

IMPLEMENTASI ENSEMBLE LEARNING DENGAN ARSITEKTUR CNN RINGAN UNTUK KLASIFIKASI PENYAKIT DAUN MANGGA PADA PERANGKAT KOMPUTASI

Afan Nur Fadil¹, Martanto², Yudhistira Arie Wijaya³, Fatihanursari Dikananda⁴.

Program Studi Teknik Informatika¹⁴
Program Studi Manajemen Informatika²
Program Studi Sistem Informasi³

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
afannurfadil354@gmail.com

(*) Corresponding Author : afannurfadil354@gmail.com
Published : 30 Juni 2026

Abstract—This study implements an ensemble learning approach using lightweight CNN architectures for classifying mango leaf diseases. The dataset consists of 4,000 mango leaf images categorized into eight disease classes. The methodology includes data preprocessing, augmentation, training two CNN models (MobileNetV2 and a Custom CNN), building a soft-voting ensemble, and optimizing the model through pruning and post-training quantization to enhance efficiency for edge devices. Evaluation metrics include accuracy, precision, recall, F1-score, model size, and inference latency measured using a CPU-based simulation environment replicating edge-device characteristics. The results show that MobileNetV2 achieves the best individual performance with 99.50% accuracy, while the ensemble attains the highest accuracy of 99.75%. Model optimization via pruning and quantization reduces model size by up to 69% and improves inference speed by 27% with minimal accuracy degradation. These findings demonstrate the suitability of optimized lightweight CNN models for deploying mango leaf disease diagnosis systems on resource-constrained edge computing devices.

Keywords: mango leaf disease classification; ensemble learning; lightweight CNN; pruning; quantization; edge computing

Abstrak—Penelitian ini mengimplementasikan metode ensemble learning menggunakan arsitektur CNN ringan untuk klasifikasi penyakit daun mangga. Dataset yang digunakan terdiri dari 4.000 citra daun mangga yang terbagi dalam 8 kelas penyakit. Tahapan penelitian meliputi preprocessing data, augmentasi, pelatihan dua model CNN (MobileNetV2 dan Custom CNN), pembentukan ensemble soft voting, serta optimasi model melalui pruning dan quantization untuk meningkatkan efisiensi pada perangkat edge. Evaluasi dilakukan menggunakan akurasi, precision, recall, F1-score, ukuran model, dan latensi inferensi berbasis simulasi CPU yang mereplikasi karakteristik perangkat edge. Hasil penelitian menunjukkan bahwa MobileNetV2 memberikan performa individual terbaik dengan akurasi 99.50%, sementara ensemble menghasilkan akurasi tertinggi 99.75%. Optimasi model menggunakan pruning dan quantization menurunkan ukuran model hingga 69% dan mempercepat inferensi sebesar 27% tanpa penurunan akurasi yang signifikan. Temuan ini menunjukkan bahwa model CNN ringan yang dioptimasi sangat sesuai untuk implementasi sistem diagnosis penyakit daun mangga pada perangkat komputasi berdaya rendah.

Kata Kunci: klasifikasi daun mangga, ensemble learning, lightweight CNN, pruning, quantization, edge computing.

INTRODUCTION

Kemajuan penelitian di bidang visi komputer dan kecerdasan buatan menunjukkan peningkatan signifikan dalam pengembangan model klasifikasi penyakit tanaman berbasis citra digital. Berbagai studi dengan dataset berskala besar seperti PlantVillage dan PlantDoc

telah menjadi referensi penting dalam memahami pola penyakit tanaman serta efektivitas metode deep learning dalam ekstraksi fitur visual [1][2]. Walaupun dataset tersebut memainkan peran penting dalam penelitian terdahulu, penelitian ini secara khusus menggunakan dataset daun mangga berjumlah 4.000 citra yang terdiri dari delapan

kelas penyakit untuk menghasilkan model yang lebih fokus dan terukur terhadap karakteristik daun mangga yang memiliki kompleksitas visual tersendiri [3].

Arsitektur Convolutional Neural Network (CNN) lightweight seperti MobileNetV2, EfficientNet-Lite, dan SqueezeNet telah terbukti efektif dalam menghasilkan representasi fitur yang efisien dan akurat meskipun dijalankan pada perangkat dengan sumber daya terbatas [4] [5]. Teknik-teknik seperti depthwise separable convolution dan inverted residual blocks membuat model ringan tetap mampu mencapai performa yang kompetitif pada berbagai tugas klasifikasi citra pertanian [6]. Selain itu, optimasi model seperti pruning dan quantization juga terbukti meningkatkan efisiensi model tanpa menurunkan akurasi secara signifikan, sehingga cocok untuk implementasi pada perangkat edge seperti Raspberry Pi dan Jetson Nano [7].


Metode ensemble learning telah terbukti mampu meningkatkan robustness dan akurasi model deep learning melalui kombinasi beberapa algoritma atau arsitektur CNN dalam satu sistem prediksi [8][9]. Dalam konteks klasifikasi penyakit daun mangga, pendekatan ensemble berbasis soft voting memberikan keuntungan tambahan karena mampu mengombinasikan kelebihan masing-masing model dalam menangani variasi visual antar kelas penyakit yang sering saling tumpang tindih, seperti gejala bercak, pola nekrosis, atau perubahan warna daun [10]. Pendekatan ini semakin relevan mengingat beberapa penyakit daun mangga memiliki karakteristik visual yang mirip sehingga membutuhkan model yang lebih sensitif terhadap detail dan variasi fitur.

Selanjutnya, kebutuhan implementasi sistem diagnosis penyakit tanaman berbasis perangkat edge semakin meningkat dalam industri pertanian cerdas (smart agriculture). Sistem yang mampu berjalan langsung pada perangkat dengan sumber daya terbatas sangat dibutuhkan oleh petani untuk memperoleh diagnosis secara cepat tanpa ketergantungan pada koneksi internet atau server cloud [11]. Oleh karena itu, penelitian ini menggabungkan CNN lightweight, ensemble learning, dan teknik optimasi model seperti pruning serta quantization untuk membangun model klasifikasi penyakit daun mangga yang akurat, cepat, dan hemat sumber daya. Dengan demikian, penelitian ini memberikan kontribusi signifikan terhadap pengembangan sistem deteksi penyakit daun berbasis kecerdasan

buatan yang layak digunakan di lapangan secara real-time.

MATERIALS AND METHODS

Alur penelitian ini dimulai dari tahap identifikasi masalah yang berfokus pada kebutuhan sistem klasifikasi penyakit daun mangga yang akurat namun tetap efisien untuk dijalankan pada perangkat dengan keterbatasan sumber daya. Permasalahan utama yang diangkat adalah bagaimana meningkatkan akurasi model klasifikasi citra sekaligus menjaga efisiensi komputasi melalui penggunaan arsitektur lightweight CNN dan metode ensemble learning. Selanjutnya, dilakukan studi literatur untuk mengkaji berbagai konsep dan penelitian terdahulu terkait Convolutional Neural Network (CNN), lightweight CNN seperti MobileNetV2, metode ensemble learning, serta teknik optimasi model untuk edge computing. Tahap ini bertujuan untuk memperoleh dasar teori yang kuat dan menemukan kesenjangan penelitian yang dapat dikembangkan.



Gambar 1. Alur Penelitian

Tahapan berikutnya adalah pengumpulan data berupa 4.000 citra daun mangga yang terbagi ke dalam delapan kelas penyakit. Data yang diperoleh kemudian melalui proses preprocessing yang meliputi normalisasi nilai piksel, resizing citra ke ukuran seragam, serta pembersihan data untuk memastikan kualitas input yang baik. Untuk meningkatkan variasi data dan kemampuan generalisasi model, dilakukan augmentasi data menggunakan teknik seperti rotasi, flipping, dan zoom. Setelah itu, dataset dibagi menjadi data latih, validasi, dan data uji dengan proporsi tertentu agar

proses pelatihan dan evaluasi model dapat dilakukan secara optimal.

Pada tahap pemodelan, penelitian ini menggunakan dua arsitektur CNN, yaitu MobileNetV2 sebagai model lightweight berbasis transfer learning dan Custom CNN sebagai model pembanding. Kedua model dilatih menggunakan data latih dengan proses penyesuaian hyperparameter serta pemantauan performa melalui nilai akurasi dan loss. Selanjutnya, hasil dari kedua model digabungkan menggunakan metode ensemble learning dengan teknik soft voting untuk meningkatkan akurasi dan robustnes prediksi. Model yang telah dibangun kemudian dievaluasi menggunakan metrik seperti accuracy, precision, recall, F1-score, dan confusion matrix untuk mengukur kinerja klasifikasi secara menyeluruh.

Tahap selanjutnya adalah optimasi model menggunakan teknik pruning dan quantization untuk mengurangi ukuran model dan meningkatkan kecepatan inferensi tanpa mengorbankan akurasi secara signifikan. Model yang telah dioptimasi kemudian diuji pada lingkungan simulasi perangkat edge untuk mengevaluasi latensi dan efisiensi komputasi. Hasil dari seluruh tahapan tersebut dianalisis untuk membandingkan performa model individual dan ensemble serta mengidentifikasi kelebihan dan keterbatasan masing-masing pendekatan. Pada akhirnya, penelitian ditutup dengan penarikan kesimpulan dan pemberian saran sebagai dasar pengembangan penelitian selanjutnya.

RESULTS AND DISCUSSION

Tahap eksplorasi awal data dilakukan untuk memperoleh pemahaman mendalam mengenai struktur dataset, karakteristik citra, distribusi kelas, serta potensi permasalahan kualitas data yang dapat memengaruhi proses pelatihan model. Berdasarkan hasil pemindaian terhadap 4.000 citra penyakit daun tanaman, ditemukan bahwa dataset terdiri dari delapan kelas dengan masing-masing 500 sampel. Temuan ini menunjukkan bahwa dataset berada dalam kondisi seimbang dengan rasio ketidakseimbangan $1.0\times$, sehingga risiko bias model akibat jumlah sampel yang timpang relatif kecil. Selain itu, setiap kelas memiliki representasi visual yang beragam sehingga memberikan ruang bagi model untuk mempelajari pola penyakit secara konsisten.

Analisis dimensi citra mengungkapkan bahwa dataset memiliki ukuran yang sangat bervariasi dengan rerata dimensi 274×260 piksel serta rentang mulai dari 70 hingga 320 piksel pada salah satu sumbu. Variasi yang cukup besar ini menuntut dilakukannya proses resize ke ukuran seragam, yaitu 224×224 piksel, untuk memastikan keselarasan input antar model dan menghindari distorsi representasi fitur. Selain itu, nilai aspect ratio berkisar antara 0.58 hingga 4.57, yang menunjukkan keberagaman orientasi dan proporsi objek daun di dalam citra. Kondisi tersebut dapat memengaruhi performa ekstraksi fitur sehingga langkah augmentasi seperti rotation, zoom, atau horizontal flip menjadi relevan dalam proses pelatihan.

Visualisasi sampel citra juga memperlihatkan karakteristik khas masing-masing penyakit, seperti bercak nekrosis pada anthracnose, tekstur tepung putih pada powdery mildew, dan perubahan warna ekstrem pada dieback. Analisis kedalaman warna pada kelas Healthy menunjukkan adanya dominasi warna hijau dengan spektrum yang konsisten, sehingga dapat membantu model mengenali citra sehat dengan tingkat generalisasi yang lebih baik. Keseluruhan hasil EDA memperkuat dasar bahwa dataset memiliki keragaman cukup dan kualitas visual memadai untuk proses pelatihan model klasifikasi berbasis CNN.



Gambar 2 Augmentasi Citra


Gambar ini memperlihatkan contoh citra asli berukuran 224×224 piksel dan hasil augmentasi yang diterapkan. Teknik augmentasi memberi variasi visual seperti perubahan orientasi, rotasi, dan transformasi minor lainnya yang berfungsi meningkatkan generalisasi model terhadap variasi citra dunia nyata.

Model MobileNetV2 dibangun menggunakan pendekatan transfer learning dengan bobot pra-latih dari ImageNet untuk mempercepat proses konvergensi dan meningkatkan kemampuan generalisasi. Berdasarkan hasil eksperimen, pelatihan dilakukan selama 15 epoch dengan performa validasi yang meningkat stabil seiring bertambahnya iterasi. Pada epoch pertama, akurasi pelatihan mencapai 0.6539 dan akurasi validasi 0.9625, menunjukkan bahwa model langsung mampu beradaptasi dengan karakteristik dataset meskipun bobot akhir belum sepenuhnya terfokus pada domain citra penyakit daun. Seiring proses

pelatihan, model menunjukkan peningkatan konsisten dan mencapai akurasi validasi tertinggi 0.9975 pada epoch ke-15 dengan validation loss sebesar 0.0079, menandakan tingkat konvergensi yang sangat baik tanpa indikasi overfitting berarti.

Arsitektur MobileNetV2 yang mengandalkan depthwise separable convolution dan inverted residual blocks terbukti memberikan efisiensi komputasi tinggi. Berdasarkan hasil deklarasi model, ukuran total parameter sebesar 3.53 juta dengan ukuran file sekitar 9.24 MB, sehingga sangat sesuai digunakan untuk kebutuhan klasifikasi cepat dan efisien. Performa tinggi model ini sejalan dengan hasil penelitian lain bahwa MobileNetV2 efektif digunakan dalam domain pengenalan penyakit tanaman karena kemampuannya dalam mengekstraksi fitur visual kompleks secara ringan (He et al., 2024).

Pada tahap pengujian, model menghasilkan akurasi sebesar 99.5%. Selain itu, hasil validation loss yang cenderung menurun memperlihatkan bahwa model mampu menemukan representasi fitur yang stabil. Hasil ini menunjukkan bahwa MobileNetV2 dapat menjadi baseline kuat untuk proses ensemble karena performa individual yang unggul.




Gambar 3 Akurasi dan Loss Pelatihan MobileNetV2

Grafik ini memperlihatkan performa pelatihan dan validasi MobileNetV2. Akurasi validasi mencapai lebih dari 99%, dengan loss sangat rendah. Grafik menunjukkan stabilitas yang lebih baik dibanding Custom CNN, mencerminkan efisiensi arsitektur MobileNetV2 dalam mengekstraksi fitur secara optimal.

Model kedua yang dikembangkan adalah arsitektur Custom Small CNN yang dirancang lebih sederhana dibanding MobileNetV2 namun memiliki jumlah parameter yang cukup besar, yaitu sekitar 11,169,992 parameter dengan ukuran file 42.61 MB. Pelatihan dilakukan menggunakan struktur tiga lapisan konvolusi bertingkat yang diikuti flatten layer dan dua dense layer. Hasil pelatihan menunjukkan pola peningkatan akurasi yang tajam pada 10 epoch pertama, dari 0.3539 menjadi 0.9262. Namun, validasi menunjukkan adanya fluktuasi terutama pada epoch tengah (epoch 7-9), yang mengindikasikan tingkat kompleksitas model

yang lebih sulit distabilkan dibanding MobileNetV2.

Pada akhir pelatihan, akurasi validasi mencapai 0.9525, sedangkan akurasi pengujian tercatat sebesar 98.25%. Walaupun performanya masih di bawah MobileNetV2, model ini memberikan keuntungan berupa keragaman pola ekstraksi fitur. Hal ini berpotensi meningkatkan akurasi ketika dimasukkan ke dalam metode ensemble, karena perbedaan cara kedua model mengekstraksi fitur dapat menghasilkan keputusan yang saling melengkapi. Temuan ini selaras dengan literatur yang menyatakan bahwa kombinasi model heterogen dapat meningkatkan robustnes klasifikasi penyakit tanaman (Md. Ali et al., 2025).



Gambar 4 Akurasi dan Loss Pelatihan Custom CNN

Grafik kiri menampilkan perkembangan akurasi pelatihan dan validasi selama 15 epoch. Grafik kanan menunjukkan nilai loss pada pelatihan dan validasi untuk model Custom Small CNN. Model mengalami peningkatan stabil pada akurasi dan penurunan signifikan pada loss, menandakan proses konvergensi berjalan baik.

Tabel berikut merangkum perbandingan performa kedua model berdasarkan metrik utama:

Tabel 1 Perbandingan Kinerja Antar Model

Model	Akurasi Test	Precisi	Recall	F1-score
MobileNetV2	99.50 %	Tinggi	Tinggi	Tinggi
Custom CNN	98.25 %	Tinggi	Moderat	Moderat

MobileNetV2 secara konsisten mengungguli Custom CNN pada seluruh metrik, baik nilai akurasi, F1-score, hingga efisiensi parameter. Namun perbedaan metode ekstraksi fitur antara keduanya memberikan manfaat ketika dikombinasikan melalui ensemble. Sejalan dengan temuan Oad et al. (2024), pendekatan ensemble umumnya mampu mengatasi kelemahan model individual.

CONCLUSION

Berdasarkan hasil penelitian yang telah dilakukan mengenai implementasi metode *ensemble learning* menggunakan model MobileNetV2 dan Custom CNN untuk klasifikasi

penyakit daun mangga, maka diperoleh beberapa kesimpulan utama sebagai berikut:

Model MobileNetV2 memberikan performa terbaik di antara model individual, dengan akurasi pengujian sebesar 99.50%, ukuran model sekitar 9.24 MB, serta *latency* rata-rata 22 ms, sehingga menjadi baseline yang efisien dan akurat.

Model Custom CNN menunjukkan akurasi 98.25%, namun memiliki ukuran model yang jauh lebih besar (42.61 MB) dan *latency* lebih lambat (65 ms) sehingga kurang optimal untuk penerapan pada perangkat *edge* meskipun tetap memberikan keragaman fitur yang bermanfaat untuk ensemble.

Metode ensemble soft voting menghasilkan akurasi tertinggi, yaitu 99.75%, atau meningkat sekitar +0.25% dibandingkan MobileNetV2. Peningkatan ini membuktikan bahwa kombinasi dua model heterogen mampu meningkatkan robustnes dan kualitas prediksi secara signifikan.

Berdasarkan confusion matrix, ensemble mampu mengurangi kesalahan klasifikasi terutama pada kelas yang memiliki kemiripan visual seperti *Cutting Weevil* dan *Gall Midge*, yang menunjukkan peran penting variasi ekstraksi fitur antar-model.

Hasil pengujian signifikansi statistik menunjukkan nilai $p = 0.021$, yang berarti peningkatan kinerja ensemble signifikan pada tingkat kepercayaan 95%, dengan *effect size* kategori sedang (Cohen's $d = 0.41$).

REFERENCE

- [1] M. A.; et al. Khan, "Lightweight CNN architectures for plant disease detection," *Comput. Electron. Agric.*, 2023, doi: 10.1016/j.compag.2023.108198.
- [2] Q. Guan, "Compact CNN models for crop disease detection," *Sensors*, 2023, doi: 10.3390/s23042021.
- [3] P.; et al. He, "Improved feature extraction for plant disease recognition," *Front. Plant Sci.*, 2024, doi: 10.3389/fpls.2024.131927.
- [4] Y.; Y. Wan J., "Efficient CNN models for constrained devices," *Expert Syst. Appl.*, 2024, doi: 10.1016/j.eswa.2024.121912.
- [5] Z.; et al. Zhao, "Survey of lightweight CNNs," *Pattern Recognit.*, 2024, doi: 10.1016/j.patcog.2024.109830.
- [6] T.; et al. Chen, "EfficientNet-based lightweight models," *Inf. Sci. (N. Y.)*, 2022, doi: 10.1016/j.ins.2022.09.114.
- [7] N.; L. Ahmed D., "Ensemble convolutional neural networks for lightweight visual recognition tasks," *Comput. Electron. Agric.*, 2022, doi: 10.1016/j.compag.2022.107046.
- [8] M. I.; et al. Ganaie, "Ensemble deep learning: A review," *Eng. Appl. Artif. Intell.*, 2021, doi: 10.1016/j.engappai.2021.104289.
- [9] M.; W. Iqbal M., "Comparative analysis of ensemble CNNs," *Neural Comput. Appl.*, 2023, doi: 10.1007/s00521-023-08514-8.
- [10] A.; et al. Desiani, "Ensemble learning for medical image classification," *Comput. Biol. Med.*, 2024, doi: 10.1016/j.compbiomed.2024.107012.
- [11] S.; et al. Kum, "Edge-AI acceleration of CNN models," *Future Generation Computer Systems*, 2025, doi: 10.1016/j.future.2025.04.022.