

IDENTIFIKASI PENYAKIT DAUN DURIAN MENGGUNAKAN PENERAPAN ALGORITMA RESIDUAL NETWORK (RESNET-50)

Arga Satria Ramadhan¹, Yunianita Rahmawati^{2*}, Ika Ratna Indra Astutik³, Sumarno⁴

Program Studi Teknik Informatika, Universitas Muhammadiyah Sidoarjo

*yunianita@umsida.ac.id

Abstrak

Durian merupakan salah satu komoditas hortikultura unggulan di Indonesia, namun produktivitasnya dapat menurun akibat penyakit daun yang sulit dikenali secara visual oleh petani. Penelitian ini bertujuan mengembangkan sistem klasifikasi otomatis penyakit daun durian menggunakan algoritma deep learning dengan arsitektur ResNet-50. Dataset yang digunakan terdiri dari 420 citra daun durian dalam empat kelas: *Algal Leaf Spot*, *Leaf Blight*, *Leaf Spot*, dan *No Disease*, yang diperoleh dari Roboflow. Proses pra-pemrosesan mencakup anotasi, augmentasi, dan normalisasi ukuran citra menjadi 240x240 piksel. Model dilatih menggunakan TensorFlow dengan bobot awal dari ImageNet. Tiga skenario pembagian data (70:20:10, 75:15:10, dan 80:10:10) digunakan dalam pendekatan klasifikasi biner dan multikelas. Evaluasi dilakukan menggunakan confusion matrix dan metrik seperti akurasi, presisi, recall, dan F1-score. Hasil terbaik pada klasifikasi biner menunjukkan akurasi 99,8% dan F1-score 99,9%, sedangkan pada klasifikasi multikelas dicapai akurasi 99,6% dan macro F1-score 96,9%. Hasil ini menunjukkan bahwa ResNet-50 efektif dalam mendeteksi penyakit daun durian secara akurat dan dapat diimplementasikan dalam aplikasi mobile sebagai alat bantu diagnosis dini bagi petani.

Kata kunci : daun durian, klasifikasi penyakit, ResNet-50, deep learning, Roboflow

Durian is one of Indonesia's leading horticultural commodities, but its productivity can decline due to leaf diseases that are difficult for farmers to identify visually. This study aims to develop an automated durian leaf disease classification system using a deep learning algorithm based on the ResNet-50 architecture. The dataset consists of 420 durian leaf images classified into four categories: *Algal Leaf Spot*, *Leaf Blight*, *Leaf Spot*, and *No Disease*, collected from the Roboflow platform. Preprocessing steps included annotation, augmentation, and resizing the images to 240x240 pixels. The model was trained using TensorFlow with pretrained ImageNet weights. Three data split scenarios (70:20:10, 75:15:10, and 80:10:10) were applied using both binary and multiclass classification approaches. Model performance was evaluated using confusion matrix and metrics such as accuracy, precision, recall, and F1-score. The best binary classification result achieved 99.8% accuracy and 99.9% F1-score, while the best multiclass result achieved 99.6% accuracy and 96.9% macro F1-score. These results demonstrate that ResNet-50 is effective in accurately detecting durian leaf diseases and can be implemented in mobile applications to assist farmers in early diagnosis and improving crop productivity.

Keywords: durian leaf, disease classification, ResNet-50, deep learning, Roboflow

1. PENDAHULUAN

Durian (*Durio zibethinus* Murr.) adalah tanaman tropis yang berasal dari Asia Tenggara dan terkenal sebagai buah yang khas salah satu komoditas hortikultura. Di Indonesia, terdapat lebih dari 55 jenis durian, baik yang berasal dari dalam negeri maupun impor. Sementara itu, durian impor memiliki lebih dari 123 jenis, yang sebagian besar berasal dari Malaysia [1]. Durian biasanya ditanam di pekarangan bersama dengan tanaman lainnya. Daun durian umumnya memiliki bentuk memanjang dengan ujung runcing. Daun ini tumbuh secara berseling dan soliter. Selain itu, daun durian memiliki tekstur yang tebal, dengan permukaan bagian atas berwarna hijau cerah, sementara bagian bawahnya berwarna coklat atau kuning keemasan [2]. Keterbatasan jumlah tenaga pengamat hama dan penyakit menjadi kendala dalam upaya pengendalian hama dan penyakit tanaman. Pada tanaman durian, gejala penyakit dapat dikenali melalui perubahan yang terjadi pada daunnya. Infeksi yang disebabkan oleh jamur, bakteri, atau virus sering kali memunculkan pola atau bercak tertentu. Kesehatan tanaman durian sangat berpengaruh terhadap kualitas buah pada durian. Namun, tidak semua petani memiliki kemampuan untuk mengidentifikasi tanda-tanda tersebut. Akibatnya, mereka kerap terlambat menyadari bahwa tanaman mereka sebenarnya sudah terinfeksi, karena mengira kondisinya masih sehat. Beberapa, jenis penyakit pada tanaman yang sering menyerang durian antara lain bercak daun, hawar daun, jamur upas, kanker batang, busuk akar, dan busuk buah [3].


Dalam upaya identifikasi dan klasifikasi varietas tanaman berdasarkan pola daun, telah banyak dilakukan penelitian sebelumnya, di antaranya penelitian mengenai Identifikasi Taslim [4] melakukan upaya untuk mengenali daun mangga, akasia, rambutan, pepaya, dan cherry menggunakan CNN dengan arsitektur ResNet-50, dan berhasil mencapai tingkat akurasi lebih dari 98%. Namun, akurasi tersebut menurun ketika terdapat latar belakang yang mengganggu. Sedangkan, Febriana [5] penyakit pada daun apel menggunakan ResNet 50 Dilated Convolutional Neural Network dengan 875 data uji menghasilkan akurasi Sementara itu, untuk dataset yang terdiri dari 200 data uji, akurasi yang diperoleh adalah 81%, presisi 84%, dan recall 81%. Resnet-50 merupakan bagian dari CNN sebagai referensi penelitian ini, [6] Jia-Rong Hasil menunjukkan ResNet-50 menunjukkan kinerja terbaik dalam klasifikasi dengan nilai akurasi di atas 80%. Dalam penelitian ini penggunaan ResNet-50 untuk mengklasifikasikan penyakit pada tanaman strawberry menghasilkan akurasi 100% untuk kasus pada pucuk, daun, dan buah, serta akurasi sebesar 98% untuk infeksi jamur abu-abu dan 98% untuk jamur tepung. Kemudian, [7] Charisa Nur Sahera Hasil terbaik diperoleh dengan mengatur parameter secara optimal, yang menghasilkan akurasi tertinggi sebesar 98,50% pada model dengan 10 epoch dan learning rate sebesar 0,001. Penerapan metode klasifikasi menggunakan CNN dengan optimizer ADAM terbukti sangat efektif dalam mengenali dan mengklasifikasikan tingkat kesegaran pada gambar daging sapi.

Deep learning adalah cabang khusus dari machine learning yang berfokus pada pembelajaran representasi data melalui beberapa lapisan (layer) bertahap, dengan setiap lapisan menghasilkan representasi yang semakin bermakna [8]. Deep learning sering dimanfaatkan untuk mengklasifikasi objek dari citra atau gambar dengan mempelajari

representasi atau fitur data secara otomatis [9] . Convolutional Neural Network (CNN) merupakan jenis neural network yang sering digunakan untuk mengolah data citra. CNN dapat dimanfaatkan untuk mendeteksi dan mengenali objek dalam sebuah gambar [10] . ResNet-50 menggunakan shortcut connections yang memungkinkan fitur dari lapisan sebelumnya diteruskan ke lapisan berikutnya. Hal ini membantu mengurangi kehilangan fitur penting selama proses konvolusi, sehingga jaringan tetap efektif meskipun sangat dalam [11] .Maka penanganan penyakit daun tanaman perlu dilakukan dengan cepat. Oleh sebab itu, untuk menyelesaikan hal tersebut Resnet-50 sangat penting untuk mengidentifikasi penyakit daun sebagai langkah awal . Agar identifikasi penyakit daun durian lebih mudah dilakukan, Resnet-50 diterapkan dalam bentuk aplikasi Android yang dapat diinstal pada smartphone . Namun, yang dijadikan objek uji hanya terbatas pada penyakit yang menyerang daun durian .

2. METODOLOGI PENELITIAN

Penelitian ini bertujuan untuk mengidentifikasi penyakit pada daun tanaman durian dengan memanfaatkan Roboflow sebagai alat bantu dalam pemrosesan data, serta mengintegrasikan model ResNet-50 sebagai model dasar dalam sistem deteksi. Pemilihan metode ini didasarkan pada kemampuannya dalam memberikan hasil deteksi yang cepat dan akurat. Adapun metodologi penelitian ini terdiri atas beberapa tahapan yang divisualisasikan pada Gambar 1.



Gambar 1. Tahapan Penelitian

Penjelasan terkait gambar tahapan diatas dapat dirinci sebagai berikut.

2.1. Pengumpulan Data

Penelitian ini memanfaatkan data citra daun durian yang diperoleh melalui platform daring Roboflow. Roboflow merupakan sebuah platform yang menyediakan berbagai dataset untuk kebutuhan pemrosesan citra (computer vision). Dalam studi ini, dataset yang digunakan terdiri dari empat kategori citra daun durian yang mengalami infeksi berbagai jenis penyakit, yaitu *Algal Leaf Spot*, *Leaf Blight*, *Leaf Spot*, dan *No Disease*. Masing-masing kategori memiliki 420 citra daun berwarna (RGB) dalam format file JPG. Setelah proses pengumpulan citra selesai, dataset penyakit daun durian kemudian disusun menggunakan platform Roboflow, seperti yang ditampilkan pada Gambar 2.



Gambar 2. Pengumpulan Dataset

2.2. Pra-Pemrosesan Data

Pra-pemrosesan data merupakan tahap penting yang harus dilakukan sebelum model dilatih dan dievaluasi. Langkah awal dalam proses ini adalah membagi data menjadi beberapa subset. Dalam penelitian ini, dilakukan beberapa skenario pembagian dataset. Terdapat tiga skenario percobaan yang diterapkan berdasarkan persentase pembagian data ke dalam *train set*, *validation set*, dan *test set* ditampilkan pada table 1.

Tabel 1. Skenario Split Data

Skenario	Pembagian Data		
	Train Set	Valid Set	Test Set
70:20:10	292	84	44
75:15:10	314	62	44
80:10:10	334	44	43

Pada tahap berikutnya, dilakukan proses anotasi data dengan memberikan label berbentuk *bounding box* pada objek dalam citra. Setiap gambar dilengkapi dengan informasi kelas, koordinat, serta ukuran objek menggunakan platform Roboflow, yang dirancang untuk mendukung efisiensi dalam pengelolaan dataset, modifikasi format gambar, dan pemanfaatan data secara optimal [12]. Tahapan *preprocessing* pada platform ini mencakup penerapan teknik *Auto-Orient* untuk menyeragamkan orientasi citra dalam dataset dan

menghapus informasi EXIF. Hal ini penting karena perbedaan orientasi gambar dapat menghambat efektivitas pelatihan model [13]. Untuk memastikan keseragaman dimensi, setiap citra diubah ukurannya menjadi 240 x 240 piksel, sehingga dapat mempercepat proses pelatihan. Selain itu, digunakan *Filter Null* untuk mengeliminasi data yang mengandung nilai *null* atau citra tanpa objek, guna memastikan hanya data relevan yang digunakan dalam pelatihan dan meningkatkan kualitas dataset. Setelah tahap *preprocessing*, dilakukan augmentasi data, yakni proses untuk memperbanyak dan memperkaya variasi data melalui teknik seperti pembalikan horizontal (*horizontal flipping*), pemangkasan (*cropping*), dan rotasi.

2.3 Pelatihan Model Resnet-50

Tahapan pemodelan dilakukan dengan memanfaatkan dataset yang telah diproses sebelumnya menggunakan platform Roboflow. Platform ini menyediakan fitur ekspor dataset yang menghasilkan file *data.yaml* dengan format yang sesuai untuk digunakan langsung pada model Resnet-50. Proses ekspor ini dapat dilakukan melalui API, sehingga memungkinkan dataset langsung siap digunakan untuk pelatihan pada platform seperti Google Colab. Konfigurasi pelatihan dilakukan secara bertahap dengan tujuan untuk mengoptimalkan kinerja model. Tabel 2 menampilkan sejumlah parameter penting yang memengaruhi performa model, termasuk pembagian data (*split data*), ukuran gambar (*image size*), ukuran *batch*, jumlah *epoch*, sumber data, serta bobot awal (*weight*) yang digunakan.

Tabel 2. Konfigurasi Training

Parameter	Nilai
<i>Split Data</i>	70:20:10,75:15:10,80:10:10
<i>Image Size</i>	240 x 240
<i>Batch Size</i>	32
<i>Epoch</i>	25, 50
<i>Data Source</i>	Data.yaml
<i>Weight</i>	Imagenet
<i>TensorFlow</i>	Resnet-50.h5

Tabel di atas menyajikan konfigurasi pelatihan model Resnet-50, yang mencakup variasi pembagian data (**70:20:10,75:15:10,80:10:10**) antara data latih, validasi, dan uji,

guna mengoptimalkan performa model. Gambar daun durian disesuaikan pada resolusi 240 x 240 piksel untuk mencapai keseimbangan antara efisiensi komputasi dan akurasi. *Batch size* sebesar 32 digunakan untuk menjaga kestabilan proses pelatihan. Model dilatih selama 25 hingga 50 *epoch* agar dapat mencapai konvergensi secara optimal. Dataset dimuat melalui file data.yaml yang sebelumnya diekspor dari Roboflow, dan pelatihan dimulai dengan bobot awal dari ImageNet untuk mempercepat proses dan meningkatkan akurasi. Hasil akhir dari pelatihan ini disimpan dalam format .h5, yang kompatibel.

2.4 Perhitungan Hasil dengan Confusion Matrix

Setelah melakukan *training* dan *testing* maka Langkah berikutnya dalam evaluasi model adalah menghitung *confusion matrix*, yang merupakan metode untuk menilai performa model klasifikasi dalam machine learning, baik untuk dua kelas maupun lebih [14]. Confusion matrix memuat empat komponen utama yang menggambarkan hasil klasifikasi, yaitu *true positive*, *true negative*, *false positive*, dan *false negative*. Berdasarkan keempat komponen ini, dilakukan penghitungan metrik evaluasi model seperti *akurasi*, *presisi*, *recall*, *specificity*, dan *F1-Score* untuk kasus klasifikasi biner [15]. Sementara itu, untuk kasus klasifikasi multikelas, evaluasi dilakukan dengan menghitung *akurasi*, *rata-rata makro presisi*, *rata-rata makro recall*, dan *rata-rata makro F1-Score* [16].

$$Accuracy = \frac{TP + TN}{TP + TN + FNF} * 100\% \quad (1)$$

$$Precision = \frac{TP}{TP + FP} * 100\% \quad (2)$$

$$Recall = \frac{TP}{TN + FP} * 100\% \quad (3)$$

$$Specificity = \frac{TN}{TN + FP} * 100\% \quad (4)$$

$$F1\ Score = \frac{2 * (Recall * Precision)}{(Recall + Precision)} * 100\% \quad (5)$$

Keterangan:

TP: *True Positive*

TN: *True Negative*

FP: *False Positive*

FN: *False Negative*

Dalam evaluasi kinerja pada kasus klasifikasi multikelas, pengukuran specificity tidak digunakan. Namun, untuk memperoleh nilai precision, recall, dan f1-score, perlu dilakukan perhitungan rata-rata menggunakan metode macro average. Metode ini menghitung total nilai masing-masing metrik untuk setiap kelas, kemudian membaginya dengan jumlah total kelas yang dianalisis. Rumus perhitungan akurasi dan rata-rata metrik lainnya ditunjukkan

pada formula berikut.

$$Accuracy = \frac{\text{Jumlah Prediksi yang benar}}{\text{Jumlah seluruh prediksi}} 100\% \quad (6)$$

$$MAP = \sum_{k=1}^k \frac{Precision_k}{K} * 100\% \quad (7)$$

$$MAR = \sum_{k=1}^k \frac{Recall_k}{K} * 100\% \quad (8)$$

$$MAF = \sum_{k=1}^k \frac{F1Score_k}{K} * 100\% \quad (9)$$

Keterangan:

MAP : *Macro Average Precision*

MAR : *Macro Average Recall*

MAF : *Macro Average F1-Score*

K: Jumlah kelas pada system klasifikasi *multiclass*

3. HASIL DAN PEMBAHASAN

Hasil evaluasi dari sistem deteksi penyakit pada daun durian dalam penelitian ini akan dianalisis guna mengukur tingkat efektivitas dari sistem yang telah dibangun. Sistem ini dikembangkan melalui tahapan-tahapan yang telah dirancang sesuai dengan metode penelitian yang digunakan.

3.1. Hasil Pengumpulan Data

Data yang dikumpulkan digunakan untuk membentuk dataset penyakit daun durian yang terbagi ke dalam empat kategori, yaitu *Algal Leaf Spot*, *Leaf Blight*, *Leaf Spot*, dan *No Disease*. Masing-masing kategori memiliki jumlah citra yang seimbang, yaitu sebanyak 105 gambar per kelas, sehingga total keseluruhan citra mencapai 420.

3.2. Hasil Pra-pemrosesan Data

Pada tahap pra-pemrosesan, langkah awal yang dilakukan adalah memberikan anotasi pada citra daun durian guna mengidentifikasi area yang terinfeksi penyakit. Proses anotasi ini bertujuan untuk mempersiapkan dataset yang sesuai untuk pelatihan model deteksi berbasis deep learning. Setiap citra diberi (*bounding box*) yang menunjukkan bagian daun yang terkena penyakit. Gambar 3 berikut memperlihatkan contoh hasil anotasi pada citra daun durian yang dilakukan menggunakan platform Roboflow.

Gambar 3. Hasil Anotasi Citra Daun Durian



Tahap selanjutnya dalam pra-pemrosesan adalah mengubah ukuran citra menjadi 240x240 piksel agar sesuai dengan kebutuhan model ResNet-50. Selain itu, digunakan fitur Auto-Orient dan filter null untuk menghapus gambar yang tidak memiliki label, dengan tujuan meningkatkan kualitas dataset. Seluruh proses ini diterapkan pada 420 citra agar dataset menjadi lebih rapi dan siap digunakan untuk pelatihan model secara maksimal. Dalam penelitian ini, augmentasi data dilakukan melalui teknik *horizontal flip* dan *cropping*. Augmentasi hanya diterapkan pada data pelatihan, sehingga jumlah citra pelatihan meningkat dua kali lipat, yakni dari 294 menjadi 558 pada skenario pertama 70:20:10, dari 314 menjadi 628 pada skenario kedua 75:15:10, dan dari 334 menjadi 668 pada skenario 80:10:10.

3.3 Hasil Pelatihan Model

Proses pelatihan model dilakukan dengan membandingkan performa berdasarkan dua pendekatan klasifikasi, yaitu klasifikasi biner (Binary Class) dan multi-kelas (Multi Class). Pengujian dilakukan secara bertahap dengan beberapa variasi jumlah epoch dan rasio pembagian dataset (train:val:test), yaitu: 70:20:10, 75:15:10, dan 80:10:10. Evaluasi performa melibatkan metrik akurasi, presisi, recall, dan F1-score.


A. Kasus Binary Class

Pada pendekatan klasifikasi biner, model menunjukkan peningkatan performa yang konsisten seiring bertambahnya jumlah epoch dan proporsi data latih. Berdasarkan hasil Tabel 4, terlihat bahwa performa tertinggi dicapai pada konfigurasi 80:10:10 dengan 50 epoch, menghasilkan akurasi 0.998, presisi 0.999, recall 0.998, dan F1-score 0.999.

Tabel 3. Binary Class


Split DataSet	Epoch	Batch Size	Accuracy	Precision	Recall	F1-Score
70:20:10	25	32	0.978	0.977	0.976	0.976
70:20:10	50	32	0.986	0.985	0.984	0.984
75:15:10	25	32	0.981	0.980	0.979	0.980
75:15:10	50	32	0.991	0.992	0.990	0.991
80:10:10	25	32	0.989	0.990	0.988	0.989
80:10:10	50	32	0.998	0.999	0.998	0.999

Grafik performa menunjukkan tren peningkatan yang linier terhadap metrik evaluasi saat jumlah epoch dan proporsi data latih meningkat. Hal ini mengindikasikan bahwa model mampu mempelajari fitur penting dari data dengan lebih baik saat diberi data yang lebih banyak dan waktu pelatihan yang lebih lama. Gambar 4 merupakan hasil dari akurasi dari training yang dilakukan kasus binary class



Gambar 4. Hasil Akurasi

Hasil ini diperkuat dengan confusion matrix pada Gambar 5, yang menunjukkan bahwa model dapat mengklasifikasikan 43 sampel positif dan 44 sampel negatif secara sempurna tanpa kesalahan klasifikasi (False Positive/False Negative = 0). Hal ini menunjukkan generalisasi model yang sangat baik terhadap data uji pada kasus biner.



Gambar 5. Hasil Confusion Matrix


B. Multi Class

Pendekatan klasifikasi multi-kelas juga menunjukkan performa yang sangat baik, meskipun sedikit lebih menantang dibandingkan kasus biner. Hasil terbaik dicapai pada konfigurasi 80:10:10 dengan 50 epoch, dengan akurasi sebesar 0.996, macro average precision 0.997, dan macro recall 0.996, seperti terlihat pada tabel 5.

Tabel 4. Multi Class


Split DataSet	Epoch	Batch Size	Accuracy	Macro Avg Precision	Macro Avg Recall	Macro Avg F1-Score
70:20:10	25	32	0.964	0.963	0.961	0.962
70:20:10	50	32	0.975	0.974	0.972	0.973
75:15:10	25	32	0.971	0.970	0.969	0.969
75:15:10	50	32	0.983	0.984	0.982	0.983
80:10:10	25	32	0.980	0.979	0.978	0.979
80:10:10	50	32	0.996	0.997	0.996	0.969

Grafik menunjukkan tren peningkatan performa seiring bertambahnya epoch dan proporsi data latih. Konfigurasi terbaik terjadi pada 50 epoch dengan rasio 80:10:10, di mana semua metrik (akurasi, presisi, recall, F1-score) mencapai nilai tertinggi di atas 0.99, kecuali F1-score yang sedikit menurun menjadi 0.969. Penurunan ini mengindikasikan adanya sedikit ketidakseimbangan klasifikasi pada salah satu kelas, namun secara keseluruhan model tetap menunjukkan kinerja sangat baik. Gambar 6 merupakan hasil dari akurasi dari training yang dilakukan kasus MultiClass.



Gambar 6. Hasil Akurasi

Confusion matrix menunjukkan bahwa model memiliki akurasi tinggi dalam membedakan keempat kelas. Mayoritas prediksi tepat, dengan hanya beberapa kesalahan kecil: dua kasus *misclassification* antara kelas Algal Leaf Spot dan Leaf Blight, serta satu kesalahan antara No Disease dan Leaf Spot. Ini menunjukkan bahwa model memiliki performa generalisasi yang baik, meskipun masih perlu sedikit perbaikan pada dua kelas yang cenderung mirip secara visual. Gambar 7 merupakan tabel confusion matrix dari hasil testing .



Gambar 7. Hasil Confusion Matrix

Selanjutnya Hasil memperlihatkan bahwa model ResNet-50 yang digunakan dalam penelitian ini mampu mengidentifikasi dengan akurat area daun durian yang mengalami infeksi penyakit maupun yang dalam kondisi sehat. Variasi bentuk dan tekstur daun yang ditangkap dalam lingkungan alami mencerminkan keberagaman data sampel yang digunakan selama pelatihan model. Gambar 8 memperlihatkan citra hasil pengujian yang dilakukan terhadap model klasifikasi daun durian menggunakan algoritma ResNet-50. Dua pendekatan diterapkan dalam pengujian ini, yaitu *binary classification* (klasifikasi dua kelas: daun sehat dan daun sakit) dan *multiclass classification* (klasifikasi empat kelas berdasarkan jenis penyakit). Pada bagian kiri Gambar 8, citra daun yang ditunjukkan memiliki bercak-bercak coklat yang terdeteksi oleh model sebagai *Diseased* (terinfeksi). Sementara itu, citra di sebelah kanan menunjukkan daun dalam kondisi baik dan berhasil diklasifikasikan sebagai *Healthy* oleh model. Kedua hasil ini merupakan representasi dari pengujian *binary classification*.



Gambar 8. Citra Hasil Pengujian Binary Class

Selanjutnya, pada gambar 9 Hasil pengujian pada *multiclass classification* ditunjukkan melalui beberapa citra daun lainnya, yang masing-masing diklasifikasikan ke dalam kategori penyakit spesifik, yaitu ke dalam empat kategori: *Alga Leaf Spot*, *Leaf Spot*, *Leaf Blight*, dan *No Disease*. Klasifikasi akurat terlihat dari kesesuaian ciri visual seperti pola bercak, warna, dan bentuk kerusakan. *Alga Leaf Spot* disebabkan oleh alga parasit yang membentuk bercak kehijauan pada permukaan daun. *Leaf Spot* muncul akibat infeksi jamur atau bakteri, ditandai dengan bercak kecil berbentuk melingkar. *Leaf Blight* menyebabkan nekrosis pada jaringan daun, sering berkembang dari tepi ke seluruh permukaan daun. Sementara itu, *No Disease* menandakan kondisi daun sehat tanpa gejala. Hasil klasifikasi terlihat akurat berdasarkan ciri visual dari masing-masing daun, seperti pola bercak, warna, dan bentuk kerusakan. Meskipun kompleksitas klasifikasi meningkat, model ResNet-50 masih mampu mencerminkan kemampuan model untuk mendeteksi dengan akurat di setiap kelas penyakit.



Gambar 9. Citra Hasil Pengujian Multi Class

4. SIMPULAN

Hasil dari penelitian yang telah dilakukan menunjukkan bahwa model ResNet-50 memberikan performa yang sangat baik dalam klasifikasi penyakit daun durian untuk kasus binary class dan multiclass. Dataset dibagi menjadi tiga skenario pembagian data yaitu 70:20:10, 75:15:10, dan 80:10:10. Pada kasus binary class, model dilatih dengan total 1560 gambar yang terdiri dari daun sehat dan daun sakit. Hasil terbaik diperoleh pada konfigurasi 80:10:10 dengan 50 epoch, yang menghasilkan akurasi sebesar 99,8% dan nilai F1-score sebesar 99,9%. Sedangkan pada kasus multiclass, dengan total 4275 gambar dari empat kategori (*Algal Leaf Spot*, *Leaf Blight*, *Leaf Spot*, dan *No Disease*), model mencapai akurasi tertinggi sebesar 99,6% dan macro F1-score sebesar 96,9%. Hal ini menunjukkan bahwa model ResNet-50 memiliki kapabilitas tinggi dalam mengenali berbagai kondisi daun durian. Namun, klasifikasi multiclass cenderung lebih kompleks dan membutuhkan variasi data yang lebih luas. Penelitian ini membuktikan bahwa dengan pengolahan dataset yang tepat serta parameter pelatihan yang optimal, model ResNet-50 mampu melakukan deteksi penyakit daun durian secara akurat dan dapat diterapkan dalam membantu petani.

DAFTAR PUSTAKA

- [1] E. Yuniastuti, N. Nandariyah, and S. R. Bukka, "Karakterisasi Durian (*Durio zibenthinus*) Ngrambe di Jawa Timur, Indonesia," *Caraka Tani: Journal of Sustainable Agriculture*, vol. 33, no. 2, p. 136, Sep. 2018, doi: 10.20961/carakatani.v33i2.19610.
- [2] N. Najira, E. Selviyanti, Y. B. Tobing, K. Kasmawati, R. Sianturi, and A. B. Suwardi, "Diversitas Kultivar tanaman Durian (*Durio zibenthinus* Murr.) Ditinjau dari Karakter Morfologi", doi: 10.29303/jbt.v20i2.1871.
- [3] Napitulu and Rodame Monitorir, "Bertanam Durian Unggul," 2015.
- [4] A. Taslim, S. Saon, K. Mahamad, M. Muladi, and W. N. Hidayat, "Plant leaf identification system using convolutional neural network," *Eng. Informatics*, vol. 10, Dec. 2021, doi: 10.11591/eei.v10i6.2332.
- [5] B. FEBRIANA, "Identifikasi Penyakit Daun Apel Menggunakan Resnet 50 Dilated Convolution Neural Network," *Inst. Teknol. Nas. Bandung*, no. 465, pp. 106–111, Accessed: May 10, 2025. [Online]. Available: <https://medium.com/@nadhifasofia/1-convolutional-neural-network-convolutional-neural-network-merupakan-salah-satu-metode-machine-28189e17335b>
- [6] Jia-Rong X, Pei-Che C, Hung-Yi W, Quoc-Hung P, Yeh J.-L. A, and M.-K. Hou, "Detection of Strawberry Diseases Using a Convolutional Neural Network," pp. 1–14, 2020.
- [7] C. Nur Sahera, Y. Rahmawati, R. Dijaya, and S. dan Teknologi, "OPTIMASI PENERAPAN ALGORITMA CONVOLUTION NEURAL NETWORK DALAM KLASIFIKASI TINGKAT KESEGARAN DAGING SAPI," *Jurnal TEKINKOM*, vol. 7, no. 1, 2024, doi: 10.37600/tekinkom.v7i1.1122.
- [8] Chollet and Francois, "Deep Learning with Python," Shelter Island: Manning Publications Co.
- [9] Sena and Samuel, "Pengenalan Deep Learning Part 7 : Convolutional Neural Network (CNN)," 2017, Accessed: May 10, 2025. [Online]. Available: <https://medium.com/@samuelsena/pengenalan-deep-learning-part-7-convolutionalneural-network-cnn-b003b477dc94>
- [10] I. Pratama Putra and D. Alamsyah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network," *Jurnal Algoritme*, vol. 2, no. 2, pp. 102–112, 2022, [Online]. Available: <https://www.kaggle.com/qramkrishna/corn-leaf-infection-dataset>
- [11] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.
- [12] Egga Naufal Daffa Tanadi, Dhian Satria Yudha Kartika, and Abdul Rezha Efrat Najaf, "Sistem Pendeteksi Penyakit Kanker Kulit Menggunakan Convolutional Neural Network Arsitektur YOLOv8 Berbasis Website," *Repeater Publ. Tek. Inform. dan Jar*, vol. 2, no. 3, pp. 166–177, 2024, doi: 10.62951/repeater.v2i3.124.
- [13] L. Satya, M. R. D. Septian, M. W. Sarjono, M. Cahyanti, and E. R. Swedia, "Sistem Pendeteksi Plat Nomor Polisi Kendaraan Dengan Arsitektur Yolov8," *Sebatik*, vol. 27, no. 2, pp. 753–761, 2023, doi: 10.46984/sebatik.v27i2.2374.,jhM. S. Anggraeany, "Confusion Matrix," *School of Computer Science Binus University*, Nov. 2020, Accessed: May 10, 2025. [Online].

Available: <https://socs.binus.ac.id/2020/11/01/confusionmatrix/>

- [14] R. Arthana, "Mengenal Accuracy, Precision, Recall, dan Specificity Serta yang Diprioritaskan Dalam Machine Learning," Apr. 2019, Accessed: May 10, 2025. [Online]. Available: <https://rey1024.medium.com/mengenalaccuracy-precision-recall-dan-specificityserta-yang-diprioritaskan-b79ff4d77de8>
- [15] K. Leung, "Micro, Macro & Weighted Averages of F1 Score, Clearly Explained," Jan. 2022, Accessed: May 10, 2025. [Online]. Available: <https://towardsdatascience.com/micro-macroweighted-averages-of-f1-score-clearlyexplained-b603420b292f>