

Evaluasi Komparatif Transfer Learning Convolutional Neural Network untuk Klasifikasi Penyakit Daun Mangga

Nisrina Jacinda Mahardika*, Nur Nafi'iyah

Teknik Informatika, Fakultas Teknik, Universitas Islam Lamongan, Lamongan, Indonesia

Email: ¹*nisrinajacinda@gmail.com, ² mynaff@unisla.com

Email Penulis Korespondensi: nisrinajacinda@gmail.com

Submitted: 26/01/2026; Accepted: 28/02/2026; Published: 31/03/2026

Abstrak– Salah satu faktor utama yang dapat menurunkan produktivitas dan kualitas hasil pertanian adalah penyakit daun mangga. Penyakit yang diidentifikasi secara manual masih bergantung pada pengalaman petani, yang dapat menyebabkan kesalahan. Oleh karena itu, dapat menggunakan teknik transfer learning Convolutional Neural Network (CNN), tujuan penelitian ini adalah untuk mengklasifikasikan berbagai jenis penyakit yang menyerang daun mangga. Dengan 4.000 gambar, dataset yang digunakan berasal dari Kaggle dan terdiri dari delapan kelas: anthracnose, bacterial canker, cutting weevil, die back, gall midge, sehat, powdery mildew, dan sooty mold. Dalam eksperimen ini, empat arsitektur CNN ResNet50, ConvNeXt-Tiny, DenseNet121, MobileNetV2, dan yang lainnya dimodifikasi dengan Global Average Pooling, Batch Normalization, dan Lapisan Dense. Hasilnya menunjukkan bahwa ResNet50 dan ConvNeXt-Tiny memberikan tingkat akurasi terbaik, masing-masing 96,13% dan 95,88%, dengan skor F1 di atas 95%. Temuan ini menunjukkan bahwa pemilihan arsitektur CNN memiliki dampak yang signifikan.

Kata Kunci: Penyakit daun mangga; Transfer Learning; Convolutional Neural Network (CNN); Klasifikasi citra; ResNet50

Abstract– One of the main factors that can reduce the productivity and quality of agricultural products is mango leaf disease. Diseases identified manually still depend on the experience of farmers, which can lead to errors. Therefore, using the Convolutional Neural Network (CNN) transfer learning technique, the aim of this study was to classify various types of diseases that attack mango leaves. With 4,000 images, the dataset used was derived from Kaggle and consisted of eight classes: anthracnose, bacterial canker, cutting weevil, dieback, gall midge, healthy, powdery mildew, and sooty mold. In this experiment, four CNN architectures ResNet50, ConvNeXt-Tiny, DenseNet121, MobileNetV2, and others were modified with Global Average Pooling, Batch Normalization, and Dense Layers. The results showed that ResNet50 and ConvNeXt-Tiny provided the best accuracy rates, 96.13% and 95.88%, respectively, with an F1 score above 95%. These findings indicate that the choice of CNN architecture has a significant impact.

Keywords: Mango leaf disease; transfer learning; convolutional neural network; image classification; ResNet50.

1. PENDAHULUAN

Mangga (*Mangifera indica*) adalah salah satu jenis mangga yang paling populer di Indonesia dan memiliki nilai moneter yang tinggi. Ini juga berkontribusi besar pada pendapatan petani dan perekonomian nasional. Sentra produksi utama mangga Indonesia terletak di Jawa Timur, Jawa Barat, Jawa Tengah, dan beberapa wilayah Nusa Tenggara, menjadikannya salah satu produsen mangga terbesar di Asia Tenggara. Mangga memiliki potensi ekspor yang terus berkembang selain memenuhi kebutuhan domestik. Oleh karena itu, meningkatkan produktivitas dan kualitas buah mangga sangat penting untuk meningkatkan daya saing industri hortikultura nasional [1]. Meskipun demikian, berbagai hambatan sering menghalangi produktivitas tanaman mangga, salah satunya adalah penyakit daun. Penyakit daun mengganggu pertumbuhan vegetatif, mengurangi kemampuan tanaman untuk fotosintesis, dan berdampak langsung pada kuantitas dan kualitas buah yang dihasilkan. Anthracnose, bacterial canker, die back, powdery mildew, dan sooty mold adalah beberapa penyakit daun yang umum menyerang tanaman mangga. Karakteristik visual penyakit tersebut termasuk bercak, perubahan warna, nekrosis, dan lapisan jamur, yang sering mirip satu sama lain. Kemiripan gejala visual sering kali membuatnya sulit untuk dikenali, terutama pada tahap awal infeksi ketika perbedaan antara penyakit belum jelas [2], [3], [4].

Petani atau penyuluh pertanian masih menggunakan observasi visual manual untuk menemukan penyakit pada daun mangga di tingkat lapangan. Metode ini tidak pasti dan sangat bergantung pada pengalaman dan pengetahuan individu. Ketidaktepatan diagnosis dapat menyebabkan pemilihan fungisida atau bakterisida yang salah. Pada akhirnya, ini dapat menyebabkan biaya produksi yang terbuang, resistensi patogen, dan pencemaran lingkungan akibat penggunaan pestisida yang tidak tepat sasaran. Keterbatasan jumlah spesialis patologi tanaman juga meningkatkan kemungkinan penyakit akan terlambat dideteksi dan menyebarluaskan. Akibatnya, suatu sistem deteksi yang lebih akurat, cepat, dan objektif diperlukan untuk mendukung pengambilan keputusan berbasis data dalam pengelolaan kesehatan tanaman mangga.

Teknologi kecerdasan buatan, terutama dalam pengolahan citra digital dan deep learning, membuka jalan bagi pengembangan sistem deteksi penyakit tanaman secara otomatis [5], [6], [7], [8]. Convolutional Neural Network (CNN) adalah salah satu teknik klasifikasi citra yang paling banyak digunakan [9], [10]. CNN dapat secara otomatis mengekstraksi fitur visual yang kompleks seperti tekstur, warna, pola bercak, dan bagaimana lesi tersebar di daun tanpa perlu mengekstraksi fitur secara manual. Keunggulan ini membuat CNN menjadi metode

yang efektif untuk mengklasifikasikan penyakit tanaman dalam berbagai konteks. Berbagai arsitektur CNN telah digunakan untuk menentukan penyakit pada daun mangga dan tanaman hortikultura lainnya. Dengan tingkat akurasi yang relatif tinggi, arsitektur seperti VGG, ResNet, EfficientNet, dan MobileNet menunjukkan kinerja yang menjanjikan [11], [12], [13]. Namun, penelitian sebelumnya hanya membahas satu atau dua desain arsitektur tertentu, sehingga tidak memberikan gambaran menyeluruh tentang bagaimana perubahan desain memengaruhi performa klasifikasi. Ini terutama berlaku untuk kasus multi-kelas dengan tingkat kemiripan visual yang tinggi [14], [15], [16], [17].

Selain keterbatasan pada jumlah arsitektur yang dibandingkan, evaluasi performa penelitian sebelumnya biasanya hanya berfokus pada metrik akurasi semata. Padahal, dalam konteks klasifikasi multi-kelas dengan potensi ketidakseimbangan data dan kemiripan gejala visual, metrik seperti precision, recall, dan skor F1 menjadi sangat penting untuk menilai stabilitas prediksi dan kemampuan generalisasi model. Precision diperlukan untuk mengetahui sejauh mana model menghasilkan prediksi positif yang benar, sedangkan recall menunjukkan kemampuan model untuk mendeteksi seluruh kasus dalam kelas tertentu. Skor F1 memastikan bahwa model tidak hanya akurat di seluruh dunia, tetapi juga konsisten dalam mendeteksi setiap jenis penyakit, evaluasi multimetrik ini sangat penting.

Sebaliknya, ConvNeXt, sebuah arsitektur CNN modern, menawarkan pendekatan baru yang menggabungkan prinsip desain CNN klasik dengan peningkatan efisiensi dan kapasitas representasi fitur. Desain ConvNeXt memungkinkannya bersaing dengan arsitektur berbasis transformer dalam hal performa, tetapi tetap mempertahankan efisiensi komputasi khas CNN. Meskipun demikian, penelitian tentang arsitektur ini dalam klasifikasi penyakit daun mangga masih relatif terbatas. Arsitektur CNN konvensional seperti ResNet atau MobileNet jarang dibandingkan dengannya dalam kerangka eksperimen yang terstandarisasi.

Penelitian ini bertujuan untuk mengevaluasi dan membandingkan berbagai arsitektur CNN berbasis transfer learning dalam klasifikasi berbagai kelas penyakit daun mangga. Dataset yang digunakan dikumpulkan melalui Kaggle dan terdiri dari berbagai kelas penyakit daun yang relevan. Dataset telah melalui praproses yang sesuai untuk meningkatkan kualitas pelatihan model dan diseimbangkan untuk menghindari bias kelas.

Studi ini menerapkan empat arsitektur CNN: ConvNeXt-Tiny, DenseNet121, MobileNetV2, dan ResNet50. Untuk meningkatkan stabilitas pelatihan dan kemampuan generalisasi model, setiap arsitektur diubah dengan penambahan lapisan densitas, normalisasi batch, dan global rata-rata. Untuk memberikan analisis performa yang lebih mendalam, evaluasi dilakukan menggunakan metrik akurasi, precision, recall, dan skor F1.

Penyajian analisis komparatif yang sistematis antara arsitektur CNN modern dan konvensional dalam klasifikasi penyakit daun mangga dalam berbagai kelas adalah fokus utama penelitian ini. Ini dilakukan dengan menggunakan pendekatan evaluasi multimetrik. Hasil penelitian diharapkan dapat memberikan referensi berbasis bukti empiris mengenai trade-off performa antar arsitektur CNN. Selain itu, hasil penelitian akan membantu dalam menentukan model terbaik untuk mengembangkan sistem deteksi penyakit tanaman berbasis deep learning yang aplikatif dan efektif di lapangan.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Gambar 1 menunjukkan langkah-langkah dalam penelitian untuk mengklasifikasikan penyakit pada daun mangga. Penelitian ini menggunakan pendekatan transfer learning yang berbasis Convolutional Neural Network (CNN). Secara umum, penelitian ini terdiri dari beberapa langkah utama: pengumpulan dan persiapan dataset; pembuatan arsitektur model yang bergantung pada transfer learning; proses pelatihan (training); dan evaluasi kinerja model menggunakan metrik kuantitatif.

Dalam klasifikasi multi-kelas, keseimbangan dataset memastikan bahwa setiap kelas memberikan kontribusi yang sama untuk proses pembelajaran model. Ini dilakukan untuk menghindari bias kelas, atau imbalance kelas, yang dapat menyebabkan model cenderung lebih akurat pada kelas dengan lebih banyak data.

Sebelum proses instruksi, gambar secara keseluruhan diproses melalui proses praproses dengan mengubah ukurannya menjadi 224x224 piksel dan menggunakan tiga kanal warna (RGB). Jumlah ini dipilih karena memenuhi persyaratan input standar untuk arsitektur CNN yang diatur berbasis ImageNet. Nilai piksel juga dinormalisasi ke interval [0,1] untuk mempercepat proses konvergensi dan meningkatkan stabilitas pelatihan.

Dalam penelitian ini, empat arsitektur CNN pretrained (ConvNeXt-Tiny, DenseNet121, MobileNetV2, dan ResNet50) digunakan sebagai feature extractor. Arsitektur-arsitektur ini dipilih karena mewakili berbagai macam desain CNN modern dan konvensional dengan berbagai kompleksitas parameter.

Semua model menggunakan bobot awal dari ImageNet. Pendekatan transfer learning mempercepat proses pelatihan dan meningkatkan generalisasi karena memungkinkan model memanfaatkan fitur dasar yang telah dipelajari dari jutaan gambar umum, seperti deteksi tepi, tekstur, dan pola warna. Ini terutama berlaku dalam kasus di mana ukuran dataset lebih kecil daripada dataset ImageNet.


Pada bagian akhir masing-masing backbone, lapisan klasifikasi bawaan dihapus (`include_top=False`) dan digantikan dengan arsitektur kustom yang terdiri atas: Global Average Pooling (GAP); dengan menghitung rata-rata tiap kanal fitur, lapisan ini berfungsi untuk mereduksi dimensi map fitur menjadi vektor satu dimensi.

Dibandingkan dengan layer yang penuh terhubung konvensional, penggunaan GAP membantu mengurangi jumlah parameter yang diperlukan serta mengurangi kemungkinan overfitting. Dense Layer (128 neuron): sebelum proses klasifikasi akhir, tujuan lapisan ini adalah untuk mempelajari representasi fitur tingkat tinggi. Jumlah 128 neuron dipilih untuk mengimbangi efisiensi komputasi dan kapasitas representasi. Batch Normalization: digunakan untuk menstabilkan distribusi aktivasi selama pelatihan, mempercepat konvergensi, serta mengurangi risiko overfitting. Output Layer (Softmax, 8 neuron): lapisan akhir menggunakan fungsi aktivasi softmax dengan delapan neuron yang mewakili delapan kelas penyakit daun mangga. Softmax menghasilkan probabilitas untuk setiap kelas, dan kelas dengan probabilitas tertinggi dipilih sebagai hasil prediksi.

Optimizer Adam digunakan untuk melakukan proses pelatihan dengan rate learning sebesar 0,0001. Optimizer Adam efektif dalam mempercepat konvergensi pada berbagai arsitektur CNN karena mampu menyesuaikan laju pembelajaran untuk setiap parameter.

Untuk klasifikasi multi-kelas dengan representasi label dalam encoding one-hot, fungsi kerugian kategorikal cross-entropy digunakan. Model dilatih selama tiga puluh epoch dengan ukuran batch dua. Tujuan dari penggunaan ukuran batch kecil adalah untuk mempertahankan stabilitas pembaruan gradien dan menyesuakannya dengan keterbatasan memori komputasi. Model melakukan iterasi pada seluruh data pelatihan setiap kali hingga seluruh sampel diproses.

Selama proses pelatihan, kinerja model dipantau menggunakan akurasi pelatihan dan validasi untuk menemukan kemungkinan overfitting atau underfitting. Hasil pengujian menentukan model terbaik.



Gambar 1. Tahapan Penelitian

a. Evaluasi Model

Data uji yang tidak digunakan selama proses pelatihan digunakan untuk melakukan evaluasi. Tujuan penggunaan data uji terpisah adalah untuk mengetahui seberapa baik model dapat diterapkan pada data baru yang belum pernah dilihat sebelumnya. Dalam penelitian ini, empat metrik evaluasi digunakan. Accuracy (Rumus 1) mengukur proporsi prediksi yang benar terhadap seluruh data uji; Precision (Rumus 2) mengukur ketepatan model dalam memprediksi kelas; dan Recall (Rumus 3) mengukur kemampuan model untuk mendeteksi seluruh sampel dari kelas tertentu. F1-score (Rumus 4) adalah rata-rata harmonik antara akurasi dan recall. Untuk klasifikasi berbagai kelas, evaluasi multimetrik diperlukan karena akurasi saja tidak cukup untuk menunjukkan kestabilan model untuk setiap kelas. Sementara skor F1 menunjukkan keseimbangan antara keduanya, precision dan recall memberikan gambaran lebih rinci tentang kinerja deteksi masing-masing penyakit.

Metodologis yang terstandarisasi ini memungkinkan penelitian untuk melakukan perbandingan objektif dan terukur dari kinerja keempat arsitektur CNN. Metodologi ini menghasilkan analisis komparatif yang sah dan dapat diterapkan pada penelitian selanjutnya.

$$\text{Akurasi} = \frac{TP+TN}{TP+FP+TN+FN} \quad (1)$$

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

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

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

2.2 Dataset

Dataset yang digunakan dalam penelitian ini merupakan dataset sekunder yang diperoleh dari platform Kaggle [18], yang menyediakan kumpulan citra daun mangga dengan berbagai jenis penyakit. Dataset ini dipilih karena memiliki kualitas citra yang baik, variasi visual yang representatif, serta telah banyak digunakan dalam penelitian klasifikasi penyakit tanaman, sehingga memungkinkan evaluasi model secara objektif dan reproduktibel.

Dataset yang digunakan dalam penelitian ini terdiri atas delapan kelas penyakit daun mangga, yaitu anthracnose, bacterial canker, cutting weevil, die back, gall midge, healthy, powdery mildew, dan sooty mould. Setiap kelas memiliki jumlah data yang sama untuk menjaga keseimbangan distribusi kelas (class balance) serta meminimalkan potensi bias selama proses pelatihan dan pengujian model. Pembagian data dilakukan menggunakan skema tetap (fixed split), yaitu 400 citra untuk data pelatihan (training set) dan 100 citra untuk data pengujian (testing set) pada setiap kelas. Dengan demikian, setiap kelas memiliki total 500 citra. Secara keseluruhan, total dataset yang digunakan dalam penelitian ini berjumlah 4.000 citra, yang terdiri dari: 3.200 citra sebagai data pelatihan (8 kelas×400 citra), dan 800 citra sebagai data pengujian (8 kelas×100 citra).

Pendekatan pembagian data yang seimbang ini bertujuan untuk memastikan bahwa setiap kelas memiliki kontribusi yang sama dalam proses pembelajaran model. Dengan distribusi yang merata, model tidak akan cenderung lebih dominan mempelajari pola dari kelas tertentu, sehingga hasil evaluasi menjadi lebih objektif dan representatif terhadap seluruh kategori penyakit daun mangga yang diklasifikasikan. Rincian distribusi dataset pada masing-masing kelas disajikan pada Tabel 1.

Tabel 1. Dataset Penelitian

No	Kelas	Training	Testing	Total
1	Anthracnose	400	100	500
2	Bacterial canker	400	100	500
3	Cutting weevil	400	100	500
4	Die back	400	100	500
5	Gall midge	400	100	500
6	Healthy	400	100	500
7	Powdery mildew	400	100	500
8	Sooty mould	400	100	500
Total		3200	800	4000

3. HASIL DAN PEMBAHASAN

3.1 Hasil

Dalam penelitian ini, empat metrik utama akurasi, precision, recall, dan skor F1 digunakan untuk mengevaluasi kinerja model. Evaluasi multimetrik sangat penting untuk klasifikasi multikelas karena masing-masing arsitektur Convolutional Neural Network (CNN) dapat mengidentifikasi delapan kelas penyakit daun mangga. Tabel 2 menunjukkan hasil evaluasi kinerja model transfer learning. Hasil menunjukkan bahwa ResNet50 adalah yang terbaik dengan akurasi sebesar 96,13% dan skor F1 sebesar 96,10%. Hasil ini menunjukkan bahwa ResNet50 tidak hanya mampu memprediksi kelas secara keseluruhan dengan benar, tetapi juga memiliki keseimbangan yang baik antara kemampuan untuk menemukan sampel yang tepat (recall) dan meminimalkan kesalahan. Nilai skor F1, yang hampir setara dengan nilai akurasi, menunjukkan keseimbangan ini.

Karakteristik arsitektur residual learning ResNet50 dapat dikaitkan dengan kinerjanya yang luar biasa. Selama proses pelatihan, aliran gradien yang lebih stabil dimungkinkan oleh mekanisme koneksi pendek, yang memungkinkan model untuk dilatih lebih dalam tanpa kehilangan kinerja karena masalah vanishing gradient. Dengan struktur yang cukup dalam dan stabil, ResNet50 memiliki kemampuan untuk mengekstraksi fitur visual yang kompleks seperti distribusi lesi, pola nekrosis, perubahan warna, dan variasi tekstur bercak. Fitur-fitur ini merupakan karakteristik unik dari setiap penyakit daun mangga. Dalam kasus klasifikasi delapan kelas yang memiliki kemiripan visual yang cukup besar, kemampuan representasi fitur yang kuat merupakan komponen penting dalam meningkatkan akurasi klasifikasi.

Dengan akurasi sebesar 95,88% dan skor F1 sebesar 95,67%, ConvNeXt-Tiny menempati posisi kedua; perbedaan dalam kinerja antara ResNet50 dan ConvNeXt-Tiny sangat kecil, menunjukkan bahwa kedua arsitektur memiliki kapasitas yang sebanding untuk menampilkan fitur dalam konteks dataset yang digunakan. ConvNeXt-Tiny adalah arsitektur CNN kontemporer yang menggunakan prinsip desain yang diperbarui untuk meningkatkan kinerja dan efisiensi. Hasil penelitian menunjukkan bahwa arsitektur modern dapat bersaing dengan arsitektur residual konvensional seperti ResNet50 dalam klasifikasi penyakit daun mangga.

Precision dan recall ConvNeXt-Tiny yang tinggi menunjukkan kemampuan model untuk mempertahankan konsistensi prediksi pada sebagian besar kelas. Hal ini menunjukkan bahwa metode transfer learning dengan basis modern dapat menjadi alternatif yang kompetitif dalam pengembangan sistem klasifikasi berbasis gambar tanaman.

Sebaliknya, DenseNet121 memiliki performa yang paling buruk dengan akurasi sebesar 63,63% dan skor F1 sebesar 58,66%. Perubahan yang signifikan ini dibandingkan dengan ResNet50 dan ConvNeXt-Tiny menunjukkan bahwa mekanisme koneksi padat pada DenseNet121 tidak memberikan hasil yang optimal untuk dataset ini. Melalui koneksi langsung dari layer satu ke layer berikutnya, DenseNet secara teoritis dimaksudkan untuk meningkatkan aliran data antar layer. Namun, kemungkinan representasi fitur yang dihasilkan belum cukup diskriminatif untuk membedakan karakteristik visual antar kelas secara konsisten dalam kumpulan delapan kelas penyakit daun mangga yang memiliki variasi tekstur dan pola yang kompleks.

Ada ketidakseimbangan antara akurasi dan recall pada beberapa kelas. Skor F1 yang lebih rendah dibandingkan dengan akurasi DenseNet121 menunjukkan bahwa, meskipun beberapa prediksi benar, model masih

mengalami kesalahan yang cukup besar dalam menemukan atau membedakan kelas tertentu. Ini menunjukkan bahwa kemampuan generalisasi model pada data pengujian sangat terbatas.

MobileNetV2 memiliki performa menengah dengan akurasi sebesar 74,12% dan skor F1-sebesar 71,90%, yang menunjukkan adanya perbedaan antara kecepatan komputasi dan akurasi. MobileNetV2 memiliki arsitektur yang ringan dan berfokus pada efisiensi parameter dan kecepatan komputasi dengan menggunakan convolution yang terpisah secara menyeluruh. Hasil penelitian menunjukkan bahwa model ini kurang efektif dalam menangani klasifikasi multi-kelas dengan tingkat kemiripan visual antar penyakit yang tinggi, meskipun desain ini efektif untuk digunakan pada perangkat dengan sumber daya terbatas.

Tabel 2. Hasil Evaluasi


No	Model	Skor F1 (%)	Akurasi (%)	Precision (%)	Recall (%)
1	ConvNext-Tiny	95,67	95,88	96,12	95,88
2	DenseNet121	58,66	63,63	69,78	58,88
3	MobileNetV2	71,90	74,12	75,94	73,00
4	ResNet50	96,10	96,13	96,60	95,75

3.2 Pembahasan

Analisis kurva akurasi pada Gambar 2 memperjelas perbedaan dalam kinerja model. Pada ResNet50, kurva akurasi pelatihan dan validasi menunjukkan pola peningkatan yang stabil dan konvergen. Ada perbedaan yang relatif kecil antara akurasi pelatihan dan validasi, yang menunjukkan bahwa model tidak mengalami overfitting yang signifikan. Pola konvergensi ini menunjukkan bahwa proses optimisasi dilakukan dengan baik. Selain itu, model memiliki kemampuan untuk mempelajari pola visual yang relevan tanpa kehilangan kemampuan generalisasinya.

Selain itu, ConveXt-Tiny menunjukkan pola kurva yang konsisten dan stabil antara pelatihan dan validasi. Ini mendukung hasil kuantitatif dari Tabel 2 yang menunjukkan bahwa model memiliki kemampuan generalisasi yang baik. Stabilitas kurva akurasi menunjukkan bahwa model tidak hanya menghafal data instruksi tetapi juga mempelajari representasi fitur yang relevan untuk data yang ditambahkan.


Sebaliknya, kurva validasi akurasi DenseNet121 dan MobileNetV2 lebih rendah dan tidak selalu mengikuti peningkatan akurasi pelatihan. Proses pembelajaran fitur diskriminatif memiliki keterbatasan, menurut pola ini. Fluktuasi yang terjadi pada titik tertentu menunjukkan bahwa model belum sepenuhnya stabil dalam hal mengurangi kesalahan validasi data. Ini sejalan dengan nilai akurasi yang lebih rendah dan skor F1 yang lebih rendah dibandingkan dengan dua model terbaik.



Gambar 2. Grafik Akurasi Model

Gambar 3 menunjukkan kurva loss function selama proses training dan validation dari beberapa model transfer learning CNN yang digunakan dalam penelitian ini, yaitu ConvNeXt-Tiny, DenseNet121, MobileNetV2, dan ResNet50. Hasil tersebut juga didukung oleh analisis grafik loss function. Penurunan loss function yang lebih cepat dan stabil baik pada pelatihan maupun validasi ditunjukkan oleh ResNet50 dan ConvNeXt-Tiny. Penurunan loss function yang konsisten menunjukkan bahwa model secara bertahap mengurangi kesalahan prediksi dan mencapai kondisi konvergen. Oleh karena itu, DenseNet121 dan MobileNetV2 menunjukkan nilai validation loss yang lebih tinggi dan bervariasi. Ini menunjukkan bahwa proses optimisasi kedua model belum mencapai titik minimum global yang ideal.

Penyakit daun mangga memiliki gejala visual yang mirip, seperti perubahan warna kekuningan, bercak coklat, atau lapisan putih pada permukaannya. Karena kompleksitas masalahnya, klasifikasi delapan kelas penyakit daun mangga menjadi tantangan. Untuk membedakan pola yang halus dan spesifik dalam situasi ini, model membutuhkan kapasitas representasi fitur yang memadai. Dibandingkan dengan model yang lebih ringan atau dengan mekanisme konektivitas yang berbeda, arsitektur dengan kedalaman dan stabilitas pelatihan yang baik, seperti ResNet50, cenderung lebih mampu menangani kompleksitas ini.



Gambar 3. Grafik Loss Function Model

Penelitian ini menggunakan pendekatan yang lebih komprehensif dibandingkan dengan studi sebelumnya [19]. Penelitian ini menggunakan EfficientNetV2-S dan ResNet50 pada delapan kelas dengan total 4.000 gambar, serta beberapa skenario pembagian data. Hasil penelitian menunjukkan bahwa kedua arsitektur dapat menghasilkan akurasi yang tinggi dan dapat digunakan untuk aplikasi berbasis web. Studi ini berbeda karena menilai empat arsitektur dalam satu skema pembagian data yang konsisten dan seimbang, yang mencakup 400 data pelatihan dan 100 data pengujian per kelas. Studi ini juga mencakup delapan kelas, termasuk kelas sehat, sehingga tingkat kompleksitas klasifikasi meningkat. Untuk memberikan gambaran performa yang lebih menyeluruh, evaluasi menggunakan akurasi, precision, recall, dan skor F1.

Hasil menunjukkan bahwa ResNet50 dan ConvNeXt-Tiny memiliki performa di atas 95%, yang menunjukkan bahwa mereka memiliki konsistensi dan stabilitas yang baik. Hasil ini menunjukkan bahwa pemilihan arsitektur memiliki dampak yang signifikan terhadap bagaimana klasifikasi dilakukan. Dengan

kemampuan representasi fitur yang kuat dan proses pelatihan yang stabil, arsitektur lebih mampu menangani variasi tekstur dan pola pada gambar daun mangga.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa arsitektur CNN dengan kedalaman dan kemampuan representasi yang lebih baik memungkinkan klasifikasi penyakit daun mangga dengan lebih baik. Tidak semua model transfer learning menghasilkan hasil yang sama meskipun menggunakan dataset dan parameter pelatihan yang sama. Perbedaan kinerja antar arsitektur menunjukkan hal ini. Oleh karena itu, pilihan arsitektur adalah komponen penting dalam pembuatan sistem deteksi penyakit tanaman berbasis pembelajaran mendalam.

Penggunaan evaluasi multimetrik untuk mendapatkan interpretasi performa yang lebih komprehensif dan analisis komparatif yang sistematis terhadap berbagai arsitektur CNN dalam kondisi eksperimen yang seragam adalah fokus utama penelitian ini. Hasil ini dapat digunakan sebagai referensi penting di masa mendatang dalam menentukan model yang ideal untuk menerapkan sistem klasifikasi penyakit daun mangga; ini dapat mencakup aplikasi berbasis web dan sistem pendukung keputusan pertanian cerdas.

4. KESIMPULAN

Metode transfer learning berbasis Convolutional Neural Network (CNN) digunakan dalam penelitian ini untuk mengklasifikasi penyakit daun mangga ke dalam delapan kelas, menggunakan data gambar daun mangga. Dalam evaluasi performa, ResNet50 dan ConvNeXt-Tiny menunjukkan kinerja terbaik, dengan skor F1 sebesar 96,10% dan 95,67%, dan akurasi sebesar 96,13% dan 95,88%, di atas DenseNet121 dan MobileNetV2. Dalam penelitian ini, skor F1 dipilih sebagai metrik utama karena mampu menunjukkan keseimbangan antara precision dan recall pada skenario klasifikasi multi-kelas. Hasil penelitian menunjukkan bahwa struktur CNN modern dan konvensional tertentu dapat melakukan klasifikasi penyakit daun mangga dengan baik ketika dievaluasi secara menyeluruh dengan beberapa metrik. Penelitian ini berkontribusi dalam menyediakan referensi empiris untuk memilih arsitektur CNN yang tepat untuk tugas klasifikasi penyakit daun mangga berbasis citra. Hal ini ditunjukkan oleh analisis komparatif yang dilakukan pada dataset citra daun mangga yang telah dipersiapkan sesuai dengan pembagian kelas pada bagian dataset. Penelitian lebih lanjut dapat berkonsentrasi pada pengujian model menggunakan data lapangan untuk meningkatkan validitas praktis. Dengan mempertimbangkan keterbatasan sumber daya komputasi, model juga dapat dimasukkan ke dalam aplikasi berbasis perangkat *mobile* atau *edge computing*. Selain itu, untuk meningkatkan kinerja tanpa meningkatkan kompleksitas model, dapat dilakukan eksplorasi arsitektur CNN kecil atau mekanisme perhatian yang efektif.

REFERENCES

- [1] F. I. Tanesab, Y. C. Laatrehe, and M. alberto Wurlala, "Penerapan Metode CNN Dalam Mengklasifikasi Jenis Penyakit Pada Daun Mangga Menggunakan Arsitektur InceptionV3," *Jurnal Penelitian Nusantara*, vol. 1, no. 8, 2025.
- [2] M. F. A. Maulana, N. M. Anggadimas, and D. A. Sani, "Klasifikasi Citra Penyakit Daun Padi Dengan Metode CNN Menggunakan Arsitektur ResNet50V2," *CESS (Journal of Computer Engineering, System and Science)*, vol. 10, no. 2, 2025, doi: 10.24114/cess.v10i2.66960.
- [3] J. V. P. Putra, F. Ayu, and B. Julianto, "Implementasi Pendeteksi Penyakit pada Daun Alpukat Menggunakan Metode CNN," *Stains (Seminar Nasional Teknologi & Sains)*, vol. 2, no. 1, 2023.
- [4] E. H. Rachmawanto and H. P. Hadi, "OPTIMASI EKSTRAKSI FITUR PADA KNN DALAM KLASIFIKASI PENYAKIT DAUN JAGUNG," *Dinamik*, vol. 26, no. 2, 2021, doi: 10.35315/dinamik.v26i2.8673.
- [5] R. Adenia, A. E. Minarno, and Y. Azhar, "Implementasi Convolutional Neural Network Untuk Ekstraksi Fitur Citra Daun Dalam Kasus Deteksi Penyakit Pada Tanaman Mangga Menggunakan Random Forest," *Jurnal Repositor*, vol. 4, no. 4, 2024, doi: 10.22219/repositor.v4i4.32287.
- [6] M. Khoiruddin, A. Junaidi, and W. A. Saputra, "Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network," *Journal of Dinda : Data Science, Information Technology, and Data Analytics*, vol. 2, no. 1, 2022, doi: 10.20895/dinda.v2i1.341.
- [7] I. Yudistura and N. Nafiiyah, "Pengembangan Arsitektur CNN untuk Sistem Identifikasi Penyakit Daun pada Tanaman Padi," *Jurnal Sistem Komputer dan Informatika (JSON)*, vol. 7, no. 1, pp. 24–32, Sep. 2025, doi: 10.30865/json.v7i1.8849.
- [8] R. Suhendra, I. Juliwardi, and S. Sanusi, "Identifikasi dan Klasifikasi Penyakit Daun Jagung Menggunakan Support Vector Machine," *Jurnal Teknologi Informasi*, vol. 1, no. 1, 2022, doi: 10.35308/v1i1.5520.
- [9] M. A. N. Hidayat, Kusriani, and Hanafi, "Convolutional Neural Network Pada Identifikasi Varian Tanaman Anggur Menggunakan Resnet-50," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 10, no. 3, 2023.
- [10] F. Zaelani and Y. Miftahuddin, "Perbandingan Metode EfficientNetB3 dan MobileNetV2 Untuk Identifikasi Jenis Buah-buahan Menggunakan Fitur Daun," *Jurnal Ilmiah Teknologi Infomasi Terapan*, vol. 9, no. 1, 2022, doi: 10.33197/jitter.vol9.iss1.2022.911.
- [11] A. Setiawan, A. Nursafitri, E. V. Afnarista, H. Mulyasari, V. H. Zahwa, and Z. Suryadi, "Klasifikasi Penyakit Tanaman Mangga Menggunakan Algorithma CNN Pada Citra Daun Daun," *SENTIMETER (Seminar Nasional Teknologi Informasi, Mekatronika dan Ilmu Komputer)*, vol. 4, 2025.
- [12] I. P. Putra, R. Rusbandi, and D. Alamsyah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network," *Jurnal Algoritme*, vol. 2, no. 2, 2022, doi: 10.35957/algoritme.v2i2.2360.
- [13] Q. N. Azizah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet," *sudo Jurnal Teknik Informatika*, vol. 2, no. 1, 2023, doi: 10.56211/sudo.v2i1.227.

- [14] M. I. Rosadi and M. Lutfi, “Identifikasi Jenis Penyakit Daun Jagung Menggunakan Deep Learning Pre-Trained Model,” *Jurnal Explore IT!*, vol. 13, no. 2, 2021.
- [15] A. B. Prakosa, Hendry, and R. Tanone, “Implementasi Model Deep Learning Convolutional Neural Network (CNN) Pada Citra Penyakit Daun Jagung Untuk Klasifikasi Penyakit Tanaman,” *Jurnal Pendidikan Teknologi Informasi (JUKANTI)*, vol. 6, no. 1, 2023.
- [16] A. D. Nurcahyati, R. M. Akbar, and S. Zahara, “Klasifikasi Citra Penyakit pada Daun Jagung Menggunakan Deep Learning dengan Metode Convolution Neural Network (CNN),” *SUBMIT: Jurnal Ilmiah Teknologi Infomasi dan Sains*, vol. 2, no. 2, 2022, doi: 10.36815/submit.v2i2.1877.
- [17] E. Elfatimi, R. Eryigit, and L. Elfatimi, “Beans Leaf Diseases Classification Using MobileNet Models,” *IEEE Access*, vol. 10, 2022, doi: 10.1109/ACCESS.2022.3142817.
- [18] Swakat Ali, “Dataset Kaggle,” <https://www.kaggle.com/datasets/aryashah2k/mango-leaf-disease-dataset>.
- [19] K. Putri Ramadhani and M. Tarigan, “IMPLEMENTASI METODE CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI PENYAKIT DAUN MANGGA MENGGUNAKAN ARSITEKTUR EFFICIENTNETV2-S DAN RESNET50,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 3, 2025, doi: 10.36040/jati.v9i3.13571.