temuan dari penelitian ini mengindikasikan bahwa :

- Fitur GLCM dan algoritma KNN terbukti efektif untuk deteksi dini penyakit daun padi. Berdasarkan *testing* yang dilakukan, dimana saat k bernilai 5 mendapatkan hasil optimal berupa akurasi, presisi, *recall*, dan *F1-score* sebesar 94,2%.
- Proses *preprocessing* melalui konversi warna RGB ke HSV dan segmentasi berbasis *thresholding* terbukti meningkatkan akurasi deteksi area yang terinfeksi pada daun padi.

- Tantangan produktivitas panen yang kurang optimal dapat diatasi dengan program deteksi dini secara otomatis, serta dapat mendukung program pemerintah seperti Makan Bergizi Gratis (MBG) dengan menyediakan beras berkualitas tinggi tanpa perlu impor.
- Kedepannya, penelitian ini dapat dikembangkan menjadi berbasis mobile dengan menggunakan metode yang lebih kompleks untuk meningkatkan akurasi dan kemudahan penggunaan di lapangan.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada semua pihak yang telah memberikan bantuan dan dukungan selama proses eksperimen hingga penyusunan laporan penelitian ini.

DAFTAR PUSTAKA

- [1] A. K. Wijayanto, L. B. Prasetyo, and et al, "Textural features for BLB disease damage assessment in paddy fields using drone data and machine learning: Enhancing disease detection accuracy," *Smart Agricultural Technology*, vol. 8, Aug. 2024, doi: 10.1016/j.atech.2024.100498.
- [2] A. Q. Pudjiastuti, G. M. K. Arisena, and et al, "Rice Import Development in Indonesia," *SOCA: Jurnal Sosial, Ekonomi Pertanian*, vol. 15, no. 2, p. 390, Jun. 2021, doi: 10.24843/soca.2021.v15.i02.p14.
- [3] P. Sudharshan Duth and P. Rithik Lal, "Paddy Leaf Disease Classification Using Machine Learning and Deep Learning Techniques," in *2022 International Conference on Futuristic Technologies, INCOFT 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/INCOFT55651.2022.10094429.
- [4] P. Kulkarni, S. Shastri, and A. Professor, "Rice Leaf Diseases Detection Using Machine Learning," pp. 17–22, [Online]. Available: www.jsrtjournal.com
- [5] A. Atikah Merlinda and Yusuf Yusmar, "Analisis Program Makan Gratis Prabowo Subianto Terhadap Strategi Peningkatan Motivasi Belajar Siswa di Sekolah Tinjauan dari Perspektif Sosiologi Pendidikan," *Journal of Multidisciplinary Research and Development*, vol. 7, 2025, doi: <https://doi.org/10.38035/rj.v7i2>.

- [6] D. W. Rustanto, F. Liantoni, and N. P. T. Prakisy, "Identifikasi Penyakit Daun pada Tanaman Padi Menggunakan Ekstraksi Fitur Gray Level Co-occurrence Matrix (GLCM) dan Metode K-Nearest Neighbour (KNN)," *Jurnal Sistem dan Teknologi Informasi (JustIN)*, vol. 12, no. 1, p. 100, Jan. 2024, doi: 10.26418/justin.v12i1.69752.
- [7] Siti Saniah and Mhd. Furqan, "Classification Of Rice Plant Diseases Using K-Nearest Neighbor Algorithm Based On Hue Saturation Value Color Extraction And Gray Level Co-Occurrence Matrix Features," *Jurnal Teknologi dan Open Source*, vol. 7, no. 2, pp. 212–223, Dec. 2024, doi: 10.36378/jtos.v7i2.3972.
- [8] C. Nyasulu *et al.*, "A comparative study of Machine Learning-based classification of Tomato fungal diseases: Application of GLCM texture features," *Heliyon*, vol. 9, no. 11, Nov. 2023, doi: 10.1016/j.heliyon.2023.e21697.
- [9] E. D. S. Mulyani, H. J. Pramana, and *et al*, "Classification of Rice Leaf Diseases Based on Texture and Leaf Colour," in *2022 4th International Conference on Cybernetics and Intelligent System, ICORIS 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, doi: 10.1109/ICORIS56080.2022.10031403.
- [10] V. Kumar, T. Docse, P. Kumar, S. Docse, and A. Pandey, "Hue based Plant Leaves Disease Detection and Classification Using Machine Learning Approach," *2021 10th IEEE International Conference on Communication Systems and Network Technologies (CSNT)*, 2021, doi: 10.1109/CSNT.2021.104.
- [11] M. Y. Pusadan, I. Safitri, and *et al*, "The Image Extraction Using the HSV Method to Determine the Maturity Level of Palm Oil Fruit with the k-nearest Neighbor Algorithm," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 6, pp. 1448–1456, Dec. 2023, doi: 10.29207/resti.v7i6.5558.
- [12] P. Hidayat, R. Kurniawan, Y. A. Wijaya, and T. Suprpti, "Optimasi Algoritma K-Nearest (KNN) Neighbors Pada Prediksi Risiko Penyakit Kardiovaskular," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 1, Jan. 2025, doi: 10.23960/jitet.v13i1.5864.
- [13] L. Guadarrama, C. Paredes, and O. Mercado, "Plant Disease Diagnosis in the Visible Spectrum," *Applied Sciences (Switzerland)*, vol. 12, no. 4, Feb. 2022, doi: 10.3390/app12042199.
- [14] Z. H. Husin, N. S. A. M. Taujuddin, S. Sari, and *et al*, "Bacterial Leaf Blight (BLB) Disease Detection Using Hue, Saturation, Value (HSV) Band Threshold Method," in *Lecture Notes in Electrical Engineering*, Springer Science and Business Media Deutschland GmbH, 2022, pp. 403–420. doi: 10.1007/978-981-16-2406-3_31.
- [15] J. Amin *et al.*, "An Integrated Design Based on Dual Thresholding and Features Optimization for White Blood Cells Detection," *IEEE*, vol. 9, pp. 151421–151433, 2021, doi: 10.1109/ACCESS.2021.3123256.
- [16] B. G. Kaushalya Madhavi, A. Bhujel, N. E. Kim, and H. T. Kim, "Measurement of Overlapping Leaf Area of Ice Plants Using Digital Image Processing Technique," *Agriculture (Switzerland)*, vol. 12, no. 9, Sep. 2022, doi: 10.3390/agriculture12091321.
- [17] A. A. Huda, B. Setiaji, and F. R. Hidayat, "Implementasi Gray Level Co-Occurrence Matrix (GLCM) Untuk Klasifikasi Penyakit Daun Padi," 2022. [Online]. Available: www.ejournal.unib.ac.id/index.php/pseudocode
- [18] M. Raeisi and A. B. Sesay, "A Distance Metric for Uneven Clusters of Unsupervised K-Means Clustering Algorithm," *IEEE*, vol. 10, pp. 86286–86297, 2022, doi: 10.1109/ACCESS.2022.3198992.