

Evaluasi Kinerja Model CNN Berbasis Transfer Learning dalam Klasifikasi Penyakit Daun Padi

Tsabit Yunan Al Rajab*, Nur Nafiyah

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

Email: ^{1,*}tsabityunan@gmail.com, ²mynaff@unisla.ac.id

Email Penulis Korespondensi: tsabityunan@gmail.com*

Submitted: 26/01/2026; Accepted: 23/02/2026; Published: 31/03/2026

Abstrak— Salah satu penyebab utama penurunan produktivitas pertanian adalah penyakit daun padi, yang berdampak langsung pada ketahanan pangan nasional. Tujuan dari penelitian ini adalah untuk mengevaluasi dan membandingkan kinerja sembilan arsitektur Convolutional Neural Network (CNN) berbasis transfer learning dalam klasifikasi penyakit daun padi. Arsitektur-arsitektur ini termasuk DenseNet121, InceptionV3, MobileNet, MobileNetV2, MobileNetV3Large, NASNetLarge, ResNet101, VGG16, dan Xception. Tiga kelas penyakit (Blast, Blight, dan Tungro) terdiri dari dataset Kaggle. Data asli digunakan sebagai data pengujian untuk menjaga objektivitas evaluasi, sedangkan data hasil augmentasi digunakan sebagai data pelatihan. Setiap model dilengkapi dengan lapisan Global Average Pooling, Batch Normalization, dan Dense (128). Selain itu, setiap model dilatih menggunakan optimizer SGD yang memiliki tingkat pembelajaran 0,001, epoch 30, ukuran batch 2, dan fungsi kehilangan kategoris crossentropy. Akurasi, precision, recall, dan skor F1 digunakan untuk menilai. Hasil penelitian menunjukkan bahwa MobileNetV3Large, VGG16, dan ResNet101 memiliki akurasi tertinggi sebesar 100,00%, 99,58%, dan 99,17%, masing-masing. Hasil ini menunjukkan bahwa kinerja klasifikasi penyakit daun padi dipengaruhi secara signifikan oleh pilihan arsitektur CNN yang tepat. Selain itu, temuan ini menunjukkan bahwa pembelajaran transfer dapat menjadi cara yang efektif untuk membangun sistem AI yang mendeteksi penyakit tanaman secara dini.

Kata Kunci: Convolutional Neural Network; Daun Padi; Klasifikasi; Penyakit; Transfer Learning.

Abstract— One of the main causes of declining agricultural productivity is rice leaf disease, which has a direct impact on national food security. The purpose of this study is to evaluate and compare the performance of nine transfer learning-based Convolutional Neural Network (CNN) architectures in rice leaf disease classification. These architectures include DenseNet121, InceptionV3, MobileNet, MobileNetV2, MobileNetV3Large, NASNetLarge, ResNet101, VGG16, and Xception. Three disease classes (Blast, Blight, and Tungro) comprise the Kaggle dataset. The original data is used as testing data to maintain the objectivity of the evaluation, while the augmented data is used as training data. Each model is equipped with Global Average Pooling, Batch Normalization, and Dense (128) layers. In addition, each model is trained using the SGD optimizer with a learning rate of 0.001, 30 epochs, a batch size of 2, and a categorical crossentropy loss function. Accuracy, precision, recall, and F1 score are used to evaluate. The results showed that MobileNetV3Large, VGG16, and ResNet101 had the highest accuracies of 100.00%, 99.58%, and 99.17%, respectively. These results indicate that the performance of rice leaf disease classification is significantly influenced by the choice of an appropriate CNN architecture. Furthermore, these findings suggest that transfer learning can be an effective way to build AI systems for early detection of plant diseases.

Keywords: Convolutional Neural Network; Rice Leaves; Classification; Disease; Transfer Learning.

1. PENDAHULUAN

Di Indonesia, padi (*Oryza sativa*) adalah komoditas pangan strategis yang berfungsi sebagai pilar utama ketahanan pangan nasional. Sebagai negara dengan lebih dari 278 juta orang, stabilitas produksi padi memengaruhi ketahanan sosial, ekonomi, dan politik. Pembangunan pertanian nasional sangat bergantung pada keberlanjutan produksi beras karena masyarakat bergantung pada beras sebagai bahan pangan pokok. Laporan tahun 2024 dari Badan Pusat Statistik (BPS) menunjukkan bahwa sekitar 10,21 juta hektar tanah digunakan untuk panen padi di seluruh negeri. Namun, produktivitas gabah kering giling (GKG) terus berubah dari tahun ke tahun. Serangan organisme pengganggu tumbuhan (OPT), terutama penyakit daun padi, adalah penyebab utama ketidakstabilan ini di beberapa sentra produksi seperti Jawa Tengah, Jawa Timur, dan Sulawesi Selatan [1]. Hawar daun bakteri (Bacterial Leaf Blight), Blast (*Pyricularia oryzae*), dan Bercak Coklat adalah beberapa penyakit daun yang paling mematikan. Penyakit-penyakit ini dilaporkan mampu menurunkan hasil panen hingga 30 hingga 70 persen dalam situasi epidemi yang tidak terkendali. Penurunan produktivitas dapat berdampak pada pendapatan petani selain meningkatkan risiko inflasi pangan dan instabilitas pasokan beras nasional. Oleh karena itu, deteksi dini dan pengelolaan penyakit yang tepat sangat penting untuk menjaga keberlanjutan produksi dan mengurangi kerugian ekonomi.

Penyakit daun padi biasanya diidentifikasi secara manual di tingkat lapangan oleh petani atau penyuluh pertanian melalui pengamatan visual. Metode ini tidak objektif dan sangat bergantung pada pengalaman seseorang. Problem menjadi semakin kompleks pada tahap awal infeksi, ketika gejala visual masing-masing penyakit menyerupai pola bercak, perubahan warna, dan tekstur daun. Kondisi tersebut menjadi lebih buruk karena kurangnya tenaga ahli patologi tanaman dan penyebaran penyuluh yang tidak merata [2], [3]. Penanganan sering kali tidak tepat sasaran, seperti penggunaan pestisida terlalu banyak tanpa diagnosis yang tepat, yang dalam jangka

panjang dapat merusak lingkungan, meningkatkan resistensi patogen, dan membuang biaya produksi. Kondisi ini menunjukkan bahwa sistem diagnostik yang lebih jujur, cepat, dan berbasis data diperlukan untuk membantu proses pengambilan keputusan yang berkaitan dengan pengelolaan kesehatan tanaman padi [4].

Peluang baru telah muncul dalam bidang pertanian cerdas (smart agriculture) sebagai hasil dari kemajuan teknologi kecerdasan buatan, khususnya pembelajaran mendalam. Convolutional Neural Network (CNN) adalah teknik klasifikasi gambar yang paling umum digunakan. Berbagai penelitian menunjukkan bahwa CNN dapat mengungguli teknik berbasis manual dalam klasifikasi penyakit tanaman dalam mengekstraksi fitur visual kompleks seperti tekstur, warna, bentuk lesi, dan distribusi pola penyakit pada daun [5], [6], [7]. Meskipun demikian, pelatihan model CNN dari awal (dari bawah ke atas) membutuhkan dataset berlabel yang besar dan sumber daya komputasi yang sangat besar. Infrastruktur komputasi dan ketersediaan dataset skala besar sering kali menjadi hambatan utama dalam konteks pertanian di negara berkembang. Pendekatan transfer learning berhasil mengatasi masalah ini. Dengan menggunakan model pralatih yang telah dilatih pada dataset besar seperti ImageNet, bobot awal jaringan memiliki representasi karakteristik umum yang dapat disesuaikan untuk domain penyakit tanaman. Metode ini telah terbukti dapat mempercepat proses instruksi, meningkatkan generalisasi model, dan mengurangi kebutuhan data dalam jumlah besar [8], [9], [10].

Dalam beberapa penelitian sebelumnya, transfer learning telah digunakan untuk mengklasifikasikan penyakit pada daun padi dan tanaman pangan lainnya. Misalnya, MobileNetV2 memiliki akurasi di atas 90% dengan keunggulan efisiensi komputasi yang mendukung penggunaan perangkat bergerak. Stabilitas pelatihan ResNet dan VGG sangat baik karena mekanisme residual dan kedalaman jaringan, yang memungkinkan representasi fitur yang lebih kaya [11], [12]. Selain itu, arsitektur seperti Inception, Xception, dan DenseNet meningkatkan efisiensi ekstraksi fitur visual yang kompleks melalui penggunaan strategi pergeseran secara menyeluruh dan penggunaan fitur [13].

Namun demikian, penelitian sebelumnya memiliki beberapa keterbatasan. Pertama, sebagian besar penelitian hanya membandingkan dua atau tiga arsitektur CNN yang berbeda; akibatnya, mereka tidak dapat memberikan gambaran yang mendalam tentang bagaimana masing-masing model berfungsi dalam skenario eksperimen yang sama. Kedua, evaluasi biasanya terbatas pada metrik akurasi, tanpa melakukan analisis menyeluruh terhadap skor F1, precision, dan recall yang penting untuk deteksi penyakit. Ini terutama berlaku untuk mengurangi kesalahan klasifikasi pada kelompok minoritas. Ketiga, dalam hal klasifikasi penyakit daun padi di Indonesia, belum banyak penelitian yang secara sistematis mengevaluasi arsitektur CNN modern seperti MobileNetV3 Large dan NASNetLarge sesuai dengan model konvensional. Akibatnya, pengetahuan tentang perolehan manfaat antara akurasi, sensitivitas, dan kompleksitas arsitektur model masih kurang [14], [15], [16], [17].

Analisis komparatif sistematis terhadap sembilan arsitektur CNN berbasis transfer learning (CNN): DenseNet121, InceptionV3, MobileNet, MobileNetV2, MobileNetV3 Large, NASNetLarge, ResNet101, VGG16, dan Xception diberikan dalam penelitian ini. Sembilan arsitektur tersebut dipilih untuk mewakili berbagai macam model, mulai dari yang berfokus pada efisiensi komputasi hingga yang berfokus pada akurasi tinggi. Untuk memberikan gambaran performa yang lebih menyeluruh dan seimbang, evaluasi dilakukan menggunakan metrik akurasi, precision, recall, dan skor F1.

Penelitian ini bertujuan untuk memberikan rekomendasi berbasis bukti eksperimental tentang cara terbaik untuk memilih arsitektur CNN untuk klasifikasi penyakit daun padi dengan menggunakan pendekatan komparatif yang terstandarisasi pada dataset dan konfigurasi pelatihan yang sama. Hasil penelitian ini diharapkan tidak hanya memberikan kontribusi akademik dalam pengembangan metode klasifikasi citra berbasis pembelajaran mendalam, tetapi juga mendukung penerapan sistem deteksi penyakit tanaman.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

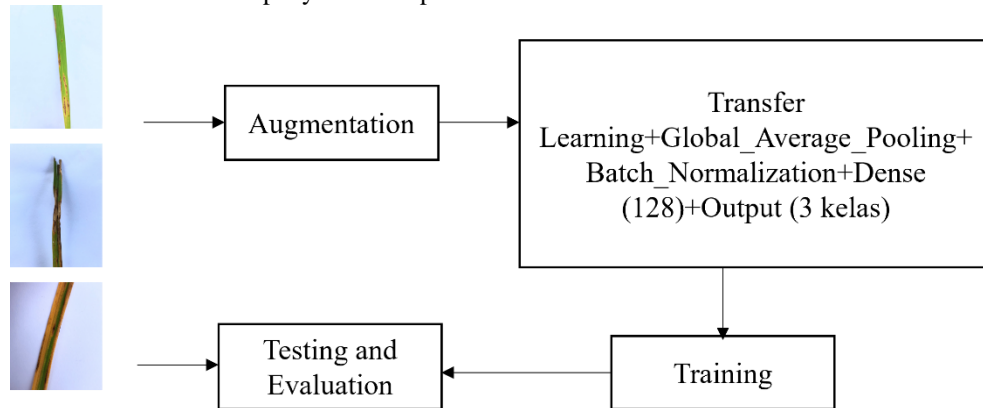
Penelitian yang menggunakan transfer learning dan sembilan arsitektur Convolutional Neural Network (CNN) untuk mengklasifikasikan penyakit daun padi digambarkan pada Gambar 1. Untuk memulai penyelidikan, kumpulan gambar daun padi yang dikumpulkan melalui Kaggle [18] telah dilabeli menurut jenis penyakit. Data set kemudian dibagi menjadi data pelatihan (training) dan data pengujian. Pada tahap pengujian, data asli tanpa modifikasi digunakan secara eksklusif untuk memastikan evaluasi model tetap objektif.

Data pelatihan mengalami proses augmentasi gambar selama tahap preprocessing. Proses augmentasi ini termasuk rotasi, flip horisontal, flip vertikal, penyesuaian kontras, dan pencahayaan. Tujuan dari teknik augmentasi ini adalah untuk meningkatkan keragaman data latih, mengurangi risiko overfitting, dan meningkatkan kemampuan generalisasi model terhadap variasi kondisi pencahayaan dan orientasi daun di dunia nyata.

Sembilan arsitektur CNN berbasis transfer learning: DenseNet121, InceptionV3, MobileNet, MobileNetV2, MobileNetV3 Large, NASNetLarge, ResNet101, VGG16, dan Xception digunakan untuk proses pelatihan menggunakan data augmentasi. Setiap model dimodifikasi dengan menggunakan bobot awal hasil pelatihan pada dataset ImageNet. Mereka juga menambahkan lapisan Global Average Pooling, Batch Normalization, dan lapisan dens dengan 128 neuron sebagai lapisan klasifikasi.

Untuk pelatihan model, optimizer Stochastic Gradient Descent (SGD) digunakan. SGD memiliki learning rate 0,001, ukuran batch 2, dan 30 epoch, serta loss function categorical cross-entropy. Untuk memastikan perbandingan kinerja yang adil dan objektif, konfigurasi pelatihan yang sama diterapkan pada seluruh arsitektur.

Setelah pelatihan selesai, kinerja masing-masing model dinilai dengan data uji asli yang tidak diubah. Analisis dilakukan dengan menggunakan metrik akurasi (Rumus 1), precision (Rumus 2), recall (Rumus 3), dan skor F1 (Rumus 4). Hasilnya memungkinkan analisis komparatif yang menyeluruh terhadap kemampuan setiap arsitektur CNN untuk mendeteksi penyakit daun padi.



Gambar 1. Diagram Alur Penelitian

a. Classification Evaluation Metrics

Metrik evaluasi klasifikasi digunakan untuk mengevaluasi kinerja model klasifikasi dalam penelitian ini. Rumus 1 menggunakan metrik akurasi, Rumus 2 menggunakan precision, Rumus 3 menggunakan recall, dan Rumus 4 menggunakan skor F1. Keempat metrik ini dihitung berdasarkan nilai Positif Benar (TP), Negatif Benar (TN), Positif Benar (FP), dan Negatif Benar (FN) yang diperoleh dari matriks confusion. Akurasi ditentukan dengan menghitung proporsi prediksi yang benar terhadap seluruh data pengujian. Kemampuan model untuk menemukan prediksi positif secara akurat diukur oleh precision dan recall. Untuk menyeimbangkan precision dan recall, skor F1 adalah rata-rata harmonik.

Keempat metrik ini digunakan untuk memberikan evaluasi menyeluruh terhadap kemampuan model untuk mengklasifikasikan penyakit daun padi. Sementara precision dan recall sangat penting dalam klasifikasi untuk mengurangi kesalahan prediksi, akurasi memberikan gambaran umum tentang kinerja model. Suara F1 menunjukkan bahwa kemampuan deteksi dan ketepatan prediksi seimbang.

$$Akurasi = \frac{TP+TN}{TP+FP+TN+FN} \tag{1}$$

$$Precision = \frac{TP}{TP+FP} \tag{2}$$

$$Recall = \frac{TP}{TP+FN} \tag{3}$$

$$F1 - score = \frac{2*Precision*Recall}{Precision+Recall} \tag{4}$$

2.2 Dataset

Untuk penelitian klasifikasi penyakit daun padi, dataset yang digunakan terdiri dari tiga kelas penyakit utama [18]: Blast, Blight, dan Tungro. Data yang digunakan dalam penelitian ini dibagi menjadi dua kelompok: data asli yang digunakan pada tahap pengujian dan data hasil augmentasi yang digunakan pada tahap pelatihan, masing-masing ditunjukkan dalam Tabel 1.

Untuk setiap kelas penyakit, ada delapan puluh gambar asli yang digunakan secara eksklusif sebagai data pengujian. Penggunaan gambar asli tanpa peningkatan pada tahap pengujian dimaksudkan untuk memastikan bahwa evaluasi kinerja model mewakili kondisi nyata di lapangan serta menghindari bias yang disebabkan oleh kemiripan antara data uji dan data latih.

Pada tahap pelatihan, jumlah data diperbesar melalui proses pengembangan gambar, sehingga setiap kelas memiliki 400 gambar yang dihasilkan dari pengembangan gambar. Rotasi, flip horisontal dan vertikal, penyesuaian kontras, dan pencahayaan adalah beberapa teknik augmentasi yang digunakan. Meningkatkan keragaman data pelatihan, meningkatkan kemampuan generalisasi model, dan mengurangi risiko overfitting karena keterbatasan jumlah data asli adalah tujuan dari pendekatan ini.

Secara keseluruhan, dataset yang digunakan dalam penelitian ini berjumlah 1.440 gambar, terdiri dari 240 gambar asli untuk pengujian dan 1.200 gambar hasil augmentasi untuk pelatihan. Data yang didistribusikan secara seimbang ke setiap kelas memastikan bahwa proses pelatihan dan evaluasi model dilakukan secara adil. Dengan demikian, perbandingan kinerja antar arsitektur CNN dapat dilakukan secara adil dan objektif.

Tabel 1. Dataset Penelitian

No	Kelas	Asli (Testing)	Augmentasi (Training)	Total
1	Blast	80	400	480
2	Blight	80	400	480
3	Tungro	80	400	480
	Total	240	1200	1440

3. HASIL DAN PEMBAHASAN

3.1. Hasil

Hasil evaluasi performa sembilan arsitektur Convolutional Neural Network (CNN) berbasis pembelajaran transfer yang digunakan untuk mengklasifikasikan penyakit daun padi disajikan dalam Tabel 2. Empat metrik utama digunakan untuk menilai evaluasi: akurasi, precision, recall, dan skor F1. Skor F1 memberikan gambaran yang luas tentang kemampuan model untuk mengklasifikasikan gambar secara tepat (akurasi), ketepatan prediksi positif (precision), kelengkapan deteksi kelas sebenarnya (recall), dan keseimbangan antara akurasi dan recall. Dalam klasifikasi penyakit tanaman, menggunakan lebih dari satu metrik sangat penting karena kesalahan dalam klasifikasi dapat memengaruhi keputusan pengendalian di lapangan.

Hasil pengujian menunjukkan bahwa model MobileNetV3Large memiliki performa terbaik dengan nilai akurasi, precision, recall, dan F1-masing-masing sebesar 100%. Nilai akurasi dan recall sebesar 100% menunjukkan bahwa model tidak hanya akurat secara keseluruhan, tetapi juga tidak menghasilkan kesalahan *false positive* sama sekali. Secara praktis, ini menunjukkan bahwa model dapat secara akurat membedakan penyakit daun dalam skenario eksperimen yang digunakan.

Tingginya kinerja MobileNetV3Large dapat dikaitkan dengan desain arsitekturnya, yang menggabungkan efisiensi komputasi dengan optimalisasi ekstraksi fitur melalui penggunaan convolution yang terpisah secara kedalaman, modul *squeeze* dan eksitasi, dan aktivasi *h-swish*. Kombinasi ini memungkinkan model menangkap pola visual yang kompleks seperti distribusi bercak, perubahan warna, dan tekstur lesi pada daun padi tanpa meningkatkan kompleksitas komputasi. Hasil ini menunjukkan bahwa arsitektur yang dirancang dengan baik tidak selalu kurang efektif daripada model yang lebih kompleks atau lebih dalam.

Selain itu, model VGG16 dan ResNet101 menunjukkan kinerja yang sangat baik dengan nilai akurasi sebesar 99,58% dan 99,17%, masing-masing, menunjukkan bahwa kedua model memiliki kemampuan ekstraksi fitur yang sangat baik, meskipun masih ada beberapa kesalahan klasifikasi yang kecil. Dengan struktur yang sederhana dan konsisten, VGG16 memiliki kemampuan untuk membangun representasi fitur yang stabil melalui tumpukan lapisan *convolutional* berukuran kecil (3x3). Selain itu, mekanisme pembelajaran residual ResNet101 memungkinkan jaringan berkembang lebih dalam tanpa kehilangan kinerja karena masalah *vanishing gradient*. Koneksi pendek pada ResNet101 memungkinkan propagasi gradien yang lebih stabil selama proses pelatihan, yang memungkinkan model untuk mempelajari representasi fitur yang lebih kompleks.

Akurasi DenseNet121 dan MobileNet, masing-masing sekitar 96%, masih sangat baik untuk tugas klasifikasi penyakit daun padi. DenseNet121 menggunakan konsep penggunaan kembali fitur melalui koneksi langsung antar lapis, yang meningkatkan representasi fitur dan meningkatkan efisiensi parameter. Sementara itu, MobileNet adalah model yang lebih ringan dan dirancang untuk perangkat dengan sumber daya terbatas, sehingga akurasinya sedikit lebih rendah.

Sementara NASNetLarge, misalnya, memiliki arsitektur hasil *neural architecture search* yang sangat kompleks, namun memiliki akurasi di bawah 90%, model MobileNetV2 mencapai 92,92%. Hasil ini menarik karena menunjukkan bahwa kompleksitas arsitektur yang tinggi tidak selalu berbanding lurus dengan akurasi yang lebih baik. NASNetLarge, misalnya, memiliki arsitektur hasil *neural architecture search* yang sangat kompleks, tetapi pada dataset ini tidak memberikan performa terbaik.

Tabel 2. Hasil Evaluasi Model

No	Model	F1-score (%)	Akurasi (%)	Precision (%)	Recall (%)
1	DenseNet121	96,26	96,25	96,23	95,83
2	InceptionV3	86,64	86,67	86,44	85,00
3	MobileNet	96,24	96,25	96,25	96,25
4	MobileNetV2	92,91	92,92	93,28	92,50
5	MobileNetV3Large	100,00	100,00	100,00	100,00
6	NasNetLarge	89,24	89,17	89,50	88,75
7	ResNet101	99,17	99,17	99,17	99,17
8	VGG16	99,58	99,58	99,58	99,58
9	Xception	87,54	87,50	88,51	86,67

3.2. Pembahasan

Gambar 2 menunjukkan grafik perbandingan akurasi dari model CNN yang diuji secara keseluruhan. Perbedaan yang jelas antara model dengan performa tertinggi dan terendah terlihat pada grafik. MobileNetV3Large menempati posisi tertinggi dengan perbedaan yang signifikan dibandingkan dengan model seperti InceptionV3 dan NASNetLarge. Temuan kuantitatif pada Tabel 2 diperkuat oleh perbedaan batang yang signifikan, yang juga mempermudah interpretasi performa relatif antar arsitektur.

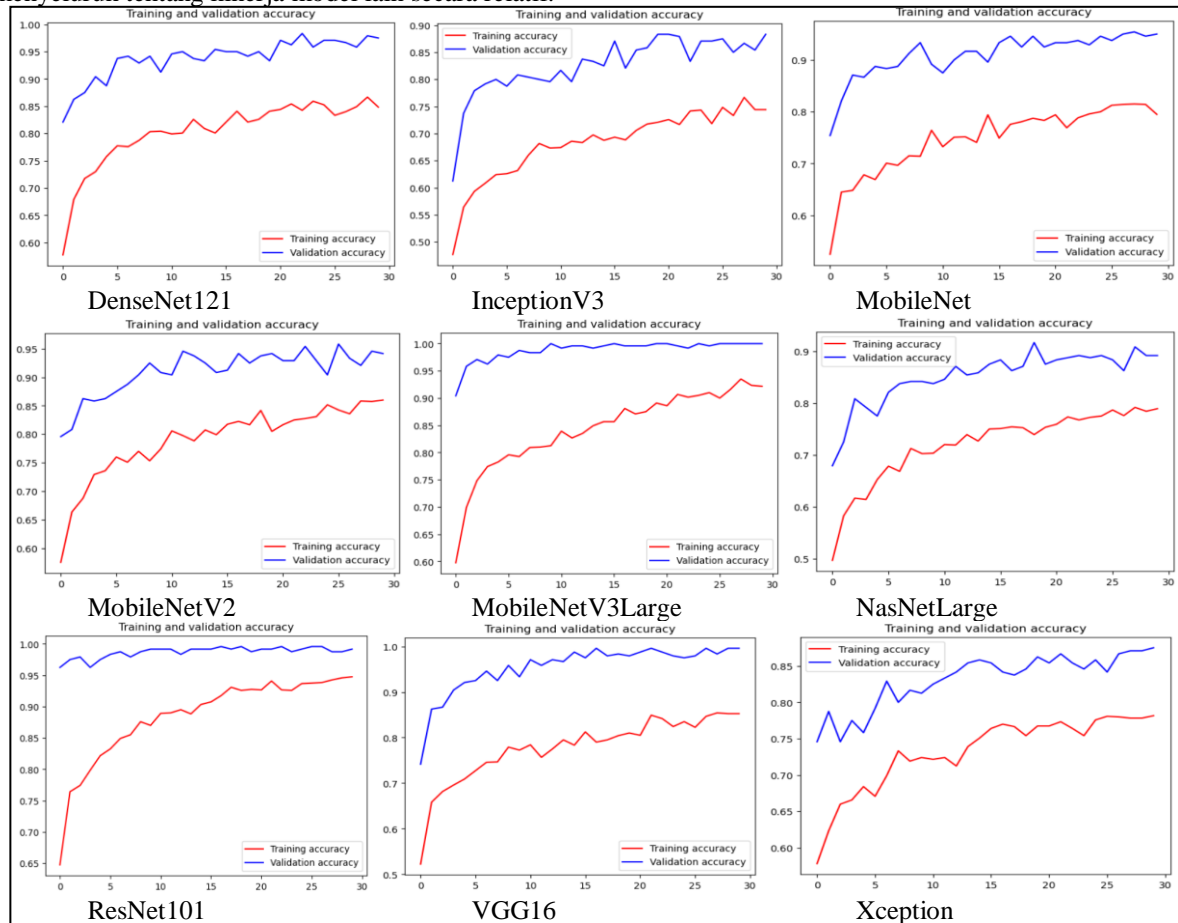
Selain itu, visualisasi ini menunjukkan bahwa model yang lebih ringan dan lebih kompleks dapat mengalahkan model yang lebih dalam dan kompleks. Hal ini menunjukkan bahwa, dalam klasifikasi penyakit daun padi, memilih arsitektur yang sesuai dengan karakteristik data lebih penting daripada menambah tingkat lapisan atau parameter.

Ada trade-off antara kompleksitas arsitektur dan kemampuan klasifikasi, yang merupakan temuan penting dari penelitian ini. Model seperti NASNetLarge dan Xception memiliki struktur kompleks dan banyak parameter, tetapi tidak selalu menghasilkan tingkat akurasi terbaik. Sebaliknya, MobileNetV3Large, yang dibuat menggunakan pendekatan efisiensi parameter, memiliki kinerja terbaik.

Hasil penelitian ini memiliki konsekuensi nyata bagi proses pengembangan sistem deteksi penyakit yang menggunakan perangkat lapangan. Sistem deteksi berbasis smartphone atau perangkat *edge computing* lebih masuk akal untuk diterapkan dalam konteks pertanian Indonesia daripada sistem yang memerlukan server berkapasitas tinggi. Oleh karena itu, model yang ringan tetapi akurat adalah yang terbaik.

Dengan dataset terbatas sebanyak 80 gambar per kelas, penelitian sebelumnya [11] yang menggunakan arsitektur CNN khusus untuk mengklasifikasikan tiga jenis penyakit daun padi menunjukkan akurasi sebesar 75%. Metode ini berfokus pada peningkatan kualitas gambar melalui equalization histogram dan CLAHE. Meskipun metode pra-proses membantu memperjelas fitur visual, keterbatasan jumlah data dan pelatihan awal menyebabkan model tidak bekerja dengan baik, terutama ketika membedakan penyakit dengan karakteristik visual serupa.

Studi lain [18] yang menggunakan InceptionV3 sebagai arsitektur tunggal menemukan akurasi 93,75% pada dataset 240 gambar. Meskipun hasilnya cukup baik, pendekatan satu arsitektur tidak memberikan analisis menyeluruh tentang kinerja model lain secara relatif.



Gambar 2. Grafik Akurasi Model

Studi ini melakukan evaluasi komparatif terhadap sembilan arsitektur CNN dalam skenario eksperimen yang seragam, berbeda dengan penelitian sebelumnya. Selain itu, penelitian ini menggunakan metode augmentasi yang lebih luas (*rotasi, flip horizontal, flip vertical, kecerahan, dan kontras*). Selain itu, untuk mencegah kebocoran data,

penelitian ini memastikan bahwa data pelatihan hasil augmentasi dan data pengujian asli terpisah satu sama lain. Metode ini meningkatkan kejujuran evaluasi dan validitas hasil.

Penelitian ini menunjukkan peningkatan yang signifikan dalam kinerja dibandingkan dengan studi sebelumnya. Akurasi di atas 99% (bahkan MobileNetV3Large mencapai 100%) menunjukkan bahwa transfer learning dengan arsitektur yang tepat jauh lebih baik daripada CNN kustom konvensional pada kumpulan data yang lebih kecil.

Secara praktis, temuan penelitian ini memberikan dasar ilmiah untuk memilih arsitektur CNN yang tepat untuk sistem deteksi penyakit daun padi yang dini. MobileNetV3Large adalah pilihan terbaik karena menggabungkan akurasi yang luar biasa dengan efisiensi komputasi. Model ini dapat diterapkan pada aplikasi mobile berbasis Android untuk membantu petani menemukan penyakit secara mandiri dan cepat.

Dalam hal kontribusi ilmiah, penelitian ini melengkapi kekurangan evaluasi komparatif CNN lintas arsitektur dalam konteks penyakit daun padi di Indonesia. Penelitian ini memberikan referensi empiris yang kuat bagi penelitian lanjutan di bidang pertanian cerdas dengan menilai sembilan model dalam kondisi eksperimen yang terstandarisasi dan menggunakan metrik evaluasi yang komprehensif.

Meskipun hasilnya sangat bagus, ada beberapa hal yang perlu diperhatikan. Pertama, dataset yang digunakan belum sepenuhnya menggambarkan variasi kondisi lapangan di seluruh wilayah Indonesia karena masih berasal dari sumber terbatas (Kaggle). Kedua, untuk memastikan bahwa model dapat digeneralisasi, akurasi 100% MobileNetV3Large harus diuji lebih lanjut pada dataset eksternal.

Untuk mengukur performa real-time secara kuantitatif, penelitian selanjutnya dapat mempertimbangkan validasi silang (cross-validation), pengujian pada dataset multi-lokasi, dan analisis waktu inferensi. Selain itu, teknik AI yang dapat dijelaskan (XAI) seperti Grad-CAM dapat membantu menjelaskan area citra yang berkontribusi pada keputusan model, meningkatkan kepercayaan pengguna.

4. KESIMPULAN

Berdasarkan hasil evaluasi, penelitian ini menunjukkan bahwa pendekatan transfer learning yang menggunakan berbagai arsitektur CNN dapat berhasil dalam klasifikasi penyakit daun padi. Hasil menunjukkan bahwa MobileNetV3Large adalah yang terbaik dengan nilai akurasi, precision, recall, dan F1 masing-masing 100,00%. Di belakangnya adalah VGG16 dan ResNet101, masing-masing dengan tingkat akurasi yang sangat tinggi. Hasil ini menunjukkan bahwa baik arsitektur ringan yang efektif maupun arsitektur yang lebih dalam dan kompleks memiliki potensi besar dalam sistem klasifikasi penyakit tanaman. Mereka hanya dapat digunakan jika mereka didukung oleh strategi yang tepat untuk pelatihan dan pengumpulan data. Secara ilmiah, penelitian ini menunjukkan bahwa perbedaan dalam desain arsitektur CNN menyebabkan karakteristik ekstraksi fitur yang berbeda. Kemampuan model untuk membedakan pola visual penyakit daun padi yang memiliki kemiripan tekstur dan warna secara langsung dipengaruhi oleh hal ini. Hasil menunjukkan bahwa evaluasi komparatif multi-arsitektur dalam satu kerangka eksperimen yang seragam lebih representatif daripada evaluasi dengan satu atau dua model saja. Oleh karena itu, temuan penelitian ini dapat berfungsi sebagai dasar ilmiah untuk memilih arsitektur CNN terbaik untuk membangun sistem pertanian presisi berbasis kecerdasan buatan yang akurat, stabil, dan berguna untuk mendeteksi penyakit padi secara dini. Hasil penelitian menunjukkan performa yang sangat baik, terutama pada arsitektur MobileNetV3Large, sehingga ada beberapa alasan untuk melanjutkan penelitian. Pertama, disarankan untuk menggunakan dataset yang lebih besar dan lebih beragam. Data ini harus mencakup berbagai kondisi pencahayaan, sudut pengambilan gambar, latar belakang alami lahan pertanian, dan tingkat keparahan penyakit yang berbeda. Ini penting untuk menguji kekuatan dan generalisasi model dalam kondisi lapangan nyata. Selanjutnya, untuk memastikan bahwa model tidak mengalami overfitting terhadap karakteristik dataset tertentu, validasi eksternal harus dilakukan menggunakan dataset dari berbagai wilayah atau musim tanam. Ini penting karena dataset ini memiliki akurasi 100%. Ketiga, penelitian selanjutnya memiliki kemampuan untuk menentukan apakah pendekatan yang lebih canggih seperti pembelajaran kelompok, Vision Transformer (ViT), atau hybrid CNN-Transformer mencapai peningkatan signifikan dalam kinerja dibandingkan dengan arsitektur CNN konvensional. Keempat, agar sistem dapat diterapkan dalam skenario smart farming, analisis lebih lanjut harus dilakukan mengenai komponen efisiensi komputasi seperti waktu inferensi, jumlah memori yang diperlukan, dan implementasi pada perangkat edge, seperti smartphone atau drone pertanian.

REFERENCES

- [1] U. I. Ismail, H. N. Chua, R. Nordin, and M. K. Ahmed, "A comprehensive review of deep learning approaches for rice disease detection: Datasets, methodologies, and future directions," 2025. doi: 10.1016/j.atech.2025.100976.
- [2] K. V. Deputy, K. Passi, and C. K. Jain, "Crop Disease Detection Using Deep Learning Techniques on Images," *Journal of Computer Science*, vol. 19, no. 12, 2023, doi: 10.3844/jcssp.2023.1438.1449.
- [3] R. S. Pambudi and M. Akbar, "Klasifikasi Jambu Air Berulat menggunakan Convolutional Neural Network," vol. 1, no. 1, pp. 136–139, 2023.

- [4] 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.
- [5] A. I. Hanifah and A. Hermawan, “Klasifikasi Kematangan Pisang Menggunakan Metode Convolutional Neural Network,” *Komputika : Jurnal Sistem Komputer*, vol. 12, no. 2, 2023, doi: 10.34010/komputika.v12i2.9999.
- [6] 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.
- [7] R. Firmansyah and N. Nafi’iyah, “Identifying Types of Corn Leaf Diseases with Deep Learning,” *Journal of Intelligent System and Computation*, vol. 6, no. 1, pp. 18–23, 2024, doi: 10.52985/insyst.v6i1.347.
- [8] P. Kakchingtabam, B. K. Sakshi, P. Jadav, and H. Harshavardhan, “A Comprehensive Survey of Transfer Learning Techniques and Applications Across Domains,” in *Proceedings of 5th International Conference on Soft Computing for Security Applications, ICSCSA 2025*, 2025. doi: 10.1109/ICSCSA66339.2025.11170934.
- [9] C. G. Simhadri, H. K. Kondaveeti, V. K. Vatsavayi, A. Mitra, and P. Ananthachari, “Deep learning for rice leaf disease detection: A systematic literature review on emerging trends, methodologies and techniques,” 2025. doi: 10.1016/j.inpa.2024.04.006.
- [10] N. Nafi’iyah, R. Wardhani, and E. Prakasa, “Identification of Banana Ripeness using Convolutional Neural Network Approaches,” in *Proceedings - 2023 10th International Conference on Computer, Control, Informatics and its Applications: Exploring the Power of Data: Leveraging Information to Drive Digital Innovation, IC3INA 2023*, 2023. doi: 10.1109/IC3INA60834.2023.10285749.
- [11] 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.
- [12] R. A. Saputra, S. Wasiyanti, A. Supriyatna, and D. F. Saefudin, “Penerapan Algoritma Convolutional Neural Network Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi,” *Swabumi*, vol. 9, no. 2, 2021, doi: 10.31294/swabumi.v9i2.11678.
- [13] 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.
- [14] 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.
- [15] U. Kulsum and A. Cherid, “Penerapan Convolutional Neural Network Pada Klasifikasi Tanaman Menggunakan ResNet50,” *SIMKOM*, vol. 8, no. 2, 2023, doi: 10.51717/simkom.v8i2.191.
- [16] 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.
- [17] 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.
- [18] S. Sheila, M. K. Anwar, A. B. Saputra, R. Pujiyanto, and I. P. Sari, “Deteksi Penyakit pada Daun Padi Berbasis Pengolahan Citra Menggunakan Metode Convolutional Neural Network (CNN),” *JURNAL MULTINETICS*, no. 1, 2023, [Online]. Available: <https://www.kaggle.com/datasets/tedisetiady/leaf->