

Perbandingan Kinerja Algoritma C4.5, Naïve Bayes dan K-Nearest Neighbor dalam Sistem Deteksi Penyakit Tanaman Jagung

Royandi¹, Paskal Kalempe^{1*}, Wilem Musu², Hardi²

¹Teknik Informatika, Universitas Dipa Makassar, Makassar, Indonesia

²Universitas Dipa Makassar, Makassar, Indonesia

e-mail: ¹randiroyandi@gmail.com, ²paskalkalempe300302@gmail.com,

³wilem.musu@undipa.ac.id, ⁴hardi@undipa.ac.id

Abstrak

Penyakit daun jagung dapat menyebabkan penurunan produktivitas sehingga diperlukan metode identifikasi yang mampu melakukan klasifikasi secara cepat dan akurat. Penelitian ini bertujuan mengembangkan sistem klasifikasi penyakit daun jagung menggunakan algoritma Decision Tree C4.5, Gaussian Naïve Bayes, dan K-Nearest Neighbor (KNN) berdasarkan fitur ekstraksi citra. Data penelitian terdiri atas tiga kelas penyakit, yaitu Bercak Daun, Bulai Daun, dan Hawar Daun. Hasil pengujian menunjukkan bahwa KNN dengan konfigurasi K=5 memberikan performa terbaik dengan akurasi 88,1%, precision 88,7%, recall 88,1%, dan F1-score 87,9%. Model tersebut dipilih sebagai metode klasifikasi terbaik dalam penelitian ini.

Kata kunci—Klasifikasi Citra, Penyakit Daun Jagung, Ekstraksi Fitur, KNN, Machine learning.

Abstract

Corn leaf diseases can reduce crop productivity; therefore, an identification method capable of performing fast and accurate classification is required. This study aims to develop a corn leaf disease classification system using Decision Tree C4.5, Gaussian Naïve Bayes, and K-Nearest Neighbor (KNN) algorithms based on image feature extraction. The dataset consists of three disease classes: Leaf Spot, Leaf Blight, and Downy Mildew. The experimental results show that KNN with the K=5 configuration achieved the best performance with an accuracy of 88.1%, precision of 88.7%, recall of 88.1%, and F1-score of 87.9%. This model was selected as the best classification method in this study.

Keywords—Image Classification, Corn Leaf Disease, Feature Extraction, KNN, Machine learning.

1. PENDAHULUAN

Jagung (*Zea mays* L.) merupakan komoditas penting yang dimanfaatkan sebagai bahan pangan dan pakan. Produktivitas jagung dapat terganggu oleh penyakit yang menimbulkan perubahan visual pada daun, seperti perubahan warna, bercak, pola permukaan, dan kerusakan jaringan. Beberapa penyakit yang menjadi perhatian adalah hawar daun, bercak daun, dan bulai. Kemiripan gejala antarpenyakit pada kondisi tertentu membuat identifikasi visual tidak selalu mudah. Kajian mengenai penyakit jagung juga menegaskan bahwa penyakit daun dapat memengaruhi kondisi dan produktivitas tanaman [1], [2].

Pada lokasi penelitian, pengenalan penyakit masih dilakukan melalui pengamatan kondisi daun secara langsung. Pendekatan ini bergantung pada pengalaman, ketelitian, dan persepsi

pengamat sehingga daun dengan karakteristik yang mirip dapat memperoleh hasil pengenalan yang berbeda. Pengolahan citra menjadi salah satu pendekatan yang dapat membantu mengubah informasi visual menjadi data numerik yang dapat dianalisis secara konsisten. Informasi warna, tekstur, distribusi intensitas, dan tepi citra dapat digunakan untuk membedakan karakteristik antarkelas penyakit [3].

Penelitian sebelumnya telah menerapkan berbagai metode pada klasifikasi penyakit daun jagung. Azizah menggunakan CNN AlexNet untuk memanfaatkan karakteristik visual citra daun [4], sedangkan Kusumastuti dkk. menerapkan EfficientNet pada ribuan citra penyakit daun jagung [5]. Pada pendekatan machine learning, Kusuma dkk. membandingkan SVM, KNN, dan Multilayer Perceptron dengan fitur dari VGG-16 [6]. Sementara itu, Naïve Bayes telah digunakan untuk klasifikasi penyakit dan hama jagung, baik dengan Information Gain maupun pendekatan fuzzy discretization [7], [8].

Berbeda dari penelitian terdahulu yang banyak menggunakan deep learning atau fitur dari jaringan pralatih, penelitian ini membandingkan Decision Tree C4.5, Gaussian Naïve Bayes, dan KNN menggunakan rangkaian Image Processing serta feature vector yang sama. Data berasal dari citra hasil pengambilan langsung di lokasi penelitian dan dataset publik. Dengan sumber fitur, pembagian data, kelas penyakit, serta metrik evaluasi yang dibuat sama, perbedaan hasil lebih mencerminkan karakteristik mekanisme klasifikasi masing-masing algoritma. Tujuan penelitian adalah membandingkan kinerja ketiga algoritma dan menentukan model terbaik untuk diimplementasikan pada sistem klasifikasi penyakit daun jagung berbasis web.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dan dilaksanakan pada Mei sampai Agustus 2026. Observasi dan pengambilan citra lapangan dilakukan di Desa Kassi, Kecamatan Rumbia, Kabupaten Jeneponto, Sulawesi Selatan. Dataset yang digunakan untuk proses pembentukan dan evaluasi model diperoleh dari dataset publik dan terdiri atas tiga kelas penyakit daun jagung, yaitu Bercak Daun, Bulai Daun, dan Hawar Daun. Citra pada dataset publik telah memiliki label kelas penyakit dan digunakan dalam proses *training*, *validation*, serta *testing* model. Selain itu, penelitian ini juga menggunakan citra daun jagung yang diperoleh secara langsung dari lokasi penelitian. Citra lapangan tersebut belum memiliki label penyakit karena jenis penyakitnya belum diketahui sebelumnya sehingga tidak digunakan dalam proses pelatihan maupun evaluasi model, melainkan digunakan sebagai masukan pada aplikasi untuk memperoleh hasil prediksi jenis penyakit. Pengumpulan data dilakukan melalui observasi lapangan, dokumentasi citra, pemanfaatan dataset publik, dan studi literatur.

2.1 Dataset Penelitian

Dataset yang digunakan dalam proses pembentukan dan evaluasi model berjumlah 450 citra daun jagung yang diperoleh dari dataset publik. Dataset tersebut terdiri atas tiga kelas penyakit, yaitu Bercak Daun sebanyak 150 citra, Bulai Daun sebanyak 150 citra, dan Hawar Daun sebanyak 150 citra. Label kelas penyakit pada citra mengikuti label yang telah tersedia pada dataset publik. Dataset berlabel tersebut digunakan dalam proses *training*, *validation*, dan *testing* untuk membangun serta mengevaluasi model klasifikasi. Distribusi jumlah citra berdasarkan kelas penyakit dan sumber data ditunjukkan pada Tabel 1.

Tabel 1 Dataset Penelitian

Kelas Penyakit	Dataset Publik	Total
Bercak Daun	150	150
Bulai Daun	150	150
Hawar Daun	150	150
Total	450	450

Selain dataset publik, penelitian ini juga menggunakan citra daun jagung yang diperoleh secara langsung di Desa Kassi, Kecamatan Rumbia, Kabupaten Jeneponto, Sulawesi Selatan.

Citra lapangan tersebut belum memiliki label penyakit pada saat pengambilan gambar karena jenis penyakit pada daun belum diketahui sebelumnya. Oleh karena itu, citra lapangan tidak digunakan dalam proses *training*, *validation*, maupun *testing* model. Citra tersebut digunakan secara terpisah sebagai masukan pada aplikasi untuk memperoleh hasil prediksi jenis penyakit berdasarkan model klasifikasi yang telah dibangun.

2.2 Tahapan Penelitian

Tahapan penelitian dimulai dari pengumpulan citra daun jagung, *Image Processing* dan *Prapemrosesan*, ekstraksi fitur, pembentukan *feature vector*, pembagian dataset, pelatihan model, validasi konfigurasi, pengujian pada *test set*, evaluasi, penentuan model terbaik, dan implementasi pada sistem berbasis *web*. Setiap algoritma menerima sumber data dan representasi fitur yang sama agar perbandingan dilakukan secara setara.

2.3 Image Processing, Prapemrosesan, dan Ekstraksi Fitur

Pada penelitian ini, *Image Processing* digunakan untuk mengubah citra daun jagung menjadi representasi numerik yang dapat digunakan oleh model klasifikasi. Citra terlebih dahulu dibaca, kemudian di-*resize* menjadi 224 x 224 piksel dan dinormalisasi dari rentang nilai 0-255 menjadi 0-1. Citra selanjutnya dianalisis dalam representasi RGB, HSV, dan *grayscale*. Fitur warna diperoleh melalui statistik kanal RGB dan HSV, sedangkan *histogram* menggunakan 16 bin pada tiga kanal RGB, tiga kanal HSV, dan satu kanal *grayscale*. Fitur tekstur dan struktur citra diperoleh melalui *Local Binary Pattern* (LBP), *entropy*, *Sobel*, dan *Laplacian*. Tahapan ini tidak menentukan kelas penyakit secara langsung, tetapi menyiapkan karakteristik warna, intensitas, tekstur, kompleksitas, dan tepi sebagai masukan yang sama bagi C4.5, *Gaussian Naïve Bayes*, dan KNN [3], [9], [10].

Seluruh nilai hasil ekstraksi digabungkan menjadi satu *feature vector* bertipe numerik sebanyak 173 fitur, terdiri atas 12 fitur statistik RGB, 12 fitur statistik HSV, 48 *histogram* RGB, 48 *histogram* HSV, 16 *histogram grayscale*, 26 LBP, 1 *entropy*, 7 *Sobel*, dan 3 *Laplacian*. Komposisi tersebut ditunjukkan pada Tabel 2.

Tabel 2 Komposisi feature vector

Kelompok Fitur	Jumlah Fitur	Keterangan
Statistik RGB	12	<i>Mean</i> , std, min, max untuk kanal R, G, B
Statistik HSV	12	<i>Mean</i> , std, min, max untuk kanal H, S, V
<i>Histogram</i> RGB	48	3 kanal x 16 bin
<i>Histogram</i> HSV	48	3 kanal x 16 bin
<i>Histogram Grayscale</i>	16	1 kanal x 16 bin
LBP	26	Representasi tekstur lokal
<i>Entropy</i>	1	Keragaman informasi citra
<i>Sobel</i>	7	Statistik perubahan tepi
<i>Laplacian</i>	3	Karakteristik turunan kedua
Total	173	<i>Feature vector</i> model

2.4 Pembagian Data, Protokol Perbandingan, dan Model Klasifikasi

Pada tahap perancangan, dataset direncanakan dibagi dengan proporsi 70% data *training*, 15% data *validation*, dan 15% data *testing*. Namun, pada implementasi diperoleh pembagian aktual sebanyak 311 citra *training*, 72 citra *validation*, dan 67 citra *testing* dari total 450 citra. Perbedaan jumlah tersebut terjadi karena proses pembagian dilakukan dengan mempertahankan

distribusi masing-masing kelas penyakit dan menyesuaikan jumlah citra dalam bentuk bilangan bulat pada setiap kelompok. Oleh karena itu, proporsi aktual tidak tepat sama dengan rancangan 70:15:15, tetapi tetap mendekati proporsi yang telah ditetapkan. Data *training* digunakan untuk membangun model, data *validation* digunakan untuk menentukan konfigurasi atau parameter model, sedangkan data *testing* digunakan secara terpisah untuk evaluasi akhir.

Tabel 3 Protokol evaluasi model pada implementasi

Tahapan	Jumlah Citra	Fungsi
<i>Training</i>	311	Melatih model
<i>Validation</i>	72	Memilih model/parameter terbaik
Final Fit	383	Pelatihan akhir menggunakan <i>training</i> dan <i>validation</i>
<i>Test</i>	67	Evaluasi akhir model

Model yang dibandingkan adalah *Decision Tree* C4.5 dengan *criterion entropy*, *Gaussian Naïve Bayes* dengan asumsi distribusi Gaussian dan independensi antarfitur, serta KNN berbasis kedekatan jarak. KNN diuji pada K=1, K=3, K=5, K=7, dan K=9. Proses perbandingan dilakukan melalui tujuh langkah: (1) menyiapkan dataset dan *feature vector* 173 fitur yang sama; (2) menggunakan pembagian data yang sama; (3) melatih masing-masing model; (4) memilih konfigurasi menggunakan data *validation* tanpa memakai *test* sebagai dasar pemilihan; (5) melakukan final fit pada 383 citra *training+validation*; (6) memprediksi 67 citra *test* dan menyusun *confusion matrix* beserta *accuracy*, *precision*, *recall*, dan *F1-score*; serta (7) melakukan *benchmark* untuk menentukan model dengan performa paling seimbang [11], [12].

2.5 Evaluasi Model

Kinerja model diukur menggunakan *confusion matrix*, *accuracy*, *precision*, *recall*, dan *F1-score*. Pada klasifikasi multikelas, *precision*, *recall*, dan *F1-score* keseluruhan diringkas menggunakan *macro average* agar setiap kelas memperoleh bobot yang sama. Data *test* tidak digunakan pada proses pemilihan model, sehingga hasil evaluasi akhir menggambarkan kemampuan model terhadap data yang tidak digunakan selama pelatihan dan validasi [13], [14].

$$Accuracy = \left(\text{jumlah prediksi} \frac{\text{benar}}{\text{seluruh}} \text{ data uji} \right) \times 100\% \quad (1)$$

$$Precision = \frac{TP}{(TP + FP)} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

3. HASIL DAN PEMBAHASAN

3.1 Hasil Ekstraksi Fitur

Rangkaian *Image Processing* menghasilkan *feature vector* sebanyak 173 nilai untuk setiap citra. Statistik RGB dan HSV merepresentasikan variasi warna; *histogram* RGB, HSV, dan *grayscale* menggambarkan distribusi intensitas; LBP merepresentasikan pola tekstur lokal; *entropy* menggambarkan tingkat keragaman informasi; sedangkan *Sobel* dan *Laplacian* memberikan karakteristik perubahan tepi. Karena ketiga algoritma menerima *feature vector* yang sama, perbandingan dapat difokuskan pada kemampuan masing-masing model dalam memanfaatkan karakteristik visual tersebut.


3.2 Perbandingan Kinerja Model

Benchmark test dilakukan pada 67 citra *test* yang sama. C4.5 memperoleh *accuracy* 77,6%, *macro precision* 77,3%, *macro recall* 77,7%, dan *macro F1-score* 77,2%. *Gaussian Naïve Bayes* memperoleh *accuracy* 64,2%, *macro precision* 66,5%, *macro recall* 64,8%, dan *macro F1-score*

60,6%. Pada KNN, *accuracy* tertinggi sebesar 88,1% diperoleh pada K=1 dan K=5. K=5 memiliki *macro precision* 88,7%, lebih tinggi daripada K=1 sebesar 87,9%, sehingga KNN K=5 dipilih sebagai konfigurasi terbaik.

Tabel 4 *Benchmark test* perbandingan model

Model	K	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	Waktu
C4.5	-	77.6%	77.3%	77.7%	77.2%	0.68 ms
Gaussian NB	-	64.2%	66.5%	64.8%	60.6%	0.02 ms
KNN	1	88.1%	87.9%	88.1%	87.9%	0.00 ms
KNN	3	85.1%	86.1%	85.0%	84.6%	0.00 ms
KNN	5	88.1%	88.7%	88.1%	87.9%	0.00 ms
KNN	7	85.1%	86.1%	85.0%	84.6%	0.00 ms
KNN	9	79.1%	79.2%	79.1%	78.3%	0.00 ms



Gambar 1 Perbandingan *accuracy* seluruh model

Hasil *benchmark* menunjukkan perbedaan kinerja yang jelas. *Decision Tree* C4.5 membentuk pohon keputusan dengan *criterion entropy*, 53 node, dan kedalaman maksimum 9, tetapi masih mengalami kesalahan pada kelas yang memiliki kemiripan visual. *Gaussian Naïve Bayes* menghasilkan waktu proses yang ringan, namun asumsi independensi antarfitur belum mampu merepresentasikan hubungan kompleks antara fitur warna, *histogram*, tekstur, dan tepi. KNN lebih sesuai dengan struktur *feature vector* penelitian karena memanfaatkan kedekatan antarfitur secara langsung. *Accuracy* KNN K=5 lebih tinggi 10,5 poin persentase daripada C4.5 dan 23,9 poin persentase daripada *Gaussian Naïve Bayes*. Dibanding KNN K=1, K=5 memiliki *accuracy* dan *F1-score* yang sama, tetapi *macro precision* lebih tinggi 0,8 poin persentase, sehingga dipilih sebagai model terbaik.

3.3 *Confusion matrix* KNN K=5

Pada model KNN K=5, 59 dari 67 citra *test* diklasifikasikan dengan benar. Seluruh 22 citra Bulai Daun dikenali dengan benar. Untuk kelas Bercak Daun, 17 dari 22 citra diklasifikasikan dengan benar, sedangkan pada Hawar Daun 20 dari 23 citra dikenali dengan benar. Kesalahan yang masih terjadi terutama menunjukkan adanya kemiripan visual antara Bercak Daun dan Hawar Daun.

Tabel 5 *Confusion matrix* KNN K=5 pada *test set*

Aktual / Prediksi	Bercak Daun	Bulai Daun	Hawar Daun
Bercak Daun	17	2	3
Bulai Daun	0	22	0
Hawar Daun	1	2	20


Aktual \ Prediksi	Bercak	Bulai	Hawar
Bercak	17	2	3
Bulai	0	22	0
Hawar	1	2	20


Gambar 2 Heatmap Confusion Matrix KKN (KNN=5)

Per-class report memperkuat hasil tersebut. KNN K=5 menghasilkan *precision* 94,4%, *recall* 77,3%, dan *F1-score* 85,0% pada Bercak Daun; *precision* 84,6%, *recall* 100%, dan *F1-score* 91,7% pada Bulai Daun; serta *precision*, *recall*, dan *F1-score* masing-masing 87,0% pada Hawar Daun. Nilai *recall* 100% pada Bulai Daun menunjukkan bahwa seluruh sampel aktual Bulai Daun pada *test set* teridentifikasi oleh model.


3.4 Implementasi Sistem Berbasis Web

Model KNN K=5 selanjutnya digunakan pada sistem berbasis *web* dengan *Flask* sebagai *backend*. Antarmuka menyediakan dua jalur *input*, yaitu *upload* gambar dan kamera. Pengguna dapat memilih citra, melihat *preview*, menjalankan deteksi, serta melihat hasil prediksi dan visualisasi tahapan *image processing*. Sistem menyediakan masukan citra melalui pengambilan gambar kamera secara *realtime* dan *upload* gambar dari perangkat pengguna. Citra diproses melalui *resize*, normalisasi, ekstraksi fitur, dan pembentukan *feature vector* 173 fitur sebelum diberikan kepada model KNN K=5. *Backend* kemudian mengembalikan label kelas penyakit untuk ditampilkan pada halaman *web* [15].

Gambar 3 Dashboard sistem dengan pilihan *input upload* gambar dan kamera



Gambar 4 Contoh keluaran prediksi pada citra Bercak Daun

Gambar 5 Visualisasi tahapan *image processing* dan waktu proses per tahapTabel 6 Pengujian fitur *web* yang dapat diverifikasi dari dokumentasi skripsi

Fitur	Contoh masukan	Keluaran yang terdokumentasi	Hasil uji dokumentasi
<i>Upload</i> gambar	Citra daun dari perangkat	<i>Preview</i> dan label prediksi Bercak Daun	Berhasil ditunjukkan pada lampiran
Kamera	<i>Frame</i> kamera <i>realtime</i>	Fitur tersedia pada antarmuka	Keberhasilan <i>capture</i> /prediksi khusus kamera belum terdokumentasi

Fitur	Contoh masukan	Keluaran yang terdokumentasi	Hasil uji dokumentasi
<i>Processing</i>	Citra terpilih	<i>Resize</i> , normalisasi, RGB, HSV, <i>grayscale</i> , histogram, LBP, <i>entropy</i> , Sobel, Laplacian	Berhasil ditampilkan

Tabel 7 Waktu tahapan *image processing* pada satu contoh citra yang ditampilkan sistem

Tahap	Waktu pada contoh tampilan
Pembacaan/ <i>original</i>	67,27 ms
<i>Resize</i>	34,10 ms
Normalisasi	0,32 ms
RGB	0,77 ms
HSV	0,61 ms
<i>Grayscale</i>	0,04 ms
Histogram	6,24 ms
LBP	28,25 ms
<i>Entropy</i>	2,36 ms
Sobel	0,26 ms
Laplacian	0,21 ms

3.5 Pembahasan

Prosedur perbandingan dibuat setara dengan menggunakan sumber fitur, pembagian data, kelas penyakit, dan metrik evaluasi yang sama. Dengan demikian, selisih kinerja terutama menunjukkan perbedaan cara ketiga algoritma membentuk keputusan: C4.5 menggunakan aturan pemisahan, *Gaussian Naïve Bayes* menggunakan probabilitas, dan KNN menggunakan kedekatan jarak. Pada dataset ini, pendekatan berbasis jarak memberikan hasil paling tinggi.

KNN K=5 memberikan keseimbangan terbaik dengan *accuracy* 88,1%, *macro precision* 88,7%, *macro recall* 88,1%, dan *macro F1-score* 87,9%. K=1 memperoleh *accuracy* yang sama, tetapi *macro precision* lebih rendah. Sementara itu, peningkatan jumlah tetangga hingga K=9 menurunkan *accuracy* menjadi 79,1%, sehingga penambahan K tidak selalu meningkatkan performa dan dapat membuat keputusan kurang spesifik ketika batas antarkelas berdekatan.

Kesalahan klasifikasi paling perlu diperhatikan pada Bercak Daun dan Hawar Daun karena kedua kelas dapat memiliki kemiripan warna, tekstur, serta pola kerusakan. Sebaliknya, pada KNN K=5 seluruh 22 citra Bulai Daun pada *test set* berhasil dikenali, yang ditunjukkan oleh *recall* 100% pada kelas tersebut. Peningkatan variasi data, augmentasi terkontrol, seleksi fitur, serta penambahan fitur tekstur atau bentuk yang lebih spesifik dapat digunakan untuk meningkatkan kemampuan generalisasi model.

4. KESIMPULAN

Berdasarkan hasil penelitian dapat disimpulkan bahwa: (1) karakteristik visual citra daun jagung dapat direpresentasikan melalui kombinasi fitur warna, intensitas, tekstur, kompleksitas, dan tepi yang membentuk feature vector sebanyak 173 fitur untuk membedakan Bercak Daun,

Bulai Daun, dan Hawar Daun; (2) ketiga algoritma berhasil diterapkan menggunakan fitur yang sama, dengan accuracy KNN 88,1%, lebih tinggi daripada Decision Tree C4.5 sebesar 77,6% dan Gaussian Naïve Bayes sebesar 64,2%; dan (3) KNN K=5 dipilih sebagai model terbaik karena memberikan keseimbangan accuracy 88,1%, macro precision 88,7%, macro recall 88,1%, dan macro F1-score 87,9%, sehingga digunakan sebagai model klasifikasi pada sistem berbasis web.

5. SARAN

- a. Menambah jumlah dan variasi citra dari berbagai kondisi pencahayaan, varietas, sudut pengambilan gambar, lokasi, dan tingkat keparahan penyakit untuk meningkatkan kemampuan generalisasi model.
- b. Meningkatkan kemampuan membedakan Bercak Daun dan Hawar Daun melalui penambahan data, augmentasi citra, seleksi fitur, atau penggunaan fitur tekstur dan bentuk yang lebih spesifik.
- c. Melakukan optimasi KNN dan pengembangan fitur melalui pengujian nilai K, metode seleksi fitur, serta perbandingan dengan metode klasifikasi lain menggunakan protokol evaluasi yang setara.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada Kepala Desa Kassi atas izin dan dukungan selama pelaksanaan penelitian. Terima kasih juga disampaikan kepada Dr. Eng. Wilem Musu, S.Kom., M.T. selaku Pembimbing I dan Hardi, S.E., M.M. selaku Pembimbing II atas bimbingan dan arahan dalam penyusunan penelitian ini, serta kepada kedua orang tua, keluarga, dan seluruh pihak yang telah memberikan dukungan.

DAFTAR PUSTAKA

- [1] M. A. Ahangar et al., "Distribution, Etiology, Molecular Genetics and Management Perspectives of Northern Corn Leaf Blight of Maize (*Zea mays* L.)," *Phyton-International Journal of Experimental Botany*, vol. 91, no. 10, 2022, doi: 10.32604/phyton.2022.020721.
- [2] E. Wulandari, J. Prasetyo, M. Nurdin, and T. Maryono, "Pengaruh Mefenoksam dan *Trichoderma* sp. Terhadap Penyakit Bulai dan Pertumbuhan Tanaman Jagung," *Jurnal Agrotek Tropika*, vol. 10, no. 1, pp. 43-49, 2022, doi: 10.23960/jat.v10i1.5601.
- [3] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*, 4th ed. Pearson Education, 2018.
- [4] Q. N. Azizah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet," *Sudo: Jurnal Teknik Informatika*, vol. 2, no. 1, pp. 28-33, 2023, doi: 10.56211/sudo.v2i1.227.
- [5] R. Kusumastuti, T. D. Putra, and Z. Z. Yudam, "Klasifikasi Citra Penyakit Daun Jagung Menggunakan Algoritma CNN EfficientNet," *Multitek Indonesia: Jurnal Ilmiah*, vol. 17, no. 2, pp. 143-153, 2024, doi: 10.24269/mtkind.v17i2.10085.
- [6] J. Kusuma, Rubianto, R. Rosnelly, Hartono, and B. H. Hayadi, "Klasifikasi Penyakit Daun Pada Tanaman Jagung Menggunakan Algoritma Support Vector Machine, K-Nearest Neighbors dan Multilayer Perceptron," *Journal of Applied Computer Science and Technology (JACOST)*, vol. 4, no. 1, pp. 1-6, 2022, doi: 10.52158/jacost.v4i1.484.
- [7] E. Rahmanita, Y. D. P. Negara, Y. Kustiyaningsih, V. Sasmeka, and B. K. Khotimah, "Implementasi Metode Naïve Bayes dan Information Gain Untuk Klasifikasi Penyakit dan Hama Tanaman Jagung," *TEKNIKA*, vol. 12, no. 3, pp. 198-204, 2023, doi: 10.34148/teknika.v12i3.684.
- [8] Y. Resti, C. Irsan, A. Neardiaty, C. Annabila, and I. Yani, "Fuzzy Discretization on the Multinomial Naïve Bayes Method for Modeling Multiclass Classification of Corn Plant Diseases and Pests," *Mathematics*, vol. 11, no. 8, 2023, doi: 10.3390/math11081761.

- [9] Q. Luo, J. Su, C. Yang, O. Silven, and L. Liu, "Scale-Selective and Noise-Robust Extended *Local Binary Pattern* for Texture Classification," *Pattern Recognition*, vol. 132, 2022, doi: 10.1016/j.patcog.2022.108901.
- [10] E. Lhermitte, M. Hilal, R. Furlong, V. O'Brien, and A. Humeau-Heurtier, "Deep Learning and *Entropy*-Based Texture Features for Color Image Classification," *Entropy*, vol. 24, no. 11, pp. 1-14, 2022, doi: 10.3390/e24111577.
- [11] M. Bansal, A. Goyal, and A. Choudhary, "A Comparative Analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, *Decision Tree* and Long Short Term Memory Algorithms in Machine Learning," *Decision Analytics Journal*, vol. 3, 2022, doi: 10.1016/j.dajour.2022.100071.
- [12] G. Christnatis, E. S. Gulo, Y. R. Gulo, and S. F. Marbun, "Perbandingan Efektifitas Algoritma Decision Tree, Naïve Bayes, K-Nearest Neighbor dan Support Vector Machine Dalam Melakukan Klasifikasi," *Jurnal Teknologi dan Ilmu Komputer Prima (JUTIKOMP)*, vol. 5, pp. 54-59, 2022, doi: 10.34012/jutikomp.v5i2.2940.
- [13] J. H. Cabot and E. G. Ross, "Evaluating Prediction Model Performance," *Surgery*, vol. 174, no. 3, pp. 723-726, 2023, doi: 10.1016/j.surg.2023.05.023.
- [14] A. Vanacore, M. S. Pellegrino, and A. Ciardiello, "Fair Evaluation of Classifier Predictive Performance Based on Binary Confusion Matrix," *Computational Statistics*, vol. 39, no. 1, pp. 363–383, 2024, doi: 10.1007/s00180-022-01301-9.
- [15] M. Grinberg, *Flask Web Development: Developing Web Applications with Python*, 2nd ed. O'Reilly Media, 2018.