

Klasifikasi Penyakit Daun Bawang Merah Menggunakan MobileNetV2 Convolutional Neural Network (CNN)

Widia Ainun Arabiaih*, Fathir, Hilyatul Mustafidah

Fakultas Teknik dan Ilmu Komputer, Ilmu Komputer, Universitas Muhammadiyah Bima, Bima

Jl. Anggrek, Nae, Kec. Rasanae Bar., Kab. Bima, Nusa Tenggara Barat, Indonesia

Email: ^{1,*}ainunwidia7@gmail.com, ²fathirpuncak@gmail.com, ³hilyatulfida@gmail.com

Email Penulis Korespondensi: ainunwidia7@gmail.com

Submitted: 02/07/2026; Accepted: 20/07/2026; Published: 21/07/2026

Abstrak—Penyakit pada tanaman bawang merah menjadi salah satu penyebab utama yang menyebabkan penurunan kualitas dan kuantitas hasil panen. Identifikasi penyakit secara manual masih mengandalkan pengamatan visual sehingga rentan terhadap kesalahan dan memerlukan waktu yang cukup lama. Penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit daun bawang merah menggunakan gabungan ekstraksi fitur Gray Level Co-occurrence Matrix (GLCM) dan MobileNetV2 yang diklasifikasikan dengan Convolutional Neural Network (CNN). Dataset yang digunakan terdiri dari 1.188 citra daun bawang merah yang dibagi ke dalam lima kelas, yaitu embun bulu, sehat, hawar daun, moler, dan bercak ungu. Tahapan penelitian mencakup pengumpulan dataset, pre-processing berupa resize citra menjadi 224×224 piksel, konversi grayscale, normalisasi, dan augmentasi data, diikuti dengan ekstraksi fitur tekstur menggunakan GLCM serta ekstraksi fitur mendalam menggunakan MobileNetV2. Kedua fitur kemudian digabungkan dan digunakan sebagai input pada model CNN untuk proses klasifikasi. Evaluasi model dilakukan menggunakan confusion matrix dengan metrik akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa model yang diusulkan mampu mencapai akurasi sebesar 93%, dengan nilai presisi, recall, dan F1-score yang seimbang pada sebagian besar kelas. Hasil tersebut menunjukkan bahwa kombinasi fitur GLCM dan MobileNetV2 mampu meningkatkan kemampuan model dalam membedakan karakteristik tekstur dan fitur visual daun bawang merah yang efektif digunakan sebagai metode klasifikasi penyakit tanaman bawang merah. Kontribusi penelitian ini adalah mengintegrasikan ekstraksi fitur tekstur Gray Level Co-occurrence Matrix (GLCM) dengan fitur visual mobilenetv2 pada model convolutional neural network (CNN) untuk meningkatkan performa klasifikasi penyakit daun bawang merah.

Kata Kunci: Penyakit Daun Bawang Merah; Convolutional Neural Network; MobileNetV2

Abstract—Diseases affecting shallot plants are a primary cause of reduced crop quality and yield. Manual disease identification relies on visual observation, making it prone to error and time-consuming. This study aims to develop a classification model for shallot leaf diseases by combining Gray Level Co-occurrence Matrix (GLCM) feature extraction with MobileNetV2, classified using a Convolutional Neural Network (CNN). The dataset comprises 1,188 shallot leaf images categorized into five classes: downy mildew, healthy, leaf blight, *moler* (basal rot), and purple blotch. The research process involved dataset collection; pre-processing (image resizing to 224×224 pixels, grayscale conversion, normalization, and data augmentation); texture feature extraction using GLCM; and deep feature extraction using MobileNetV2. These features were then combined and used as input for the CNN classification model. Model evaluation was conducted using a confusion matrix, assessing accuracy, precision, recall, and F1-score. The results demonstrate that the proposed model achieved 93% accuracy, with balanced precision, recall, and F1-score values across most classes. The contribution of this research is the integration of gray level co-occurrence matrix (GLCM) texture feature extraction with mobilenetv2 visual features within a convolutional neural network (CNN) model to improve the classification performance of shallot leaf diseases.

Keywords: Red Onion Leaf Disease; Convolutional Neural Network; MobileNetV2

1. PENDAHULUAN

Klasifikasi adalah bagian dari pengolahan gambar yang bertujuan untuk mengelompokkan atau mengkategorikan gambar ke dalam berbagai kelas atau kategori berdasarkan konten visual yang terkandung dalam gambar tersebut. Bawang merah (*Allium ascalonicum* L.) adalah salah satu bahan pokok yang penting bagi konsumen rumah tangga sebagai tambahan bumbu untuk masakan sehari-hari. Satu lagi kegunaan bawang merah adalah sebagai obat tradisional, yang manfaatnya telah dirasakan secara luas oleh masyarakat [1]. Sejalan dengan pesatnya perkembangan industri makanan dalam beberapa tahun terakhir, kebutuhan bawang merah domestik juga mengalami peningkatan. Di Indonesia, salah satu pusat produksi bawang merah terletak di Kabupaten Enrekang, Sulawesi Selatan. Pada tahun 2018, produksinya mencapai 73,58 ton, meskipun mengalami penurunan dibandingkan dengan produksi 2017 yang mencapai 111,61 ton [2].

Usaha untuk meningkatkan produksi bawang merah sering kali terhambat oleh adanya patogen penyebab penyakit yang berasal dari kelompok jamur, seperti *Fusarium Oxysporum* f.sp. *cepae* yang menyebabkan penyakit busuk pangkal batang atau juga disebut penyakit moler. Meskipun memiliki banyak potensi, budidaya bawang merah seringkali menghadapi banyak tantangan, terutama penyakit. Penyakit-penyakit ini dapat menyebabkan masalah serius bagi petani, mulai dari penurunan hasil panen hingga gagal panen secara keseluruhan [3]. Hal ini dapat menyebabkan terjadinya gangguan, seperti rendahnya kesuburan tanaman dan serangan hama atau penyakit, yang akan menyebabkan proses penanaman menjadi diluar musim dan mengakibatkan kegagalan panen. Sehingga dapat merugikan para petani yang menanam bawang merah [4].

Serangan penyakit pada tanaman bawang merah yang dapat menyebabkan kerugian hasil panen merupakan

faktor utama yang berpotensi menurunkan produktivitas pertanian [5]. Hal ini dipengaruhi oleh beberapa faktor, termasuk kualitas tanah yang kurang subur, perubahan iklim, serta serangan hama dan penyakit yang sangat berpengaruh karena dapat diamati dari perubahan fisik tanaman, terutama pada bagian daunnya [5].

Petani biasanya mengecek penyakit tanaman masih menggunakan cara yang konvensional atau dengan melakukan pengamatan manual. Hal ini dapat menyebabkan hasil yang tidak akurat. Salah satu cara yang dapat digunakan untuk mengamati penyakit pada daun bawang yaitu dengan memanfaatkan teknologi. Perkembangan teknologi, dapat menjadikan solusi dalam permasalahan yang terjadi dalam kehidupan nyata, khususnya petani bawang merah. Berdasarkan hal tersebut diperlukan suatu model dan sistem yang sesuai untuk mengklasifikasikan penyakit tanaman daun bawang. Tujuan sasaran penggunaan teknologi untuk mengatasi masalah ini, untuk meningkatkan kemampuan pemilik hewan peliharaan dalam mengidentifikasi dan mengobati kondisi kulit secara efektif [6].

Salah satu upaya untuk menanggulangnya yaitu dengan mendeteksi menggunakan teknologi yaitu teknologi kecerdasan buatan seperti metode deep learning. Metode deep learning yang banyak digunakan untuk mendeteksi penyakit yaitu CNN, Deep Learning adalah salah satu metode pembelajaran mesin yang berlandaskan pada jaringan saraf. Tujuannya adalah untuk berfungsi mirip dengan jaringan saraf korteks manusia [7]. Deep Learning memiliki kelebihan dan kemampuan yang sangat baik dalam visi komputer, Salah satunya adalah ketika objek diklasifikasikan pada gambar.

Dengan menerapkan CNN adalah salah satu teknik pembelajaran mesin yang dapat digunakan untuk klasifikasi gambar objek [7]. Penelitian sebelumnya telah dilakukan tentang masalah yang sama, menemukan penyakit pada tanaman bawang merah. Namun, penelitian sebelumnya menggunakan metode yang berbeda; penelitian sebelumnya menggunakan metode Naive Bayes dan CNN dengan ekstraksi fitur GLCM. Hasil penelitian menunjukkan bahwa metode Naive Bayes dan CNN dalam penelitian ini menghasilkan akurasi sebesar 100% [8].

Berdasarkan penelitian terdahulu, CNN Xception untuk klasifikasi penyakit daun bawang merah mampu untuk melakukan prediksi dengan sangat baik. Hasil prediksi yang baik dibuktikan dengan akurasi yang dicapai pada saat tahap pelatihan model yang mencapai 100% dan akurasi validasi sebesar 95% [9]. Tingkat presisi terkait penyakit paru-paru adalah 82,85%. Berdasarkan penelitian sebelumnya, metode jaringan saraf konvolusional telah berhasil diterapkan untuk mengklasifikasikan citra batik tanah liat Sumatera Barat dengan menggunakan pustaka Keras dan TensorFlow, serta bahasa pemrograman Python. Dengan akurasi sebesar 98.75% [10].

Klasifikasi jenis burung di Indonesia menggunakan optimiser SGD dan Adam di dapatkan akurasi 97% hingga 98% menggunakan Confusion Matrix [11]. Hasil akurasi penyakit daun tomat sebesar 94,06% [12]. Menurut penelitian terdahulu hasil klasifikasi buah mangga ini, hasil metode Support Vector Machine dan Naive Bayes dapat diperoleh dengan akurasi 81% untuk SVM dan 70% untuk NB [13]. Menurut penelitian terdahulu, klasifikasi penyakit retina menggunakan metode CNN dengan arsitektur AlexNet dilakukan menggunakan empat kategori: normal, katarak, glaukoma, dan penyakit retina akurasi hasil klasifikasi menggunakan metode CNN adalah 98,37% [14]. Berdasarkan penelitian terdahulu, sistem ini berhasil mencapai akurasi sebesar 80%. Dengan nilai precision, recall, dan F1-score yang tinggi, hasilnya menunjukkan kematangan buah salak [15].

Berdasarkan penelitian sebelumnya yang menggunakan densenet 201 terhadap tanaman padi, diperoleh nilai akurasi 92.59% pada pelatihan dan 82.99% pada data pengujian [16]. Studi sebelumnya menunjukkan bahwa MobileNetV2 mampu mendeteksi penyakit daun bawang merah dengan akurasi 87,1%, tetapi masih terkendala oleh keterbatasan dataset. Sementara itu, metode faktor keyakinan hanya memperoleh akurasi 85,71%, dan hanya berdasarkan pengetahuan pakar. Penelitian ini mengusulkan penggabungan GLCM dan MobileNetV2 dengan CNN untuk meningkatkan kemampuan klasifikasi penyakit daun bawang merah [17].

Penelitian ini berhasil mengembangkan sistem deteksi penyakit bawang merah yang menggunakan algoritma convolutional neural network (CNN) yang dibangun dengan arsitektur mobilenet. Sistem aplikasi berbasis android ini menunjukkan performa yang sangat baik dengan akurasi uji 90,63% dan nilai kehilangan 0,1874 [3]. Studi sebelumnya menunjukkan bahwa MobileNetV2 mendeteksi penyakit daun bawang merah dengan akurasi 87,1%. Ini dapat membantu petani menemukan penyakit dengan lebih cepat. Namun, jumlah dan keragaman dataset yang dimiliki penelitian tersebut masih terbatas, sehingga kemampuan model untuk mengklasifikasikan gambar baru belum optimal [18].

Sistem pengolahan gambar mengubah informasi dari sejumlah gambar, baik yang bergerak maupun diam, menjadi informasi bermanfaat. Pengolahan gambar juga dapat digunakan dalam beberapa aplikasi, seperti klasifikasi dan identifikasi gambar. Klasifikasi adalah bagian dari pengolahan gambar yang bertujuan untuk mengelompokkan atau mengkategorikan gambar ke dalam berbagai kelas atau kategori berdasarkan konten visual yang terkandung dalam gambar tersebut.

Berdasarkan gap penelitian, penelitian ini berkontribusi dengan menggabungkan fitur tekstur GLCM dan fitur visual mobilenetv2 yang diklasifikasikan menggunakan CNN. Diharapkan metode ini dapat menghasilkan representasi fitur yang lebih komprehensif, yang akan meningkatkan kemampuan untuk mengklasifikasikan penyakit daun bawang merah.

2. METODOLOGI PENELITIAN

2.1 Objek Penelitian

Objek penelitian ini berfokus pada pengklasifikasian penyakit tanaman bawang merah pada dua jenis penyakit, bercak ungu dan moler, berdasarkan karakteristik daun bawang merah. Penelitian ini menggunakan jenis penelitian kuantitatif, Menggunakan metode Convolutional Neural Network (CNN) arsitektur Xception untuk klasifikasi penyakit daun bawang.


Subjek penelitian menggunakan dataset publik yang berisi 1.188 dataset gambar daun bawang merah. Dataset ini mencakup berbagai kondisi daun dengan penyakit yang berbeda-beda, sesuai dengan klasifikasi penyakit yang umum diketahui oleh petani. Untuk memastikan bahwa model tidak bias terhadap kelas tertentu, jumlah gambar yang dipilih untuk setiap kelas adalah 60 gambar. Studi sebelumnya telah menunjukkan bahwa model CNN seperti Xception mampu bekerja dengan baik dengan dataset yang terbatas dan memerlukan parameter untuk mendukung kinerja model saat menangani dataset yang terbatas.

2.2 Alur Penelitian

Bawang merah merupakan tanaman semusim yang tersusun atas rumpun dan pendek. Tanaman ini rentan terhadap serangan hama dan penyakit, yang dapat menghambat pertumbuhan dan mengurangi hasil panen. Penting untuk dapat mengidentifikasi jenis penyakit pada tanaman bawang merah secara akurat dan efisien [19].

Untuk memperluas lingkup penelitian, pendekatan kualitatif digunakan sebagai perencanaan dan prosedur metodologis. Metode ini memungkinkan penyelidikan sistematis terhadap variabel yang relevan. Gambar alur penelitian dapat dilihat di Gambar 1.

Gambar 1 menunjukkan alur penelitian yang digunakan dalam proses klasifikasi penyakit daun bawang merah menggunakan kombinasi ekstraksi fitur Gray Level Co-occurrence Matrix (GLCM) dan MobileNetV2 dengan klasifikasi Convolutional Neural Network (CNN). Penelitian diawali dengan tahap pengumpulan data menggunakan dataset publik yang terdiri atas 1.188 citra daun bawang merah yang mencakup lima kelas, yaitu embun bulu, sehat, hawar daun, moler, dan bercak ungu. Selanjutnya dilakukan tahap pre-processing yang meliputi perubahan ukuran citra menjadi 224×224 piksel, konversi citra RGB ke grayscale, normalisasi nilai piksel, serta augmentasi data berupa rotasi, flip, dan zoom untuk meningkatkan variasi data dan mengurangi risiko overfitting. Setelah itu, dilakukan ekstraksi fitur menggunakan metode GLCM untuk memperoleh karakteristik tekstur daun dan MobileNetV2 sebagai feature extractor untuk memperoleh fitur visual tingkat tinggi. Kedua hasil ekstraksi kemudian digabungkan menjadi satu vektor fitur yang digunakan sebagai masukan pada model CNN untuk proses klasifikasi penyakit daun bawang merah. Tahap terakhir adalah evaluasi model menggunakan confusion matrix dengan metrik akurasi, presisi, recall, dan F1-score untuk mengukur performa model dalam mengklasifikasikan setiap kelas penyakit.



Gambar 1. Alur Penelitian

2.2.1 Identifikasi Masalah

Di bidang pertanian, penyakit daun tanaman bawang merah adalah masalah besar yang dapat mengurangi kualitas panen dan produktivitas. Untuk menemukan penyakit pada daun bawang merah, ahli pertanian telah melakukan analisis visual dan penggunaan perangkat lunak deteksi berbasis fitur. Namun, metode ini seringkali memerlukan waktu yang lama, mahal, dan kurang akurat, terutama untuk penggunaan skala besar. Akibatnya, solusi berbasis transfer learning yang cepat dan tepat diperlukan untuk secara otomatis mengidentifikasi penyakit daun bawang merah melalui gambar [18].

2.2.2 Studi Literatur

Pada awalnya, penelitian ini dimulai dengan melakukan penelitian menyeluruh terhadap literatur yang mencakup berbagai aspek penting. Studi dilakukan untuk memahami sifat penyakit tanaman daun bawang merah, seperti

busuk daun, bercak ungu, dan layu, serta bagaimana tanaman tetap sehat. Selain itu, evaluasi metode berbasis gambar dan teknologi pengajaran transfer dilakukan, khususnya model MobileNetV2 yang termasuk dalam jaringan ringan representatif. Tujuan dari penelitian ini adalah untuk menciptakan landasan teori yang kuat dan untuk mengidentifikasi celah penelitian yang dapat dipenuhi oleh penelitian ini [18].

2.2.3 Pengumpulan Data

Data penelitian ini terdiri dari lima kelas daun bawang merah: embun bulu, sehat, hawar daun, moler, dan bercak ungu. Data ini diperoleh melalui platform Kaggle dan Roboflow. Dataset ini terdiri dari 1.188 data publik gambar bawang merah [18].

2.2.4 Pre-Prasessing Data

Pada fase ini, perbaikan dilakukan terhadap data yang telah diperoleh. Data tersebut akan menjalani proses pra-pemrosesan terlebih dahulu sebelum diproses lebih lanjut. Kegiatan persiapan ini terdiri dari pemotongan bagian daun, mengubah dimensi gambar menjadi 224x224 piksel, serta membagi data ke dalam tiga kategori: 70% untuk data pelatihan, 10% untuk data validasi, dan 20% untuk data pengujian. Proses pemotongan bertujuan untuk menekankan bagian penting dari daun dan menghapus latar belakang yang tidak relevan, sehingga membantu model untuk lebih fokus pada fitur-fitur signifikan untuk klasifikasi penyakit. Penyesuaian ukuran gambar menjadi 224x224 piksel juga berperan dalam mengurangi beban komputasi dan mempercepat proses pelatihan model, sembari tetap mempertahankan detail penting yang diperlukan untuk mendeteksi penyakit. Ukuran 224x224 piksel dipilih karena merupakan ukuran baku yang umum digunakan dalam berbagai arsitektur CNN, termasuk Xception, yang memungkinkan model untuk menangkap fitur penting dalam gambar tanpa mengorbankan resolusi yang terlalu tinggi atau rendah.

2.2.5 Split Data

Pembagian data 70, 20, dan 10 dengan jumlah data penyakit bawang merah sebesar 1.188, yang dibagi menjadi lima kelas gambar daun bawang merah: moler 297 gambar, sehat 195 gambar, hawar daun 255 gambar, bercak ungu 237 gambar, dan embun bulu 204. Dari kelima kelas, moler memiliki jumlah data terbesar, sedangkan sehat memiliki jumlah data paling sedikit. Meskipun jumlah gambar yang ada di setiap kelas berbeda, distribusi data dianggap cukup seimbang. Hal ini memungkinkan model CNN untuk mempelajari karakteristik masing-masing kelas dengan baik dan mengurangi kemungkinan bias terhadap kelas tertentu selama proses pelatihan.

Pembagian data yang 80, 10, 10 Data terdiri dari lima kelas penyakit daun bawang merah, seperti yang ditunjukkan pada grafik. Moler memiliki jumlah gambar terbanyak, 325 gambar, sedangkan Embun Bulu memiliki jumlah gambar paling sedikit, 235 gambar. Kelas Sehat memiliki 242 gambar, Hawar Daun 280 gambar, dan Bercak Ungu 278 gambar. Meskipun jumlah gambar per kelas agak berbeda, distribusi data antar kelas secara keseluruhan relatif seimbang. Distribusi yang cukup merata ini membantu model CNN mempelajari lebih baik fitur setiap kelas dan mengurangi kemungkinan bias terhadap kelas tertentu.

2.2.6 Ekstraksi Fitur Tekstur GLCM

Untuk menunjukkan hubungan antara pasangan nilai piksel dengan intensitas tertentu, algoritma Co-Occurrence Matrix Gray Level (GLCM) menggunakan matriks yang dibuat dari perhitungan pasangan nilai piksel dengan intensitas yang sama. Intensitas biasanya diwakili dengan jarak (d) dan nilai sudut (α) [39]. Dalam penelitian ini, karakteristik GLCM adalah sebagai berikut:

Contrast digunakan untuk mengukur perbedaan nilai intensitas grayscale antara piksel dan piksel tetangga pada seluruh gambar [20].

$$\text{Contrast} = \sum_i \sum_j (i - j)^2 p(i, j) \quad (1)$$

Dissimilarity adalah fitur yang bermanfaat untuk mengukur perbedaan pada suatu gambar [21].

$$\text{Dissimilarity} = \sum_i \sum_j p(i - [j])^2 |i - j| \quad (2)$$

Energi adalah metrik yang digunakan untuk mengukur konsentrasi pasangan intensitas dalam GLCM [21]

$$\text{Homogeneity} = \sum_i \sum_j p(i, j) / (1 + |i - j|) \quad (3)$$

Dengan mengukur ketergantungan linear antara derajat keabuan pada gambar, korelasi memberikan nilai tentang adanya struktur linear pada gambar [22].

$$\text{Energy} = \sum_i \sum_j p(i, j)^2 \quad (4)$$

Angular Second Moment (ASM) menjelaskan nilai keseragaman pada gambar [23].

$$\text{Correlation} = \sum_i \sum_j ((i - \mu_j)p(j - \mu_j)p(i, j)) / \sigma_i \sigma_j \quad (5)$$

Klasifikasi Algoritma Convolutiona Neural Network (CNN)

Suatu jenis algoritma supervised bernama Convolutional Neural Network (CNN) dibuat untuk memproses gambar sebagai input. CNN memiliki keunggulan dalam pemrosesan data gambar karena merupakan evolusi dari Multilayer Perceptron (MPL) dalam hal pemrosesan data 2D. Lapisan CNN yang digunakan dalam penelitian ini adalah lapisan convolutional, pooling, flatten, dan dense [12].

Lapisan konvolusi adalah bagian penting dari CNN yang menjalankan operasi konvolusi pada lapisan sebelumnya. Pada lapisan ini, bobot digunakan untuk menentukan kerne konvolusi yang diterapkan, dan bobot ini dapat diubah selama proses pelatihan CNN. Tujuan dari konvolusi terhadap data gambar adalah untuk mengekstraksi fitur dari gambar yang dimasukkan dengan menggunakan konvolusi, sehingga informasi spasial pada data dapat diubah secara linear. Kernel konvolusi yang diterapkan ditentukan oleh bobot pada lapisan ini, sehingga kernel konvolusi dapat dibentuk berdasarkan input pada CNN [24].

Layer yang tebal (juga disebut sebagai lapisan yang penuh terhubung), di mana setiap neuron pada lapisan ini terhubung ke semua neuron aktivasi pada lapisan sebelumnya, mengubah input multidimensi menjadi satu dimensi.

2.2.7 MobileNetV2

MobileNet, varian CNN yang ringan, memungkinkan implementasi yang lebih cepat dan hemat memori tanpa mengorbankan akurasi prediksi; ini dapat digunakan pada perangkat dengan keterbatasan daya komputasi dan memori. Selain itu, multiplier dan resolusi yang luas memungkinkan MobileNet untuk disesuaikan dengan kebutuhan aplikasi [25].

2.2.8 Implementasi Hasil Tekstur (CNN)

Selanjutnya, data yang telah diproses digunakan untuk melatih model menggunakan arsitektur MobileNetV2, yang dikenal sebagai salah satu model klasifikasi terbaik dengan tingkat akurasi yang tinggi meskipun ukurannya kecil. Pelatihan model dilakukan di Google Colab platform dengan menggunakan CPU yang tersedia. Penggunaan CPU pada Google Colab memungkinkan pelatihan model secara efektif, meskipun memerlukan waktu lebih lama dibandingkan dengan GPU, namun tetap mampu menghasilkan model deteksi yang tepat [18].

2.2.9 Evaluasi dan Implementasi Hasil

Pada tahap ini, evaluasi dan analisis terhadap hasil pengolahan data dilakukan dengan menggunakan metode yang digunakan dalam penelitian ini, yaitu confusion matrix. Confusion matrix adalah metode yang umum untuk mengukur kemampuan klasifikasi untuk membuat perkiraan tentang kategori yang tidak sama [25]. Tabel Confusion matriks prediksi dapat dilihat di Tabel 1.

Tabel 1. Confusion Matrix Prediksi

Aktual	Prediksi	
	Positive	Negative
	TP	FP
Positive		
Negative	FN	TN

Dari matriks tersebut, kita dapat memperhitungkan metrik evaluasi seperti akurasi, presisi, recall, dan skor F1.

a. FI-Score

F1-Score merupakan perbandingan antara precision rata-rata dan recall yang dibobotkan [13]. Adapun rumus FI-Score dapat menggunakan Persamaan 1

$$F1 - score = 2 \times \frac{\text{Presisi} + \text{Recal}}{\text{Presisi} \times \text{Recal}} \quad (1)$$

Skor F1 digunakan sebagai metrik evaluasi yang mengukur perbedaan antara recall dan presisi. Skor F1 yang tinggi menunjukkan bahwa model CNN tidak hanya akurat dalam memprediksi penyakit daun bawang merah, tetapi juga mampu mendeteksi sejumlah besar kasus penyakit secara akurat.

b. Recall (Sensitivity)

Ingat kemampuan model CNN untuk mendeteksi semua citra daun bawang merah yang benar-benar terkena penyakit [13]. Adapun rumus recall dapat menggunakan Persamaan 2.

$$\text{Recal} = \frac{TP}{TP + FN} \quad (2)$$

Recall digunakan untuk memahami kemampuan model CNN dalam mendeteksi semua citra daun bawang merah yang mengalami penyakit. Nilai recall yang tinggi menunjukkan bahwa model mampu meminimalkan kesulitan dalam mengurangi daun bawang merah yang terkena penyakit.

c. Akurasi (Accuracy)

Akurasi menunjukkan kemampuan model CNN dalam mengklasifikasikan citra daun bawang merah secara komprehensif, termasuk daun sehat dan daun sakit [13]. Adapun rumus akurasi dapat menggunakan Persamaan 3.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

Nilai akurasi tersebut digunakan untuk mengetahui tingkat presisi model CNN dalam mengklasifikasikan daun bawang merah secara komprehensif. Dengan meningkatnya nilai akurasi, kemampuan model dalam mendeteksi pola penyakit pada citra daun bawang merah juga meningkat.

d. Presisi (Precision)

Precision atau keakuratan ialah tingkat keakuratan antara permintaan informasi pengguna dan tanggapan sistem [13].

$$\text{Presisi} = \frac{TP}{TP+FP} \quad (4)$$


Presisi digunakan untuk meningkatkan akurasi model prediksi CNN dalam mengklasifikasikan daun bawang merah tertentu. Tingginya nilai presisi menunjukkan bahwa klasifikasi citra daun sehat atau penyakit lainnya cukup kecil [14].

Dalam penelitian ini, data gambar daun bawang merah, yang terdiri dari 1.188 gambar, dibagi ke dalam lima kelas: embun bulu, sehat, hawar daun, moler, dan bercak ungu. Gambar berikut menunjukkan bagaimana jumlah gambar didistribusikan dalam setiap kelas. Jumlah citra per-kelas dapat dilihat di Tabel 2.

Tabel 2. Jumlah citra per-kelas

No	Kelas	Jumlah Kelas
1	Embun Bulu	204
2	Sehat	195
3	Hawar Daun	255
4	Moler	295
5	Bercak Ungu	239
	Total	1.188

Tabel 2 menunjukkan bahwa distribusi gambar antara kelas tidak sepenuhnya seimbang; kelas moler memiliki jumlah gambar terbanyak (297 gambar) dan kelas sehat memiliki jumlah gambar terkecil (195 gambar), dengan perbedaan 102 gambar. Namun, metode penyeimbangan kelas khusus tidak diperlukan karena perbedaan ini masih dianggap wajar dan tidak ekstrem. Agar model dapat belajar secara merata dari setiap kelas, teknik augmentasi data masih digunakan. (Masukkan gambar 2, yang menunjukkan sampel citra dataset). Sebagian gambar dari dataset yang dimuat menggunakan Google Colab ditunjukkan di atas. Diharapkan model yang dilatih dapat digeneralisasi dengan baik karena variasi pada sudut pengambilan, pencahayaan, dan latar belakang citra tersebut mencerminkan kondisi data dunia nyata. Gambar distribusi dataset dapat dilihat di Gambar 2.




Gambar 2. Distribusi dataset daun bawang merah

Berdasarkan Gambar 2, grafik distribusi dataset, jumlah gambar dalam setiap kelas hampir sama, meskipun ada sedikit perbedaan dalam jumlah gambar. Kelas Moler memiliki jumlah gambar terbesar, kira-kira 325 gambar, sedangkan kelas embun bulu memiliki jumlah gambar terkecil, kira-kira 235 gambar. Karena perbedaan jumlah data antar kelas tidak terlalu besar, dataset ini dapat dikategorikan sebagai dataset yang seimbang. Kondisi ini membantu model mempelajari karakteristik setiap kelas tanpa terpengaruh oleh dominasi kelas tertentu. Untuk kelas dengan lebih banyak data, distribusi yang lebih merata juga dapat mengurangi kemungkinan bias klasifikasi.

3. HASIL DAN PEMBAHASAN

3.1 Pre –Processing data

Sebelum proses ekstraksi fitur dan klasifikasi dimulai, tahap prapemrosesan dilakukan. Sebelum mengubah gambar secara keseluruhan, ukurannya diubah menjadi 224×224 piksel. Ini dilakukan untuk memenuhi ukuran input yang dibutuhkan oleh arsitektur MobileNetV2. Selanjutnya, gambar diubah dari format RGB ke skala abu-abu (grayscale) untuk mempersiapkan proses ekstraksi fitur tekstur menggunakan Gray Level Co-occurrence Matrix (GLCM). Metode ini bergantung pada nilai intensitas piksel tunggal, jadi ini disebut sebagai Gray Level Co-occurrence Matrix. Untuk mempercepat konvergensi model selama proses pelatihan, nilai piksel diubah ke rentang 0–1 untuk normalisasi. Selain itu, untuk meningkatkan variasi data latih dan mengurangi risiko overfitting, teknik augmentasi data seperti rotasi, flip, dan zoom digunakan. Hasil konversi gambar ke skala abu-abu ditunjukkan pada Gambar 3.




Gambar 3. Hasil konversi grayscale

Setelah citra RGB diubah menjadi grayscale, hasilnya adalah pola tekstur seperti kekasaran, kontras, dan homogenitas permukaan daun dapat dihitung dengan lebih mudah pada tahap ekstraksi fitur GLCM berikutnya. Ini terjadi karena informasi warna dalam gambar grayscale dikurangi menjadi nilai intensitas piksel dalam rentang 0–255.

3.2 Ekstraksi Fitur GLCM

Metode co-occurrence matrix gray-level (GLCM) digunakan untuk mengekstraksi fitur tekstur. Metode ini menghasilkan tujuh fitur tekstur dan tiga fitur warna rata-rata RGB, sehingga total terdapat sepuluh fitur per-gambar. Gambar grafik rata-rata dapat dilihat di gambar 4.




Gambar 4. Grafik rata-rata fitur GLCM

Gambar 4, pada grafik menunjukkan perbedaan skala yang sangat signifikan antar fitur. Untuk mencegah fitur bernilai kecil tertindih oleh fitur bernilai besar selama proses pelatihan model, sangat penting untuk

melakukan normalisasi data sebelum proses klasifikasi. Nilai kontras memiliki nilai tertinggi dengan rata-rata (904,62), diikuti oleh entropy (233,93). Nilai mean_g (126,31) adalah nilai rata-rata tertinggi dari ketiga fitur warna, menunjukkan bahwa warna hijau adalah karakteristik alami daun padi. Perbedaan nilai antar kanal warna ini berfungsi sebagai fitur pembeda yang informatif untuk membedakan daun yang sehat dari daun yang sakit. Gambar korelasi antar fitur GLCM dapat dilihat di Gambar 5.

Karena model CNN memiliki kemampuan untuk secara otomatis mempelajari seberapa penting setiap fitur melalui proses pelatihan, ada redundansi di antara fitur ini, matriks berukuran (1188, 10) terdiri dari sepuluh fitur hasil ekstraksi GLCM, dengan setiap baris menampilkan satu gambar dan setiap kolom menampilkan satu fitur. Selain fitur GLCM, ekstraksi fitur juga dilakukan menggunakan arsitektur mobilenetv2, yang telah dilatih sebelumnya (pre-trained) pada kumpulan data imagenet. Model mobilenetv2 digunakan sebagai extractor fitur murni tanpa lapisan klasifikasi (no_top), sehingga bobot yang diunduh berukuran ±9,4 MB. Proses ekstraksi berjalan selama 47 detik dalam 38 batch, dan menghasilkan matriks fitur berukuran (1188, 1280), yang berarti 1.280 fitur abstrak diwakili untuk setiap.




Gambar 5. Heatmap korelasi antar fitur GLCM

Model klasifikasi menggunakan arsitektur sequential dengan lima lapisan densitas, dan memiliki mekanisme regularisasi batch normalisasi dan dropout. Model menerima 1.290 fitur berukuran besar sebagai input, dan menghasilkan output probabilitas untuk lima kelas.

3.3 Split Data


Pemisahan dataset terhadap efektifitas model klasifikasi, studi ini merancang dua skenario pengujian, yakni dengan membagi data 70:20:10 dan 80:10:10. Kedua skenario tersebut diterapkan pada model yang serupa, yaitu kombinasi ekstraksi fitur GLCM bersama mobilenetv2, sehingga perbedaan hasil yang tercapai semata-mata disebabkan oleh resio data pelatihan, validasi, dan pengujian. Hasil dari kedua skenario pengujian selanjutnya dibandingkan berdasarkan nilai akurasi dengan tujuan mengidentifikasi konfigurasi pemisahan dataset yang menghasilkan kinerja terbaik. Perbandingan akurasi model dapat dilihat di gambar 6.



Gambar 6. Perbandingan akurasi model


Grafik yang ditampilkan di atas memperlihatkan perbandingan tingkat ketepatan model klasifikasi untuk penyakit daun bawang merah dalam dua skenario distribusi dataset, yaitu 70:20:10 dan 80:10:10. Dari hasil pengujian yang dilakukan, pembagian 70:20:10 menghasilkan tingkat ketepatan sebesar 93,00%, sedangkan pembagian 80:10:10 memperoleh tingkat ketepatan sebesar 90,76%

Temuan ini menunjukkan bahwa pembagian 70:20:10 memberikan kinerja yang lebih unggul dibandingkan dengan pembagian 80:10:10, dengan perbedaan ketepatan mencapai 2,24%. Hal ini menunjukkan bahwa penyediaan lebih banyak data untuk validasi dalam skenario 70:20:10 berkontribusi pada proses pelatihan dalam memantau dan memperbaiki daya kerja model, sehingga model dapat beradaptasi dengan data uji dengan lebih baik. Di sisi lain, meskipun skenario 80:10:10 menawarkan lebih banyak data untuk pelatihan, jumlah data validasi yang lebih sedikit mengakibatkan evaluasi selama pelatihan menjadi kurang efektif, sehingga menyebabkan penurunan sedikit pada akurasi data uji. Gambar perbandingan jumlah dataset dapat dilihat di gambar 7.



Gambar 7. Perbandingan jumlah dataset

Menampilkan perbandingan jumlah dataset dalam dua situasi pembagian data, yaitu 70:20:10 dan 80:10:10. Dalam situasi 70:20:10, dataset terdiri dari 832 gambar untuk pelatihan, 119 gambar untuk validasi, dan 237 gambar untuk pengujian. Di sisi lain, pada situasi 80:10:10, jumlah data untuk pelatihan meningkat menjadi 950 gambar, sementara jumlah data untuk validasi dan pengujian tetap masing-masing 119 gambar. Variasi dalam pembagian dataset ini dimanfaatkan untuk mengevaluasi dampak proporsi data pelatihan, validasi, dan pengujian terhadap kinerja model klasifikasi pada penyakit daun bawang merah. Gambar perbandingan hasil evaluasi model dapat dilihat di gambar 8.



Gambar 8. Perbandingan hasil evaluasi model

Menampilkan perbandingan volume dataset dalam dua kondisi pemisahan data, yakni 70:20:10 dan 80:10:10. Dalam kondisi 70:20:10, terdapat 832 gambar untuk pelatihan, 119 gambar untuk validasi, dan 237 gambar untuk pengujian. Di sisi lain, pada kondisi 80:10:10, jumlah gambar untuk pelatihan meningkat jadi 950, sedangkan jumlah gambar untuk validasi dan pengujian masing-masing tetap 119. Perbedaan dalam pembagian dataset ini bertujuan untuk mengevaluasi dampak proporsi data pelatihan, validasi, dan pengujian terhadap kinerja model klasifikasi untuk penyakit daun bawang merah.

3.4 MobileNetV2

Fitur GLCM, ekstraksi fitur juga dilakukan menggunakan arsitektur mobilenetv2, yang telah dilatih sebelumnya (pre-trained) pada kumpulan data imagenet. Model mobilenetv2 digunakan sebagai extractor fitur murni tanpa lapisan klasifikasi (no_top), sehingga bobot yang diunduh berukuran $\pm 9,4$ MB. Proses ekstraksi berjalan selama 47 detik dalam 38 batch, dan menghasilkan matriks fitur berukuran (1188, 1280), yang berarti 1.280 fitur abstrak diwakili untuk setiap.

3.5 Penggabungan Fitur

Selanjutnya, dua matriks fitur digabungkan menjadi satu matriks fitur tunggal, seperti yang ditunjukkan dalam tabel 3.

Tabel 3. Tabel matriks fitur tunggal

Aktual / Prediksi	Embun Bulu	Sehat	Hawar Daun	Moler	Bercak Ungu	Total
Embun bulu	43	1	2	1	0	47
Sehat	1	35	4	0	1	41
Hawar daun	1	1	46	0	3	51
Moler	0	0	0	60	0	60
Bercak ungu	0	0	1	0	38	39
Total	45	37	35	61	42	238

Kelas moler melakukan pekerjaan sempurna karena seluruh 60 sampel diprediksi dengan benar tanpa kesalahan. Kesalahan prediksi terbesar terjadi pada kelas sehat (6 sampel salah klasifikasi), terutama di kelas hawar daun. Ini mungkin disebabkan oleh fakta bahwa pada tahap awal infeksi, daun sehat terlihat sama dengan daun yang baru terinfeksi. Tabel prediksi terbanyak yang terjadi pada kelas dapat dilihat di Tabel 4.


Tabel 4. prediksi terbanyak terjadi pada kelas sehat

Kelas	Precision	Recall	FI-Score	Support
Bercak ungu	0.96	0.91	0.93	47
Embun bulu	0.95	0.85	0.90	41
Hawar daun	0.87	0.90	0.88	51
Moler	0.98	1.00	0.99	60
Sehat	0.90	0.97	0.94	39
Accuracy			0.93	238
Macro avg	0.93	0.93	0.93	239
Weighted avg	0.93	0.93	0.93	238

Metode hybrid ini bertujuan untuk memanfaatkan kelebihan kedua metode secara bersamaan, fitur GLCM mengambil karakteristik tekstur yang jelas dan terukur, sementara fitur MobileNetV2 mengambil representasi visual abstrak tingkat tinggi yang dipelajari dari jutaan gambar.

3.6 Implementasi Hasil Tekstur CNN

kurang lebih 73 epoch. Dua kurva ditampilkan untuk menunjukkan seberapa baik model belajar dari data dan seberapa baik mereka dapat menggeneralisasi data yang belum pernah terlihat sebelumnya. Gambar grafik accuracy dapat di lihat di gambar 9/




Gambar 9. Grafik accuracy

Dari grafik yang ditampilkan, terlihat bahwa pada awal epoch, baik untuk akurasi pelatihan maupun validasi mengalami peningkatan yang pesat, dari sekitar 0,2-0,4 hingga mendekati 0,8 hanya dalam 10-15 epoch pertama. Setelah fase tersebut, laju peningkatan menjadi lebih lambat dan kedua grafik mulai menunjukkan kestabilan

(plateau) dari sekitar epoch ke-45 hingga 50, dengan akurasi pelatihan mencapai sekitar 0,96 dan akurasi validasi berada di kisaran 0,87-0,88. Perbedaan (gap) yang muncul antara grafik pelatihan dan validasi yang stabil di angka sekitar 0,08-0,1 menunjukkan adanya indikasi overfitting yang ringan, di mana model cenderung lebih mahir dalam mengingat data pelatihan dibandingkan dengan dapat menerapkan pengetahuan tersebut pada data baru. Namun, karena selisihnya cukup kecil dan tidak menunjukkan pelebaran yang signifikan menjelang akhir pelatihan, situasi ini masih dapat diterima, dan secara keseluruhan, model menunjukkan kinerja yang baik dengan proses pelatihan yang konvergen (stabil), yang tidak mengindikasikan adanya overfitting yang serius.

Selain ketepatan, grafik di bawah ini menunjukkan nilai kehilangan (fungsi kerugian) selama proses pelatihan untuk data tambahan dan validasi dalam rentang epoch yang serupa. Nilai kehilangan yang lebih rendah menunjukkan bahwa model melakukan prediksi dengan kesalahan yang lebih sedikit, sehingga grafik ini berfungsi untuk melengkapi grafik ketepatan yang sebelumnya ditampilkan untuk mengevaluasi kondisi model secara lebih menyeluruh. Gambar accuracy loss dapat dilihat di gambar 10.




Gambar 10. Accuracy loss

Pada diagram ini, kerugian pelatihan mengalami penurunan drastis dari sekitar 2,2 di awal menjadi sekitar 0,5 pada epoch ke-25, kemudian terus berkurang secara perlahan hingga mencapai sekitar 0,15 di akhir proses pelatihan. Kerugian validasi juga menunjukkan penurunan dengan pola yang sama di awal, dari sekitar 1,45 menuju sekitar 0,35 di epoch ke-30, tetapi setelah itu laju penurunannya melambat dan cenderung stabil (plateau) di kisaran 0,3 hingga pelatihan selesai.

Mulai dari sekitar epoch ke-30, tampak adanya jarak yang konsisten antara kedua grafik, di mana kerugian pelatihan terus menurun sementara kerugian validasi relatif datar. Pola ini sejalan dengan grafik akurasi sebelumnya dan menguatkan indikasi bahwa terdapat sedikit overfitting, di mana model semakin efisien dalam mengoptimalkan data pelatihan, tetapi peningkatan pada data validasi tampaknya sudah mencapai batas. Meskipun demikian, karena kerugian validasi tidak menunjukkan kenaikan kembali (tanpa tanda divergensi), pelatihan secara keseluruhan masih berlangsung stabil dan model belum menunjukkan tanda-tanda overfitting yang signifikan.

3.7 Confusion Matriks

Menyelesaikan penilaian model, di bawah ini disajikan matriks kebingungan yang memperbandingkan label sebenarnya dengan hasil prediksi model dalam 5 kategori (0 sampai 4). Matriks ini berguna untuk mengidentifikasi secara mendalam kategori mana yang diprediksi dengan akurat dan kategori mana yang sering salah diidentifikasi dengan kategori lainnya, sesuatu yang tidak dapat diketahui hanya dengan melihat nilai akurasi secara keseluruhan. Gambar confusion matrix dapat dilihat di gambar 3.6.



Gambar 11. Confusion Matrix

Dari matriks kebingungan, tampak bahwa sebagian besar ramalan terletak di sepanjang garis diagonal utama, yang menunjukkan bahwa model umumnya berkinerja cukup memuaskan. Kelas 3 mencapai hasil terbaik, di mana semua 60 sampel berhasil dikenali dengan akurat tanpa adanya kesalahan. Kelas 2 dan kelas 0 juga menampakkan performa yang positif, dengan masing-masing 46 dan 43 prediksi yang akurat serta hanya sedikit kesalahan yang diberikan kepada kelas lain. Kelas 1 memiliki tingkat kesalahan tertinggi secara relatif, dari 41 sampel yang ada, hanya 35 yang diidentifikasi dengan benar, sementara 4 sampel salah masuk ke dalam kelas 2 dan masing-masing 1 sampel diidentifikasi tidak tepat sebagai kelas 0 dan kelas 4. Ini menunjukkan bahwa kelas 1 dan kelas 2 memiliki sifat yang mirip sehingga sering menimbulkan kebingungan bagi model. Kelas 4 juga menunjukkan performa baik dengan 38 dari 39 sampel yang berhasil diidentifikasi secara akurat.

3.8 Implementasi Sistem

Tahap terakhir dari riset adalah penerapan model yang sudah dilatih ke dalam suatu sistem untuk melakukan prediksi. Model tersebut diuji dengan memberikan satu gambar baru yang belum pernah dikenali sebelumnya oleh model. Grafik di bawah ini menunjukkan perkembangan akurasi model selama proses pelatihan (training) sebanyak. Gambar implementasi sistem dapat dilihat di Gambar 12.



Gambar 12. hasil Prediksi


Berdasarkan ilustrasi gambar 12. dari pengujian yang telah dilaksanakan, sistem berhasil mengidentifikasi citra uji sebagai kategori moler dalam durasi 49 milidetik. Hasil identifikasi ditampilkan secara langsung pada citra, memudahkan pengguna dalam memahami hasil dari sistem. Citra yang diuji menampilkan batang padi yang melilit dengan warna hijau muda kekuningan yang merupakan tanda khas dari infeksi moler akibat jamur fusarium moniliforme dan dikenali dengan akurasi tinggi oleh model tersebut. Kecepatan inferensi yang tercatat sebesar 49 ms per citra menunjukkan bahwa sistem ini mampu melakukan prediksi secara langsung, dengan kapasitas untuk memproses sekitar ± 20 citra dalam satu detik. Hal ini menjadikan sistem ini sangat cocok untuk diterapkan sebagai aplikasi deteksi penyakit pada daun padi, baik dalam bentuk web maupun mobile, yang bisa langsung digunakan di lapangan oleh petani maupun konsultan pertanian.

3.9 Pembahasan

Penelitian ini menerapkan dua skenario pemisahan dataset guna menilai dampak pemecahan data terhadap performa model klasifikasi. Skenario yang diterapkan terdiri dari 70% untuk instruksi, 20% untuk validasi, dan 10% untuk pengujian, serta 80% untuk instruksi, 10% untuk validasi, dan 10% untuk pengujian. Pendekatan yang serupa digunakan untuk menguji kedua skenario: ekstraksi fitur dari GLCM dan mobilenetv2, yang kemudian diklasifikasikan dengan menggunakan convolutional neural network (CNN). Analisis ini dilakukan untuk menilai kemampuan model dalam mengenali pola penyakit pada daun bawang merah dan untuk menguji seberapa efektif model dapat digunakan pada data yang tidak pernah dimanfaatkan selama proses pelatihan. Selanjutnya, hasil evaluasi dari masing-masing skenario dibandingkan berdasarkan tingkat akurasi, kehilangan, dan kinerja klasifikasi yang diperoleh. Langkah ini diambil untuk menemukan pemisahan data yang paling optimal untuk penelitian ini.

Berdasarkan penelitian yang telah dilaksanakan, pendekatan hibrida yang menyatukan ekstraksi ciri dari Gray Level Co-occurrence Matrix (GLCM) serta MobileNetV2 berhasil memberikan hasil klasifikasi yang memuaskan untuk lima kategori penyakit pada daun bawang merah, yakni embun bulu, sehat, hawar daun, moler, dan bercak ungu. Pengujian menunjukkan bahwa model ini mencapai akurasi 93%, dengan nilai precision, recall, dan F1-score yang cukup tinggi di semua kategori. Kategori moler menunjukkan kinerja terbaik dengan recall mencapai 1,00 dan F1-score 0,99, yang menunjukkan bahwa semua gambar dalam kategori ini berhasil diklasifikasikan dengan tepat. Namun, kesalahan klasifikasi masih terdeteksi dalam kategori sehat dan hawar daun, karena kedua kategori tersebut memiliki ciri visual yang hampir serupa di tahap awal infeksi, sehingga menyulitkan model untuk membedakan di antara keduanya.

Temuan dari penelitian ini mengindikasikan bahwa penerapan metode hibrida menawarkan performa yang lebih unggul dibandingkan dengan hanya menggunakan satu jenis fitur saja. Ciri tekstur yang diekstraksi dari



GLCM dapat menggambarkan karakteristik permukaan daun, seperti tingkat kontras, homogenitas, energi, dan dissimilarity, sedangkan MobileNetV2 berperan dalam mengekstraksi fitur visual tingkat tinggi melalui proses transfer learning. Kombinasi kedua jenis fitur ini menghasilkan representasi data yang lebih komprehensif sehingga mampu meningkatkan keahlian model dalam membedakan setiap kategori penyakit.


Penelitian Mohammad Fathor Rosi dan Bakhtiyar Hadi Prakoso (2020), yang menggunakan metode Certainty Factor dan memperoleh akurasi 85,71%, menunjukkan peningkatan yang cukup signifikan dalam kinerja. Ini karena metode Certainty Factor bergantung pada aturan dan pengetahuan pakar, sedangkan CNN dengan MobileNetV2 dapat mempelajari pola penyakit secara otomatis dari data citra, menghasilkan kemampuan klasi

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa kombinasi metode gray level co-occurrence matrix (GLCM) dan mobilenetv2 dengan klasifikasi menggunakan convolutioneural network (CNN) mampu mengidentifikasi penyakit daun bawang merah dengan kinerja yang baik. Model yang dibangun berhasil mengklasifikasikan lima kelas penyakit menggunakan dataset sebanyak 1.188 citra dengan akurasi pengujian sebesar 93%, serta nilai rata-rata precision, recall, dan fi-score sebesar 93%. Hasil tersebut menunjukkan bahwa penggabungan fitur tekstur dari GLCM dan fitur visual dari mobileNetV2 mampu menghasilkan representasi citra yang lebih informatif sehingga meningkatkan kemampuan model dalam membedakan berbagai jenis penyakit daun bawang merah. Meskipun masih ada sedikit kesalahan klasifikasi pada kelas yang memiliki karakteristik visual mirip, model secara keseluruhan menunjukkan kemampuan generalisasi yang baik dan layak dikembangkan lebih lanjut sebagai dasar sistem deteksi penyakit tanaman bawang merah yang berbasis kecerdasan buatan. Menghasilkan model klasifikasi penyakit daun bawang merah menggunakan kombinasi fitur GLCM dan MobileNetV2 menggunakan CNN adalah kontribusi dari penelitian ini. Teknik yang disarankan, yang memiliki akurasi sebesar 93%.

REFERENCES

- [1] H. E. Kim, A. Cosa-Linan, N. Santhanam, M. Jannesari, M. E. Maros, and T. Ganslandt, "Transfer learning for medical image classification: a literature review," *BMC Med Imaging*, vol. 22, no. 1, pp. 1–13, 2022, doi: 10.1186/s12880-022-00793-7.
- [2] Q. Zhu, H. Zhuang, M. Zhao, S. Xu, and R. Meng, "A study on expression recognition based on improved MobileNetV2 network," *Sci Rep*, vol. 14, no. 1, pp. 1–11, 2024, doi: 10.1038/s41598-024-58736-x.
- [3] X. Lu and Y. A. F. A. Z. Zadeh, "Deep Learning-Based Classification for Melanoma Detection Using XceptionNet," *J Healthc Eng*, vol. 2022, pp. 14–16, 2022, doi: 10.1155/2022/2196096.
- [4] R. Indraswari, R. Rokhana, and W. Herulambang, "Melanoma image classification based on MobileNetV2 network," *Procedia Comput Sci*, vol. 197, pp. 198–207, 2021, doi: 10.1016/j.procs.2021.12.132.
- [5] R. O. Ogundokun et al., "Enhancing Skin Cancer Detection and Classification in Dermoscopic Images through Concatenated MobileNetV2 and Xception Models," *Bioengineering*, vol. 10, no. 8, p. 979, 2023, doi: 10.3390/bioengineering10080979.
- [6] H. Nhut Huynh, M. Thanh Do, G. T. Huynh, A. T. Tran, and T. N. Tran, "Classification of Stages Diabetic Retinopathy Using MobileNetV2 Model Kalpa Publications in Engineering," *Kalpa Publications in Engineering*, vol. 4, pp. 147–157, 2022.
- [7] M. Akay et al., "Deep Learning Classification of Systemic Sclerosis Skin Using the MobileNetV2 Model," *IEEE Open J Eng Med Biol*, vol. 2, pp. 104–110, 2021, doi: 10.1109/OJEMB.2021.3066097.
- [8] S. Velu, "An efficient, lightweight MobileNetV2-based fine-tuned model for COVID-19 detection using chest X-ray images," *Mathematical Biosciences and Engineering*, vol. 20, no. 5, pp. 8400–8427, 2023, doi: 10.3934/mbe.2023368.
- [9] O. Ozaltin and O. Yeniay, "Detection of Monkeypox Disease from Skin Lesion Images using MobileNetV2 Architecture," *Communications Faculty Of Science University of Ankara Series A1: Mathematics and Statistics*, vol. 72, no. 2, pp. 482–499, 2023, doi: 10.31801/cfsuasmas.1202806.
- [10] W. Asmalinda, D. Setiawati, Jasmi, K. Khotimah, and E. Sapada, "DETEKSI DINI KANKER PAYUDARA MENGGUNAKAN DETECTION OF BREAST CANCER USING BREAST SELF-," *Jurnal Abdikemas*, vol. 4, no. 1, pp. 10–17, 2022.
- [11] S. Syefudin, M. N. Azmi, and G. Gunawan, "Analisis Pengaruh Dimensi Gambar Pada Klasifikasi Motif Batik Dengan Menggunakan Convolutional Neural Network," *Jurnal Sistem Informasi dan Informatika (Simika)*, vol. 6, no. 2, pp. 190–198, 2023, doi: 10.47080/simika.v6i2.2675.
- [12] V. Miftahuljannah and A. Suharso, "Pengimplementasian Berbagai Web Berdasarkan Kebutuhan Pengguna Dengan Menggunakan Metode Systematic Literature Review," *INFOTECH journal*, vol. 9, no. 2, pp. 401–405, 2023, doi: 10.31949/infotech.v9i2.6341.
- [13] L. Setiyani and B. Setiawan, "Analisis Dan Design Manajemen Control Produksi Menggunakan Business Process Improvement Dan Unified Modelling Language (Studi Kasus: Pt. Multistrada)," *Jurnal Interkom: Jurnal Publikasi Ilmiah Bidang Teknologi Informasi dan Komunikasi*, vol. 16, no. 01, pp. 27–37, 2021.
- [14] Haryanto, "Analisis Big Data Dan Artificial Intelligence (AI): Dalam Industri Khususnya Prediksi Penyakit Jantung Dengan Phytion," *GO INFOTECH: JURNAL ILMIAH STMIK AUB*, Vol. 30, No. 1, Pp. 76–86, 2024, Doi: 10.36309/Goi.V30i1.262.
- [15] E. Irawan, Moh. K. Huda, And R. Purwasih, "A Learning Trajectory For Developing Computational Thinking In



- Prospective Mathematics Teachers Through Python Programming In Google Colab,” *Alifmatika: Jurnal Pendidikan Dan Pembelajaran Matematika*, Vol. 7, No. 1, Pp. 34–52, 2025, Doi: 10.35316/Alifmatika.2025.V7i1.34-52.
- [16] S. Samrat. Medavarapu, “Advancements In Deep Learning: A Review Of Keras And Tensorflow Frameworks,” *Journal Of Scientific And Engineering Research*, Vol. 11, No. 5, Pp. 282–286, 2024.
- [17] M. Z. U. Rehman, F. Ahmed, S. A. Alsuhbany, S. S. Jamal, M. Z. Ali, And J. Ahmad, “Classification Of Skin Cancer Lesions Using Explainable Deep Learning,” *Sensors*, Vol. 22, No. 18, Pp. 1–14, 2022, Doi: 10.3390/S22186915.
- [18] S. K. E. Putri, F. H. Adiba, And A. K. Sari, “Implementasi Algoritma Cnn Dalam Pengenalan Wajah Menggunakan VGG16,” *PROSIDING SEMINAR TEKNOLOGI DAN SAINS*, Vol. 4, Pp. 618–623, 2025.
- [19] M. A. Rahman, M. B. A. Miah, M. A. Hossain, and A. S. M. S. Hosen, “Enhanced Brain Tumor Classification Using MobileNetV2: A Comprehensive Preprocessing and Fine-Tuning Approach,” *BioMedInformatics*, vol. 5, no. 2, pp. 1–33, 2025, doi: 10.3390/biomedinformatics5020030.
- [20] E. Miranda and M. Aryuni, “Klasifikasi Tutupan Lahan Menggunakan Convolutional Neural Network pada Citra Satelit Sentinel-2,” *Jurnal Sistem Informasi*, vol. 10, no. 2, pp. 323–335, 2021.
- [21] M. D. Gustinov et al., “Analysis of Web-Based E-Commerce Testing Using Black Box and White Box Methods,” *International Journal of Information System and Innovation Management*, vol. 1, no. 1, pp. 20–31, 2023.