

ANALISIS PENYAKIT DAUN MANGGA MENGGUNAKAN ALGORITMA KLASIFIKASI DATA MINING NASNETMOBILE DAN RESNET50

Muhammad Yusuf¹, Diajeng Ganis Samantha Murpri², Khumairah Awaliyah Ernas³

^{1,2,3}Program Studi Teknik Informatika, Universitas Muhammadiyah Sorong
Jln. Pendidikan No.27, Kelurahan Klabulu, Malaimsimsa, Kota Sorong, Papua Barat Daya 98416
1yusuf@um-sorong.ac.id, 2diajengmurpri17@gmail.com, 3khumairahernas5@gmail.com

Abstract

Mango plant diseases can reduce productivity and crop quality, so early detection is important to prevent losses for farmers. This study aims to identify and classify mango leaf diseases using data mining classification algorithms, namely NASNetMobile and ResNet50. The dataset used consisted of 1,800 mango leaf images, consisting of three disease classes with 600 images each, namely anthracnose, sooty mold, and leaf caterpillars. The dataset was divided into 80% training data, 10% validation, and 10% testing. Pre-processing stages were carried out through image normalization and data augmentation to improve model performance. The two models were compared based on evaluation metrics such as accuracy, precision, recall, and f1-score. The results showed that the NASNetMobile model achieved an accuracy of 96%, while ResNet50 only achieved 73%. Based on these results, NASNetMobile proved to be more effective in automatically detecting mango leaf diseases. The results of this study provide practical benefits in the form of the potential for developing a mobile or web-based system as an early detection tool for plant diseases that can be used directly by farmers to support fast and accurate decision-making.

Keywords : data mining, mango leaf disease, image classification, NASNetMobile, ResNet50

Abstrak

Penyakit pada tanaman mangga dapat menurunkan produktivitas dan kualitas hasil panen, sehingga deteksi dini menjadi penting untuk mencegah kerugian bagi petani. Penelitian ini bertujuan untuk mengidentifikasi dan mengklasifikasikan penyakit pada daun mangga menggunakan algoritma klasifikasi data mining, yaitu NASNetMobile dan ResNet50. *Dataset* yang digunakan berjumlah 1.800 citra daun mangga, yang terdiri atas tiga kelas penyakit dengan masing-masing kelas berjumlah 600 citra, yaitu antraknosa, cendawan jelaga, dan ulat daun. *Dataset* dibagi menjadi data pelatihan sebesar 80%, validasi 10%, dan pengujian 10%. Tahapan pra-pemrosesan dilakukan melalui normalisasi gambar dan augmentasi data untuk meningkatkan performa model. Kedua model dibandingkan berdasarkan metrik evaluasi berupa akurasi, *precision*, *recall*, dan *f1-score*. Hasil menunjukkan bahwa model NASNetMobile memperoleh akurasi sebesar 96%, sedangkan ResNet50 hanya mencapai 73%. Berdasarkan hasil tersebut, NASNetMobile terbukti lebih efektif dalam mendeteksi penyakit daun mangga secara otomatis. Hasil penelitian ini memberikan manfaat praktis berupa potensi pengembangan sistem berbasis *mobile* atau web sebagai alat bantu deteksi dini penyakit tanaman yang dapat digunakan langsung oleh petani untuk mendukung pengambilan keputusan yang cepat dan akurat.

Kata Kunci : Data Mining, Penyakit Daun Mangga, Klasifikasi Citra, NASNetMobile, ResNet50

1. PENDAHULUAN

Buah-buahan merupakan salah satu komoditas hortikultura yang sangat diminati oleh masyarakat Indonesia, tidak hanya karena cita rasanya yang lezat, tetapi juga karena kandungan

gizinya yang kaya, seperti vitamin dan mineral yang penting bagi kesehatan tubuh. Komoditas ini memiliki peluang besar untuk dikembangkan karena prospeknya yang sangat menjanjikan. Seiring dengan bertambahnya jumlah penduduk di Indonesia, permintaan terhadap buah-buahan

juga terus meningkat, sehingga menjadikannya sebagai salah satu sektor pertanian yang memiliki nilai ekonomi tinggi dan berkelanjutan untuk dibudidayakan [1].

Seperti contohnya mangga, mangga (*Mangifera indica* L.) merupakan Tanaman yang berasal dari wilayah India dan termasuk ke dalam famili *Anacardiaceae* [2]. Tanaman ini dikenal luas sebagai salah satu jenis buah tropis yang populer dan banyak dibudidayakan di berbagai negara, termasuk Indonesia [3]. Buah mangga memiliki berbagai khasiat yang bermanfaat bagi kesehatan, antara lain dapat meningkatkan sistem kekebalan tubuh, melancarkan proses pencernaan, menjaga kesehatan mata, serta berperan dalam perawatan rambut dan kulit. Selain itu, mangga juga dapat membantu mengurangi risiko terkena kanker, menurunkan kadar kolesterol, dan menjaga kesehatan jantung. Mangga merupakan sumber vitamin C yang kaya akan antioksidan. Kandungan antioksidan ini berfungsi untuk melawan radikal bebas dari lingkungan, seperti polusi asap rokok, emisi kendaraan, dan paparan sinar matahari, yang berpotensi memicu timbulnya penyakit kanker [4][5].

Biji-bijian dan buah-buahan memiliki peran penting dalam pemenuhan gizi manusia, namun keberadaannya sering terancam oleh berbagai penyakit yang disebabkan oleh jamur dan bakteri. Sejak zaman dahulu, penyakit tanaman telah menjadi salah satu kendala utama dalam upaya menghasilkan produk pertanian yang sehat dan berkualitas. Gangguan ini tidak hanya mempengaruhi kualitas hasil panen, tetapi juga berdampak pada jumlah produksi secara keseluruhan. Oleh karena itu, deteksi dini terhadap penyakit tanaman menjadi langkah penting dan efektif untuk mencegah kerusakan lebih lanjut serta menjaga ketahanan pangan [6].

Menurut data dari Badan Pusat Statistik (BPS), total produksi tanaman mangga di Indonesia pada tahun 2023 mencapai sekitar 33.026.197,13 kuintal. Namun, pada tahun 2024, produksi mengalami penurunan tipis sebesar 0,03% menjadi 33.017.398,56 kuintal, yang menunjukkan adanya penurunan produktivitas meskipun dalam skala kecil [7]. Menurunnya produktivitas tanaman mangga merupakan salah satu masalah utama yang dihadapi dalam budidaya, yang sebagian besar dipicu oleh serangan hama dan penyakit. Gangguan ini dapat mempengaruhi pertumbuhan tanaman serta kualitas dan kuantitas hasil panen, sehingga perlu dilakukan upaya pengendalian yang tepat untuk menjaga stabilitas produksi [8].

Akibat serangan berbagai penyakit, para petani berisiko mengalami kerugian besar

meskipun telah melakukan berbagai upaya budidaya. Kondisi ini seringkali terjadi karena keterbatasan pengetahuan serta minimnya dukungan teknis yang tersedia, sehingga penyakit pada tanaman tidak tertangani secara tepat dan cepat. Pemanfaatan solusi berbasis kecerdasan buatan (AI) dapat digunakan untuk mengidentifikasi dan mengklasifikasikan daun tanaman sesuai dengan jenis penyakit yang menyerang. Salah satu metode yang umum diterapkan dalam bidang ini adalah *Convolutional Neural Network* (CNN), yang dikenal efektif dalam mengenali pola pada citra dan melakukan klasifikasi secara akurat [9].

Convolutional Neural Network (CNN) merupakan metode yang potensial dalam menjawab berbagai permasalahan terkait klasifikasi objek, terutama dalam bidang pertanian. Pendekatan ini menawarkan kemampuan tinggi dalam mengenali pola visual dari data citra, sehingga sangat mendukung proses identifikasi tanaman maupun penyakit secara otomatis dan efisien di sektor pertanian [10].

NASNetMobile merupakan salah satu arsitektur jaringan saraf konvolusional yang dirancang untuk menghasilkan performa tinggi dengan efisiensi yang optimal. Arsitektur ini dikembangkan melalui pendekatan *Neural Architecture Search* (NAS), yaitu teknik otomatis yang mencari struktur jaringan terbaik untuk tugas tertentu. Salah satu keunggulan utama dari NASNetMobile adalah jumlah parameternya yang lebih sedikit dibandingkan dengan arsitektur seperti MobileNet, sehingga menjadikannya lebih ringan dan hemat sumber daya komputasi. Hal ini membuat NASNetMobile sangat cocok untuk digunakan pada perangkat dengan keterbatasan *hardware* seperti *smartphone* atau *embedded system*, tanpa harus mengorbankan akurasi secara signifikan. Dengan demikian, NASNetMobile menjadi pilihan ideal dalam aplikasi klasifikasi citra yang membutuhkan keseimbangan antara kecepatan, ukuran model, dan akurasi [11].

ResNet50 adalah salah satu varian arsitektur dari *Convolutional Neural Network* (CNN) yang terdiri dari 50 lapisan dan memperkenalkan konsep baru yang disebut *shortcut connections*. Fitur ini dirancang untuk mengatasi permasalahan *vanishing gradient* yang sering muncul selama proses pelatihan jaringan *deep learning*, terutama ketika jaringan memiliki banyak lapisan. *Vanishing gradient* terjadi ketika nilai gradien menjadi sangat kecil, sehingga menyulitkan pembaruan bobot pada lapisan-lapisan awal jaringan. Masalah ini dapat menurunkan kinerja dan akurasi model secara

keseluruhan. Dengan adanya *shortcut connections*, ResNet50 mampu mempertahankan aliran gradien yang lebih stabil, sehingga pelatihan jaringan dalam yang kompleks dapat dilakukan dengan lebih efektif dan menghasilkan performa yang lebih baik [12].

Penelitian [13] mengkaji komparasi antara algoritma MobileNet dan NASNetMobile dalam klasifikasi penyakit daun teh dengan menggunakan *dataset* enam kelas citra daun teh. Hasil penelitian menunjukkan bahwa MobileNet menghasilkan akurasi lebih tinggi sebesar 95%, sementara NASNetMobile hanya mencapai 88%, sehingga MobileNet dinilai lebih unggul dalam hal akurasi untuk klasifikasi citra daun, khususnya pada sistem berbasis ringan. Berbeda dengan penelitian ini, penggunaan arsitektur NASNetMobile justru menghasilkan akurasi yang lebih tinggi, yakni mencapai 96%, yang menunjukkan bahwa dengan optimasi yang tepat dan penyesuaian data serta parameter, performa NASNetMobile masih dapat ditingkatkan secara signifikan melebihi hasil yang dicapai pada penelitian sebelumnya.

Penelitian [14] yang dilakukan pada tahun 2023 membandingkan performa lima arsitektur *transfer learning* InceptionV3, MobileNetV2, VGG16, ResNet50V2, dan NASNetMobile dalam klasifikasi penyakit daun pada tanaman gandum, kedelai, dan jagung menggunakan tiga *dataset* berbeda dengan enam skenario pelatihan. Evaluasi dilakukan berdasarkan metrik akurasi, presisi, *recall*, dan *f1-score*. Hasil analisis menunjukkan bahwa VGG16 memiliki performa paling stabil di seluruh skenario, dengan akurasi tinggi dan tanpa *overfitting*, yaitu 93,75% (A1), 91,49% (A2), 93,94% (B1), 97,96% (B2), 91,73% (C1), dan 90,35% (C2). ResNet50V2 memperoleh akurasi tertinggi di beberapa skenario hingga 100%, namun menunjukkan gejala *overfitting* pada data pelatihan. MobileNetV2 juga mencatatkan akurasi yang cukup baik dan stabil, mencapai 97,96% pada skenario B2. Sebaliknya, NASNetMobile cenderung memiliki performa yang lebih rendah dibandingkan arsitektur lainnya, dengan akurasi hanya mencapai 90,62% (A1), 93,88% (B2), dan 91,30% (C2). Perbandingan ini menunjukkan bahwa meskipun arsitektur seperti VGG16 dan MobileNetV2 dapat mencapai akurasi tinggi dan stabil, NASNetMobile belum memberikan hasil yang optimal, sehingga masih diperlukan pendekatan yang lebih baik untuk meningkatkan akurasi.

Penelitian [14] membandingkan performa arsitektur MobileNet dan NASNetMobile dalam klasifikasi penyakit daun kentang, menggunakan *dataset* yang terdiri dari tiga kelas (daun sehat,


daun terinfeksi *Early Blight*, dan daun terinfeksi *Late Blight*) dengan lima skema pemisahan data. Hasil penelitian menunjukkan bahwa arsitektur NASNetMobile, pada skema pembagian data 90:10, menghasilkan akurasi sebesar 90,96%, *precision* 90,86%, *recall* 91,11%, dan *f1-score* 92,93%. Sementara itu, pada skema pembagian lainnya, akurasi NASNetMobile mengalami penurunan, dengan nilai tertinggi hanya mencapai 81,82%. Perbandingan ini menunjukkan bahwa meskipun NASNetMobile efektif pada perangkat *mobile*, akurasi yang diperoleh masih lebih rendah dibandingkan hasil penelitian ini, yang berhasil mencapai akurasi hingga 96% dengan arsitektur CNN yang lebih dioptimalkan.

Berdasarkan hal tersebut, penelitian ini difokuskan pada klasifikasi penyakit daun mangga menggunakan perbandingan dua arsitektur CNN modern, yaitu NASNetMobile dan ResNet50. NASNetMobile dipilih karena ringan dan efisien untuk implementasi pada perangkat terbatas [15], sedangkan ResNet50 dikenal memiliki kedalaman jaringan yang dapat menangkap fitur kompleks. Kebaruan penelitian ini terletak pada penggunaan *dataset* citra daun mangga dengan tiga jenis penyakit serta penerapan optimasi pra-pemrosesan dan augmentasi data untuk meningkatkan akurasi model. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi nyata dalam pengembangan sistem deteksi otomatis penyakit mangga serta membantu petani dalam pengambilan keputusan yang lebih cepat dan akurat.

2. METODOLOGI PENELITIAN

2.1. Alur Penelitian

Penelitian ini dilakukan melalui serangkaian tahapan yang sistematis untuk mengklasifikasikan penyakit pada daun mangga menggunakan dua algoritma klasifikasi data mining yaitu NASNetMobile dan ResNet50. Adapun tahapan tersebut meliputi pengumpulan *dataset*, pra-pemrosesan data, pelatihan model klasifikasi dengan dua arsitektur, evaluasi model, dan perbandingan hasil. Alur lengkap tahapan penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

2.2. Pengumpulan Dataset

Pengumpulan *dataset* dalam penelitian ini dilakukan dengan mengambil data citra daun tanaman mangga dari platform *Kaggle*. *Dataset* tersebut terdiri dari gambar-gambar daun yang menunjukkan berbagai kondisi, termasuk yang terinfeksi penyakit, dan digunakan sebagai bahan pelatihan untuk membangun model klasifikasi guna mengidentifikasi jenis penyakit pada daun tanaman mangga. Pengumpulan *dataset* merupakan langkah awal dalam penelitian ini. *Dataset* yang digunakan berupa kumpulan citra daun mangga yang mengalami tiga jenis penyakit yaitu *antraknosa*, cendawan jelaga, dan ulat daun. Setiap citra telah dikelompokkan ke dalam folder masing-masing sesuai dengan label penyakitnya. Sumber data berasal dari koleksi gambar yang telah dipilih dan disusun secara sistematis untuk memudahkan proses pelatihan. Setelah dikumpulkan, *dataset* diunggah ke *Google Drive* untuk diakses

melalui *Google Colaboratory*. Pemanfaatan *Google Drive* dan *Colab* bertujuan untuk mendukung pelatihan model secara efisien dan fleksibel menggunakan GPU secara *daring*.

2.3. Pra-pemrosesan Data

Tahapan selanjutnya adalah pra-pemrosesan data yang dilakukan untuk menyiapkan data agar sesuai dengan kebutuhan dua algoritma klasifikasi yang digunakan dalam penelitian ini, yaitu NASNetMobile dan ResNet50. Kedua algoritma ini memerlukan input citra dengan format dan skala tertentu agar proses klasifikasi dapat berjalan secara optimal. Proses pra-pemrosesan dimulai dengan normalisasi gambar, yaitu mengubah nilai piksel citra ke dalam rentang antara 0 dan 1 yang bertujuan untuk menyamakan skala nilai pada seluruh citra sehingga algoritma dapat lebih mudah mempelajari pola tampilan. Setelah normalisasi, dilakukan augmentasi data untuk memperluas variasi data pelatihan. Teknik augmentasi yang digunakan meliputi rotasi, pembalikan (*flipping*), pembesaran (*zooming*), dan pergeseran (*shifting*). Augmentasi ini dilakukan agar model NASNetMobile dan ResNet50 dapat lebih tahan terhadap variasi posisi, arah, dan skala citra saat proses pelatihan. Setelah melalui tahapan tersebut, dataset dibagi menjadi tiga bagian, yaitu 80% untuk data pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Pembagian ini dilakukan secara acak namun tetap menjaga proporsi kelas yang seimbang, agar hasil klasifikasi yang dihasilkan oleh kedua algoritma dapat dievaluasi secara objektif dan menyeluruh.

2.4. Pelatihan Model Klasifikasi

2.4.1 Tahapan Eksperimen

Setelah tahap pra-pemrosesan selesai, proses dilanjutkan ke pelatihan model klasifikasi yang merupakan inti dari penelitian ini. Pada tahap ini digunakan dua arsitektur *Convolutional Neural Network* (CNN), yaitu NASNetMobile dan ResNet50. Kedua model tersebut diadaptasi menggunakan pendekatan *transfer learning*, dengan menambahkan lapisan akhir berupa *fully connected layer* serta fungsi aktivasi *softmax* untuk memetakan prediksi ke dalam tiga kelas target (*antraknosa*, cendawan jelaga, dan ulat daun). Proses pelatihan dilakukan dengan metode *fine-tuning*, di mana bobot model disesuaikan

secara bertahap agar mampu mengenali pola visual khas dari tiap jenis penyakit daun mangga. Selama pelatihan, model mempelajari karakteristik *dataset* melalui iterasi berulang, dengan tujuan meminimalkan kesalahan prediksi dan meningkatkan kemampuan generalisasi.

2.4.2 Parameter Pelatihan

Untuk menjaga agar proses pelatihan berlangsung optimal dan hasil penelitian dapat direplikasi secara konsisten, maka digunakan sejumlah parameter pelatihan yang telah disesuaikan dengan karakteristik dataset dan kebutuhan klasifikasi multikelas. Parameter ini sebagai acuan dalam mengatur jalannya pembelajaran model yang meliputi jumlah *epoch*, ukuran *batch*, metode optimasi, hingga fungsi evaluasi kesalahan. Parameter yang digunakan dalam proses pelatihan kedua model dijabarkan pada Tabel 1 berikut:

TABEL 1. PARAMETER PELATIHAN MODEL

Parameter	Nilai
<i>Epoch</i>	50
<i>Batch Size</i>	64
Fungsi Aktivasi	<i>Softmax</i>
<i>Optimizer</i>	Adam
<i>Learning Rate</i>	0.001
<i>Loss Function</i>	<i>Categorical Crossentropy</i>

Parameter pelatihan pada Tabel 1 dipilih untuk menjaga keseimbangan antara akurasi dan efisiensi proses pembelajaran. Jumlah *epoch* 50 dan *batch size* 64 digunakan agar model memiliki cukup iterasi dengan pemakaian memori yang efisien. *Optimizer* Adam dengan *learning rate* 0.001 dipilih karena stabil dalam memperbaiki bobot, sedangkan fungsi aktivasi *softmax* digunakan untuk memetakan hasil prediksi ke dalam tiga kelas. Sementara itu, *loss function categorical crossentropy* sesuai diterapkan karena mampu menangani masalah klasifikasi multikelas secara efektif.

2.5. Spesifikasi Hardware dan Software

Penelitian ini dilakukan menggunakan platform *Google Colaboratory* dengan dukungan GPU NVIDIA Tesla T4 dan memori RAM sebesar 12 GB. Penyimpanan dataset dilakukan melalui layanan *Google Drive* yang terhubung langsung dengan sistem kerja pengembangan. Dari sisi perangkat lunak,

penelitian ini memanfaatkan bahasa pemrograman *Python* versi 3.10 dengan pustaka utama *TensorFlow* dan *Keras* untuk proses pemodelan, serta didukung oleh *Scikit-learn*, *Pandas*, *NumPy*, dan *Matplotlib* untuk analisis data dan visualisasi. Seluruh tahapan eksperimen dijalankan pada platform *Google Colaboratory* berbasis *Jupyter Notebook*, sehingga memungkinkan proses pelatihan model berlangsung secara efisien dan dapat direplikasi dengan mudah.

2.6. Evaluasi Model

Setelah proses pelatihan selesai, model dievaluasi untuk mengukur sejauh mana kemampuannya dalam mengklasifikasikan citra daun mangga yang belum pernah dilihat sebelumnya. Evaluasi dilakukan menggunakan data pengujian dengan memanfaatkan akurasi, *precision*, *recall*, dan *f1-score* sebagai indikator performa. Selain itu, *confusion matrix* digunakan untuk mengetahui distribusi prediksi model terhadap masing-masing kelas, baik yang benar maupun yang salah. Tahap evaluasi ini penting untuk menilai efektivitas model secara menyeluruh dan memastikan model mampu melakukan generalisasi dengan baik pada data baru.

2.7. Perbandingan Hasil NASNetMobile dan ResNet50

Perbandingan antara dua algoritma klasifikasi dilakukan untuk mengetahui tingkat kinerja masing-masing model dalam menyelesaikan permasalahan klasifikasi penyakit daun mangga. Langkah ini penting karena setiap algoritma memiliki karakteristik dan metode yang berbeda dalam memproses citra, sehingga dapat memengaruhi tingkat akurasi, kemampuan menghadapi gangguan data (*noise*), dan daya generalisasi model. Melalui perbandingan ini, dapat diketahui kelebihan dan kekurangan dari masing-masing algoritma ketika diterapkan pada *dataset* yang sama. Selain itu, perbandingan ini juga membantu dalam menentukan algoritma mana yang lebih sesuai untuk diterapkan pada sistem klasifikasi citra tanaman, baik untuk keperluan penelitian lanjutan maupun penerapan secara langsung di lapangan. Oleh karena itu, evaluasi yang objektif terhadap kedua model memungkinkan peneliti untuk memberikan rekomendasi pemilihan model yang lebih tepat, sesuai dengan kebutuhan dan tujuan aplikasi yang diharapkan.

3. HASIL DAN PEMBAHASAN

3.1. Pengumpulan Dataset

Dataset dalam penelitian ini dikumpulkan melalui *platform* penyedia data *daring* yaitu *Kaggle*, yang menyediakan kumpulan citra daun mangga dengan label jenis penyakit. *Dataset* ini diunduh sebagai sumber data utama untuk keperluan pelatihan dan pengujian model klasifikasi. Setiap citra telah diklasifikasikan berdasarkan gejala penyakit yang tampak pada permukaan daun. Adapun tiga kategori penyakit yang digunakan dalam penelitian ini meliputi *antraknosa*, cendawan

jelaga, dan ulat daun. Seluruh citra dalam *dataset* telah dikelompokkan ke dalam tiga folder sesuai dengan label kelas masing-masing. *Dataset* terdiri dari 1.800 citra dengan jumlah yang merata, yaitu 600 citra untuk setiap kelas untuk menjaga keseimbangan data dan mencegah ketidakseimbangan kelas yang dapat memengaruhi akurasi model. Data tersebut disimpan di *Google Drive* dan diolah menggunakan *Google Colaboratory* selama proses pelatihan dan evaluasi model berlangsung. Deskripsi jumlah *dataset* untuk masing-masing kelas dapat dilihat pada Tabel 2.

TABEL II. JUMLAH DATASET

Kelas Penyakit	Citra Dataset	Jumlah Dataset
<i>Antraknosa</i>		600
Cendawan Jelaga		600
Ulat Daun		600
Total Dataset		1.800

Tabel 2 menunjukkan bahwa jumlah *dataset* yang digunakan dalam penelitian ini adalah sebanyak 1.800 citra daun mangga, yang dibagi secara merata ke dalam tiga kelas penyakit, yaitu *antraknosa*, cendawan jelaga, dan ulat daun, masing-masing sebanyak 600 gambar. Pembagian yang seimbang ini dilakukan untuk menjaga distribusi data yang adil antar kelas dan meminimalkan potensi bias selama proses pelatihan model.

3.2. Pra-pemrosesan Data

Tahap pra-pemrosesan data dalam penelitian ini diterapkan untuk menyesuaikan format citra daun mangga dengan kebutuhan


input dari kedua algoritma yang digunakan, yaitu NASNetMobile dan ResNet50. Seluruh citra dalam dataset diubah ukurannya menjadi 224×224 piksel dan dinormalisasi ke dalam skala nilai antara 0 dan 1 dengan membagi nilai piksel terhadap 255. Langkah ini bertujuan untuk menyamakan skala data dan mempercepat proses pelatihan model. Setelah normalisasi, dilakukan proses augmentasi data menggunakan fungsi *ImageDataGenerator* dari Keras. Teknik augmentasi yang diterapkan meliputi rotasi citra sebesar 20 derajat, *flipping horizontal*, *zooming*, dan pergeseran posisi horizontal maupun vertikal. Tujuan dari augmentasi ini adalah untuk menambah keragaman data latih dan meningkatkan

kemampuan generalisasi model terhadap berbagai variasi citra yang mungkin ditemui saat pengujian. *Dataset* kemudian diproses menggunakan metode generator dengan pemisahan data secara acak ke dalam tiga bagian yaitu data pelatihan, validasi, dan pengujian. Proporsi pembagian masing-masing adalah 80% untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Seluruh proses pra-pemrosesan ini dilaksanakan pada lingkungan *Google Colaboratory* dan dihubungkan langsung dengan penyimpanan *Google Drive*, sehingga memudahkan akses serta meningkatkan efisiensi dalam proses pelatihan kedua model.

3.3. Hasil Pelatihan Model

Hasil pelatihan menggunakan arsitektur NASNetMobile dan ResNet50 menunjukkan

bahwa NASNetMobile memiliki kinerja yang lebih baik dalam mengklasifikasikan citra daun mangga. Berdasarkan grafik akurasi dan *loss* pelatihan pada model NASNetMobile menunjukkan peningkatan akurasi yang stabil hingga mencapai 96% pada data validasi, dengan nilai *loss* yang terus menurun selama 50 *epoch*, yang menunjukkan proses pelatihan berjalan dengan baik dan tidak mengalami kelebihan pelatihan. Sementara itu, ResNet50 hanya mencapai akurasi sekitar 73% dan memperlihatkan perubahan nilai akurasi dan *loss* yang naik turun, yang menandakan bahwa proses pelatihannya belum berjalan secara optimal. Sehingga model NASNetMobile lebih mampu mengenali ciri-ciri penyakit pada daun mangga secara konsisten pada ketiga kelas yang diuji. Adapun grafik hasil pelatihan model dapat terlihat pada Gambar 2.



Gambar 2. Grafik akurasi dan *loss*

Gambar 2 memperlihatkan bahwa model NASNetMobile menunjukkan tren peningkatan akurasi yang konsisten hingga mencapai 96%, dengan nilai *loss* yang terus menurun selama pelatihan, menandakan konvergensi model yang baik. Sebaliknya, ResNet50 hanya mencapai akurasi 73% dan memperlihatkan fluktuasi yang tidak stabil pada kurva akurasi dan *loss*, mengindikasikan bahwa proses

pelatihan model tersebut kurang optimal dalam mengenali pola visual dari citra daun mangga.

3.4. Hasil Pelatihan Model

Evaluasi dilakukan menggunakan data pengujian untuk mengetahui kemampuan generalisasi dari masing-masing model. Empat metrik evaluasi digunakan, yaitu akurasi,

precision, *recall*, dan *f1-score*. Hasil evaluasi menunjukkan bahwa model NASNetMobile memberikan performa yang jauh lebih tinggi dibandingkan ResNet50. NASNetMobile berhasil mencapai akurasi sebesar 96%, dengan nilai *precision* 96%, *recall* 96%, dan *f1-score* sebesar 96%. Sedangkan, model ResNet50 hanya mencapai akurasi 73%, dengan *precision* 76%, *recall* 71%, dan *f1-score* sebesar 73%. Perbandingan hasil evaluasi kedua model tersebut disajikan pada Tabel 3.

Untuk memperjelas kemampuan prediksi pada masing-masing kelas, dilakukan evaluasi klasifikasi menggunakan visualisasi *confusion matrix* untuk setiap model. Evaluasi ini bertujuan untuk mengetahui sejauh mana akurasi model dalam mengenali masing-masing jenis penyakit daun mangga. Model NASNetMobile menunjukkan distribusi klasifikasi yang cukup seimbang pada ketiga kelas yaitu *antraknosa*, cendawan jelaga, dan ulat daun, serta menghasilkan performa yang

TABEL III. HASIL EVALUASI MODEL

Metrik Evaluasi	ResNet50	NASNetMobile
Akurasi	73%	96%
<i>Precision</i>	76%	96%
<i>Recall</i>	71%	96%
<i>F1-Score</i>	73%	96%


konsisten dengan akurasi tinggi, terutama pada kelas *antraknosa*. Sementara itu, model ResNet50 masih menunjukkan kesalahan klasifikasi antar kelas, terutama pada kelas yang memiliki kemiripan tekstur permukaan daun, seperti cendawan jelaga dan ulat daun, yang ditunjukkan oleh tingginya nilai *false positive* di antara kedua kelas tersebut. Hasil klasifikasi berdasarkan masing-masing kelas dapat dilihat pada Tabel 4 berikut.

TABEL VI. HASIL KLASIFIKASI MASING-MASING KELAS

Kelas Penyakit	Model	Prediksi Benar	Prediksi Salah	Total Data Uji
<i>Antraknosa</i>	NASNetMobile	59	3	62
	ResNet50	32	30	62
Cendawan Jelaga	NASNetMobile	59	3	62
	ResNet50	49	13	62
Ulat Daun	NASNetMobile	55	1	56
	ResNet50	50	6	56

Pada Tabel 4 di atas, ditampilkan hasil *confusion matrix* yang merangkum jumlah prediksi benar dan prediksi salah dari model NASNetMobile dan ResNet50 dalam mengklasifikasikan tiga jenis penyakit pada daun mangga. Model NASNetMobile menunjukkan performa yang lebih unggul dengan jumlah prediksi benar sebanyak 59 gambar untuk kelas *Antraknosa*, 59 gambar untuk Cendawan Jelaga, dan 55 gambar untuk

Ulat Daun. Sebaliknya, model ResNet50 menghasilkan jumlah prediksi benar yang lebih rendah yaitu 32 gambar untuk *Antraknosa*, 49 gambar untuk Cendawan Jelaga, dan 50 gambar untuk Ulat Daun. Berdasarkan hasil tersebut, dapat disimpulkan bahwa NASNetMobile memiliki akurasi yang lebih konsisten serta tingkat kesalahan yang lebih rendah dibandingkan dengan ResNet50 pada ketiga kelas penyakit yang diuji.



Gambar 3. Hasil *Confusion Matrix*

Berdasarkan Gambar 3, dapat diamati bahwa model NASNetMobile menunjukkan tingkat akurasi yang tinggi pada seluruh kelas penyakit, khususnya dalam mengidentifikasi kelas *Antraknosa* dengan sangat baik. Di sisi lain, model ResNet50 memperlihatkan tingkat kesalahan klasifikasi yang lebih tinggi, terutama dalam membedakan antara kelas Cendawan Jelaga dan Ulat Daun. Hal ini menunjukkan bahwa NASNetMobile lebih mampu mengenali ciri visual khas dari masing-masing penyakit dibandingkan ResNet50.

3.5. Perbandingan Hasil

Hasil perbandingan performa antara model NASNetMobile dan ResNet50 berdasarkan empat metrik utama, yaitu akurasi, presisi, *recall*, dan *f1-score* dalam mengklasifikasikan tiga jenis penyakit daun mangga yaitu *antraknosa*, cendawan jelaga, dan ulat daun. Berdasarkan hasil, NASNetMobile secara konsisten menunjukkan performa lebih baik dibandingkan ResNet50 pada seluruh metrik, dengan akurasi tertinggi mencapai 96%, sementara ResNet50 hanya memperoleh 73%. Perbedaan ini menunjukkan bahwa NASNetMobile lebih efektif dalam mengenali pola visual dari masing-masing kelas penyakit dan memiliki kemampuan generalisasi yang lebih baik terhadap data uji. Keunggulan ini dapat dikaitkan dengan efisiensi arsitektur NASNetMobile dalam mengolah citra dan menyesuaikan fitur selama proses pelatihan.

4. Kesimpulan dan Saran

Model NASNetMobile menunjukkan performa terbaik dalam klasifikasi penyakit daun mangga dengan hasil evaluasi yang tinggi, yaitu akurasi

sebesar 96%, *precision* 96%, *recall* 96%, dan *f1-score* 96%. Sebaliknya, model ResNet50 hanya mencapai akurasi 73%, *precision* 76%, *recall* 71%, dan *f1-score* 73%. Hasil *confusion matrix* menunjukkan bahwa NASNetMobile mampu mengklasifikasikan ketiga kelas penyakit secara lebih seimbang, yaitu *antraknosa*, cendawan jelaga, dan ulat daun. Sementara itu, ResNet50 masih mengalami kesalahan klasifikasi yang cukup tinggi, terutama pada kelas cendawan jelaga dan ulat daun yang memiliki kemiripan pola tampilan permukaan daun.

Keunggulan utama NASNetMobile terletak pada efisiensi arsitekturnya yang ringan serta kemampuannya dalam mengenali ciri-ciri tampilan khas dari penyakit daun mangga, meskipun digunakan pada *dataset* berukuran sedang. Hal ini menunjukkan bahwa model tersebut lebih adaptif terhadap variasi bentuk dan permukaan daun yang umum ditemukan. Sebaliknya, kelemahan ResNet50 terletak pada kebutuhan data yang lebih banyak dan proses pelatihan yang lebih kompleks agar dapat mencapai performa yang optimal. Hasil ini memberikan kontribusi penting dalam pengembangan sistem klasifikasi penyakit tanaman berbasis citra, khususnya untuk mendukung penerapan teknologi pertanian yang lebih tepat.

Penelitian selanjutnya disarankan untuk mengeksplorasi model lain seperti EfficientNet, MobileNetV3, atau *Vision Transformer*, serta mengintegrasikan metode peningkatan data dan penyempurnaan lanjutan (*fine tuning*) guna meningkatkan akurasi dan kemampuan adaptasi sistem. Selain itu, model dapat dikembangkan dalam bentuk aplikasi berbasis *mobile* atau *web* agar dapat digunakan secara langsung oleh petani di lapangan sebagai alat bantu untuk mendiagnosis penyakit daun mangga secara

cepat dan tepat, sehingga dapat mempercepat pengambilan keputusan dalam pengendalian hama dan penyakit tanaman.

5. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Rian Julianto, S.Kom. yang telah memberikan bimbingan dan arahan dalam pengembangan penelitian ini, sehingga proses penyusunan dan pelaksanaan penelitian dapat berjalan dengan baik.

Daftar Pustaka:

- [1] N. Tati, "Peningkatan Produksi Bibit Mangga Agrimania Melalui Teknik Sambung Susu di Poktan Agrimania Kabupaten Indramayu," *IPB University*, 2021.
- [2] S. Utami, K. Baskoro, L. Khotimperwati, and M. Murningsih, "Keragaman Varietas Mangga (*Mangifera indica* L.) Di Kotamadya Semarang Jawa Tengah," *Bioma : Berkala Ilmiah Biologi*, vol. 21, no. 2, pp. 121–125, 2019, doi: 10.14710/bioma.21.2.121-125.
- [3] T. Ayu, V. Dwi, and A. E. Minarno, "Pendiagnosa Daun Mangga Dengan Model Convolutional Neural Network," *CESS (Journal of Computer Engineering System and Science)*, vol. 6, no. 2, pp. 230–235, 2021.
- [4] A. P. V. Hapsari, M. Hasdar, Daryono, and Y. Purwanti, "Kadar Vitamin C pada Mangga Arum Manis yang disimpan pada Suhu yang Berbeda," *Jurnal Kewarganegaraan*, vol. 6, no. 3, pp. 5475–5481, 2022.
- [5] A. Ayuningtyas, "Penggunaan Madu dan Mangga (*Mangifera Indica*) pada Penyembuhan Luka," *Journal of Health Science and Physiotherapy*, vol. 2, no. 1, pp. 111–115, 2020, doi: 10.35893/jhsp.v2i1.41.
- [6] N. Z. Afifah, R. I. Septiani, and R. A. Putri, "Dampak Perubahan Iklim Terhadap Produksi Dan Ekspor Pada Komoditi Kopi," *JURNAL ILMIAH RESEARCH STUDENT*, vol. 2, no. 1, pp. 473–480, 2025, doi: 10.61722/jirs.v2i1.3710.
- [7] BPS, "Produksi Mangga Di Indonesia Tahun 2023-2024." Accessed: Jul. 14, 2025. [Online]. Available: <https://share.google/NnUJysswdvNtCoLPF>
- [8] Harmiansyah, E. T. Oviana, R. Alpaizon, D. P. Khalifah, and P. Dwirota, "Sistem Deteksi Hama dan Penyakit Tanaman Mangga (*Mangifera indica* L.) Berbasis Deep Learning Menggunakan Model Pra Latih YOLOv5," *Jurnal Agrikultura*, vol. 35, no. 1, pp. 151–163, 2024, doi: 10.24198/agrikultura.v35i1.53834.
- [9] R. A. Rizvee *et al.*, "LeafNet: A proficient convolutional neural network for detecting seven prominent mango leaf diseases," *J Agric Food Res*, vol. 14, pp. 1–13, 2023, doi: 10.1016/j.jafr.2023.100787.
- [10] F. Gusnanto, N. Rahaningsih, R. D. Dana, and Mulyawan, "Optimasi Model Klasifikasi Tingkat Kematangan Buah Mangga Dengan Metode Yolo11," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 1, pp. 1773–1780, 2025, doi: 10.36040/jati.v9i1.12591.
- [11] I. J. Efendi, J. Muktabir, K. S. Billah, M. V. Al Qadri, W. O. Asriyani, and A. A. Ismoyo, "Diagnocar: Pendeteksian Otomatis Kerusakan Mobil Menggunakan Deep Learning Berbasis Citra Lewat Perangkat Mobile," *Simtek : Jurnal Sistem Informasi Dan Teknik Komputer*, vol. 10, no. 1, pp. 199–205, 2025, doi: 10.51876/simtek.v10i1.1547.
- [12] R. FATURRAHMAN, Y. S. HARIYANI, and S. HADIYOSO, "Klasifikasi Jajanan Tradisional Indonesia berbasis Deep Learning dan Metode Transfer Learning," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 11, no. 4, pp. 945–957, 2023, doi: 10.26760/elkomika.v11i4.945.
- [13] N. Hardi, "Komparasi Algoritma MobileNet Dan Nasnet Mobile Pada Klasifikasi Penyakit Daun Teh," *Jurnal Rekayasa Perangkat Lunak*, vol. 3, no. 1, pp. 50–55, 2022, doi: 10.31294/reputasi.v3i1.1313.
- [14] T. S. Winanto, C. Rozikin, and A. Jamaludin, "Analisa Performa Arsitektur Transfer Learning Untuk Mengidentifikasi Penyakit Daun Pada Tanaman Pangan," *Journal of Applied Informatics and Computing (JAIC)*, vol. 7, no. 1, pp. 74–87, 2023, doi: 10.30871/jaic.v7i1.5991.
- [15] G. A. S. Gado and P. N. Primandari, "Sistem Klasifikasi Berbasis Android untuk Penyakit Buah Kakao Menggunakan CNN NasNet-Mobile," *Jurnal Teknologi Terpadu*, vol. 11, no. 1, pp. 27–35, 2025, doi: 10.54914/jtt.v11i1.1821.