

Analisis Komparatif Kinerja MobileNetV2 dan EfficientNetB0 pada Klasifikasi Penyakit Daun Paprika dengan Teknik CLAHE

Peronika Sari^{1*}, Deasy Purwarningtias², Ali Mustopa³

^{1,2,3}Fakultas Teknik & Informatika, Program Studi Informatika, Universitas Bina Sarana Informatika, Kota Pontianak, Indonesia

Email: ^{1*}yelrevoras@gmail.com, ²deasy.dwg@bsi.ac.id, ³alimustopa.aop@bsi.ac.id

(*Email Corresponding Author: yelrevoras@gmail.com)

Received: 26 Juni 2026 | Revision: 30 Juni 2026 | Accepted: 4 Juli 2026

Abstrak

Penyakit bercak bakteri (bacterial spot) pada daun paprika sering kali sulit dikenali secara dini oleh petani karena identifikasi masih dilakukan secara visual dan manual, sehingga rawan subjektivitas dan membutuhkan waktu lama. Kondisi ini mendorong kebutuhan sistem klasifikasi otomatis berbasis deep learning yang mampu membedakan daun paprika sehat dan daun terinfeksi bakteri secara cepat dan konsisten. Penelitian ini bertujuan membandingkan kinerja dua arsitektur transfer learning, yaitu MobileNetV2 dan EfficientNetB0, dalam mengklasifikasikan citra daun paprika dari subset dataset PlantVillage, serta mengukur kontribusi teknik Contrast Limited Adaptive Histogram Equalization (CLAHE) yang diterapkan pada kanal luminance (L) di ruang warna LAB sebagai tahap pra-proses. Sebanyak 2.475 citra daun paprika, terdiri atas kelas bacterial spot dan sehat, dibagi menjadi data latih, validasi, dan uji dengan skema pelatihan head lalu fine-tuning pada 40 lapisan terakhir setiap arsitektur. Hasil pengujian pada data uji menunjukkan EfficientNetB0 mencapai akurasi 99,19% dan F1-score 99,19%, unggul dibandingkan MobileNetV2 yang memperoleh akurasi 95,70% dan F1-score 95,66%. Eksperimen ablasi memperlihatkan bahwa CLAHE memberi peningkatan akurasi sebesar 1,61 poin persentase pada EfficientNetB0, tetapi hampir tidak berpengaruh pada MobileNetV2. Visualisasi Grad-CAM mengonfirmasi bahwa kedua model memusatkan perhatian pada area lesi daun, bukan pada latar belakang citra. Temuan ini menunjukkan bahwa pemilihan arsitektur dan teknik pra-proses citra perlu disesuaikan secara spesifik dengan karakteristik dataset agar diperoleh kinerja klasifikasi yang optimal.

Kata Kunci: MobileNetV2, EfficientNetB0, CLAHE, Klasifikasi Penyakit Daun Paprika, Transfer Learning, Grad-CAM

Abstract

Bacterial spot disease on bell pepper (paprika) leaves is often difficult to detect at an early stage because farmers still rely on manual visual inspection, which is subjective and time-consuming. This condition motivates the need for an automatic deep learning-based classification system that can distinguish healthy pepper leaves from bacterially infected ones quickly and consistently. This study aims to compare the performance of two transfer learning architectures, MobileNetV2 and EfficientNetB0, in classifying pepper leaf images from a subset of the PlantVillage dataset, and to measure the contribution of Contrast Limited Adaptive Histogram Equalization (CLAHE) applied to the luminance (L) channel in the LAB color space as a preprocessing step. A total of 2,475 pepper leaf images, consisting of bacterial spot and healthy classes, were divided into training, validation, and test sets using a head-training scheme followed by fine-tuning of the last 40 layers of each architecture. Test results show that EfficientNetB0 achieved 99.19% accuracy and a 99.19% F1-score, outperforming MobileNetV2, which achieved 95.70% accuracy and a 95.66% F1-score. Ablation experiments revealed that CLAHE improved EfficientNetB0 accuracy by 1.61 percentage points but had almost no effect on MobileNetV2. Grad-CAM visualizations confirmed that both models focused their attention on lesion regions rather than background areas. These findings indicate that the choice of architecture and image preprocessing technique should be tailored to the specific characteristics of the dataset to achieve optimal classification performance.

Keywords: MobileNetV2, EfficientNetB0, CLAHE, Bell Pepper Leaf Disease Classification, Transfer Learning, Grad-CAM

1. PENDAHULUAN

Indonesia merupakan salah satu negara penghasil utama komoditas hortikultura, termasuk paprika (*Capsicum annum* L.), yang memiliki nilai ekonomi tinggi dan permintaan pasar yang terus meningkat. Namun demikian, produktivitas tanaman paprika di Indonesia masih sangat rentan terhadap serangan penyakit, salah satunya adalah bacterial spot yang disebabkan oleh bakteri *Xanthomonas campestris* pv. *vesicatoria*. Penyakit ini ditandai dengan munculnya bercak cokelat kekuningan pada permukaan daun yang dapat menyebabkan penurunan hasil panen secara signifikan jika tidak ditangani sejak dini [1]. Identifikasi penyakit yang selama ini dilakukan secara manual oleh petani maupun penyuluh pertanian mengandalkan pengamatan visual langsung terhadap gejala pada daun. Pendekatan ini memiliki sejumlah kelemahan mendasar, yaitu bersifat subjektif karena bergantung pada pengalaman pengamat, membutuhkan waktu yang relatif lama, serta rawan menghasilkan diagnosis yang keliru sehingga belum mampu memenuhi tingkat presisi yang dibutuhkan oleh praktik pertanian modern [2].

Salah satu pendekatan yang banyak digunakan untuk mengatasi permasalahan tersebut adalah sistem klasifikasi penyakit daun berbasis deep learning dengan pendekatan transfer learning. Transfer learning memungkinkan model memanfaatkan bobot yang telah dilatih sebelumnya pada dataset besar seperti ImageNet, sehingga proses pelatihan menjadi lebih singkat dan akurasi yang dicapai lebih tinggi dibandingkan pelatihan dari awal (training from scratch), terutama ketika data yang tersedia terbatas [3]. Selain itu, untuk mengatasi masalah kontras citra yang tidak konsisten, penelitian ini menerapkan Contrast Limited Adaptive Histogram Equalization (CLAHE) pada kanal luminance (L) di ruang warna LAB sebagai tahap praproses sebelum citra dimasukkan ke dalam model, sebuah pendekatan praproses yang juga terbukti efektif meningkatkan kontras area lesi penyakit pada klasifikasi daun tomat berbasis MobileNetV2 dan berhasil menekan ukuran model tanpa mengorbankan akurasi [4].


Sejumlah studi relevan telah dilaporkan dalam lima tahun terakhir. Pertama, Khoirunnisa [5] mengadakan uji komparasi antara MobileNetV2 dan VGG16 untuk mengenali tiga kategori penyakit pada daun cabai dengan 3.150 citra dan rasio pembagian data 70:30. Studi tersebut melaporkan MobileNetV2 mencatatkan akurasi 99,47% sementara VGG16 berada di angka 98,62%, menegaskan bahwa arsitektur ringan bisa mengungguli arsitektur yang lebih dalam untuk tanaman keluarga Solanaceae. Kedua, penelitian komparatif MobileNetV1 dan MobileNetV2 pada dataset 2.000 citra daun padi empat kelas di JIRE (2025) mendapati MobileNetV2 dengan 64 neuron dan rasio pembagian 8:1:1 memberikan kinerja terbaik; namun studi ini tidak menyertakan evaluasi dampak teknik pengolahan citra pra-proses terhadap performa akhir [6]. Ketiga, Gunawan [7] mengoptimalkan MobileNetV2 berbasis transfer learning pada citra primer daun jagung tiga kelas (600 gambar) dan mendapatkan akurasi 95%, mengungguli CNN standar yang hanya meraih 91%; akan tetapi penelitian tersebut tidak menyertakan perbandingan dengan arsitektur ringan kompetitor seperti EfficientNet-B0. Keempat, INTECOMS [8] menguji dua arsitektur yang sama—MobileNetV2 dan EfficientNetB0—untuk mengklasifikasikan lima varietas pisang pada 2.248 citra, dan menemukan EfficientNetB0 unggul dengan akurasi 80% berbanding MobileNetV2 75%; namun konteksnya adalah identifikasi jenis komoditas, bukan deteksi penyakit daun tanaman pangan. Kelima, Sayyid [9] secara khusus membandingkan Histogram Equalization (HE) dan CLAHE sebagai pra-proses citra dalam klasifikasi penyakit daun jagung menggunakan CNN dan menyimpulkan bahwa CLAHE menghasilkan akurasi lebih tinggi; namun penelitian itu belum menguji efektivitas CLAHE pada arsitektur transfer learning ringan seperti MobileNetV2 dan EfficientNet-B0. Keenam, As'ad dan Pramudya [10] mengimplementasikan MobileNetV2 dengan strategi two-stage transfer learning untuk deteksi real-time bacterial spot pada paprika dan membuktikan keunggulan arsitektur lightweight dibandingkan ResNet50 dari sisi akurasi, ukuran model, dan waktu inferensi, namun penelitian tersebut tidak membandingkan MobileNetV2 dengan EfficientNetB0 maupun mengevaluasi kontribusi teknik CLAHE. Terkait praproses citra, Yamaçlı dan Yildirim [11] membuktikan bahwa penyiangan dan peningkatan kontras citra dapat meningkatkan akurasi klasifikasi MobileNetV2 dan Xception pada penyakit tanaman.

Berdasarkan celah tersebut, penelitian ini bertujuan untuk: (1) membandingkan kinerja klasifikasi MobileNetV2 dan EfficientNetB0 pada citra daun paprika kelas bacterial spot dan sehat menggunakan pendekatan transfer learning; (2) mengevaluasi kontribusi teknik CLAHE terhadap peningkatan akurasi klasifikasi pada masing-masing arsitektur melalui perbandingan skema dengan dan tanpa CLAHE serta pengukuran kualitas citra menggunakan PSNR dan SSIM; dan (3) menginterpretasi hasil klasifikasi menggunakan visualisasi Grad-CAM untuk mengonfirmasi validitas fokus perhatian model. Penelitian ini diharapkan dapat memberikan rekomendasi berbasis bukti empiris mengenai kombinasi arsitektur CNN dan teknik praproses citra yang optimal untuk pengembangan sistem deteksi dini penyakit paprika yang akurat, efisien, dan dapat dipercaya, sehingga temuannya dapat direplikasi untuk pengembangan sistem serupa pada komoditas hortikultura lain di Indonesia.

2. METODOLOGI PENELITIAN

2.1 Alur Penelitian

Penelitian ini menggunakan pendekatan eksperimental kuantitatif yang mencakup tahapan pengumpulan data, praproses citra, pembagian data, augmentasi, pelatihan model, evaluasi kinerja, dan interpretasi model. Seluruh tahapan penelitian digambarkan pada diagram alur Gambar 1.



Gambar 1. Alur tahapan penelitian

Tahapan penelitian dimulai dari pengumpulan dataset citra daun paprika, dilanjutkan dengan praproses berupa penyesuaian ukuran citra (resizing) dan normalisasi piksel. Pada tahap ini, dataset diproses melalui dua skema secara paralel, yaitu skema dengan penerapan CLAHE dan skema tanpa CLAHE, untuk mengukur kontribusi teknik praproses tersebut secara terpisah. Data pada masing-masing skema kemudian dibagi menjadi data latih, validasi, dan uji dengan strategi stratified sampling agar proporsi kelas tetap seimbang. Pada tahap pelatihan, dua arsitektur CNN yaitu MobileNetV2 dan EfficientNetB0 dilatih menggunakan pendekatan transfer learning dengan bobot awal dari ImageNet. Model kemudian dievaluasi menggunakan metrik klasifikasi standar dan divisualisasikan menggunakan Grad-CAM untuk menganalisis area fokus model, sebelum akhirnya diintegrasikan ke dalam purwarupa antarmuka deployment sebagai bukti konsep penerapan praktis.

2.2 Dataset Penelitian

Dataset yang digunakan bersumber dari PlantVillage kelas Pepper bell yang terdiri dari dua label, yaitu Bacterial_spot (daun terinfeksi) dan healthy (daun sehat). Total dataset yang digunakan berjumlah 2.475 citra RGB dengan resolusi bervariasi, diambil pada kondisi lingkungan terkendali dengan pencahayaan dan latar belakang yang relatif seragam [10]. Dataset dibagi menjadi data latih, validasi, dan data uji dengan rasio 70:15:15 menggunakan stratified sampling, dengan rincian distribusi kelas dirangkum pada Tabel 1.

Tabel 1. Distribusi dataset penelitian

Kelas	Data Latih	Data Validasi	Data Uji
Bacterial_spot	698	149	150
Healthy	1.034	222	222
Total	1.732	371	372

Tabel 1 menunjukkan bahwa dataset memiliki sedikit ketidakseimbangan kelas dengan proporsi healthy lebih besar dibandingkan Bacterial spot.

2.3 Praproses Citra dan Teknik CLAHE

Seluruh citra terlebih dahulu diubah ukurannya menjadi 224x224 piksel agar sesuai dengan dimensi input standar MobileNetV2 dan EfficientNetB0, kemudian dinormalisasi menggunakan persamaan (1).

$$X_{norm} = \frac{X}{255}, X \in [0, 255] \quad (1)$$

Normalisasi bertujuan mempercepat konvergensi dengan meminimalkan magnitudo gradien dan mencegah saturasi fungsi aktivasi. Selanjutnya, teknik Contrast Limited Adaptive Histogram Equalization (CLAHE) diterapkan pada skema pertama untuk meningkatkan kontras lokal citra. Berbeda dengan histogram equalization global yang menyamaratakan kontras pada seluruh citra, CLAHE membagi citra ke dalam beberapa tile kecil dan melakukan ekualisasi histogram secara independen pada setiap tile, kemudian membatasi amplifikasi kontras melalui parameter clip limit untuk mencegah penguatan derau pada area dengan intensitas seragam [4], [12]. Pada penelitian ini, CLAHE diterapkan pada kanal L dari ruang warna Lab agar informasi warna daun (kanal a dan b) tetap terjaga, sebelum citra dikonversi kembali ke ruang warna RGB.

2.4 Arsitektur Model dan Strategi Pelatihan

Pada penelitian ini, augmentasi diterapkan hanya pada data latih melalui lapisan RandomFlip horizontal, randomRotation sebesar 0,08, RandomZoom sebesar 0,10 dan RandomContrast sebesar 0,10 yang seluruhnya dijalankan secara acak setiap batch selama proses training berlangsung, sedangkan data validasi dan data uji tetap menggunakan citra asli tanpa augmentasi agar evaluasi kinerja model tetap mencerminkan kondisi citra yang sebenarnya. Dan membandingkan dua arsitektur CNN yang direpresentasikan sebagai model dasar (base model) pre-trained ImageNet. MobileNetV2 menggunakan struktur inverted residual block dengan depthwise separable convolution sebagai inti desain berorientasi efisiensi, sehingga memiliki jumlah parameter yang jauh lebih kecil dibandingkan arsitektur CNN konvensional. EfficientNetB0 menggunakan pendekatan compound scaling yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan secara proporsional melalui blok Mobile Inverted Bottleneck Convolution (MBConv). Pada kedua arsitektur, seluruh lapisan konvolusi dasar dibekukan (frozen), kemudian classifier head kustom ditambahkan yang terdiri atas GlobalAveragePooling2D, Batch Normalization, lapisan Dense dengan aktivasi ReLU, Dropout, dan lapisan Softmax dengan dua neuron keluaran untuk klasifikasi biner. Model dilatih menggunakan optimizer Adam dengan skema pengurangan learning rate otomatis (ReduceLROnPlateau) dan penghentian dini (EarlyStopping) berdasarkan validation loss untuk mencegah overfitting. Proses pelatihan dijalankan secara terpisah untuk skema dengan CLAHE dan tanpa CLAHE pada masing-masing arsitektur, sehingga menghasilkan empat kombinasi eksperimen yang dapat dibandingkan secara langsung.

2.5 Evaluasi Kinerja

Kinerja klasifikasi dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score yang dihitung berdasarkan nilai True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN) pada confusion matrix, sebagaimana dirumuskan pada persamaan (2) hingga (5).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$


$$F1 - score = \frac{2*Precision*Recall}{Precision+Recall} \quad (5)$$

Selain metrik klasifikasi, kualitas citra hasil CLAHE dievaluasi secara kuantitatif menggunakan Peak Signal-to-Noise Ratio (PSNR) dan Structural Similarity Index Measure (SSIM) terhadap citra asli pada 50 sampel citra, untuk mengukur seberapa besar perubahan yang dihasilkan CLAHE tanpa merusak struktur visual daun. Terakhir, interpretasi model dilakukan menggunakan Gradient-weighted Class Activation Mapping (Grad-CAM) yang menghasilkan peta panas (heatmap) berdasarkan gradien kelas terhadap peta fitur pada lapisan konvolusi terakhir, sehingga area citra yang paling berkontribusi terhadap keputusan klasifikasi dapat divisualisasikan dan diverifikasi secara agronomis [13].

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pra-Pemrosesan Citra dengan CLAHE


Penerapan CLAHE pada citra daun paprika menghasilkan peningkatan kontras lokal yang cukup jelas, khususnya pada area lamina daun yang sebelumnya memiliki variasi kecerahan tidak merata akibat pencahayaan pengambilan gambar. Gambar 2 pada bagian metodologi menunjukkan bahwa tekstur urat daun dan gradasi warna hijau menjadi lebih tajam setelah penerapan CLAHE, tanpa menimbulkan artefak noise yang berlebihan. Untuk mengevaluasi perubahan ini secara lebih objektif, distribusi histogram RGB citra asli dan citra hasil CLAHE dibandingkan sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. Distribusi histogram RGB citra asli dan citra hasil CLAHE

Gambar 2 memperlihatkan bahwa histogram citra asli memiliki tiga puncak intensitas yang terpisah dan menumpuk pada rentang nilai piksel tertentu, mengindikasikan kontras yang terkonsentrasi pada rentang sempit. Setelah penerapan CLAHE, distribusi histogram menjadi lebih melebar dan merata di sepanjang rentang intensitas 0 hingga 255, yang menunjukkan bahwa informasi visual citra tersebar lebih merata dan detail pada area gelap maupun terang menjadi lebih terlihat. Untuk memastikan bahwa perubahan ini tidak merusak struktur asli citra secara berlebihan, dilakukan pengukuran kuantitatif menggunakan PSNR dan SSIM terhadap 50 sampel citra, dengan hasil ditunjukkan pada Gambar 3.

Metrik Kuantitatif CLAHE vs Original (n=50 sampel)




Gambar 3. Nilai rata-rata PSNR dan SSIM citra hasil CLAHE terhadap citra asli

Hasil pengukuran menunjukkan nilai rata-rata PSNR sebesar 21,101 dB dan SSIM sebesar 0,791. Nilai PSNR tersebut menunjukkan bahwa citra hasil CLAHE masih memiliki tingkat kemiripan yang cukup baik terhadap citra asli meskipun terjadi perubahan intensitas akibat peningkatan kontras. Nilai SSIM sebesar 0,791 yang mendekati 1 menunjukkan bahwa struktur spasial citra, seperti bentuk tepi daun dan pola urat daun, tetap terjaga dengan baik meskipun kontras lokal berubah cukup besar. Temuan ini konsisten dengan hasil Ahmed dkk [4], dan Ali dkk [12] yang melaporkan bahwa CLAHE mampu meningkatkan kontras citra daun tanpa mendistorsi fitur morfologis yang relevan untuk klasifikasi penyakit.


3.2 Dinamika Pelatihan Model

Proses pelatihan pada skema dengan CLAHE menunjukkan pola konvergensi yang berbeda antara kedua arsitektur, sebagaimana ditunjukkan pada Gambar 4.



Gambar 4. Kurva akurasi dan loss pelatihan MobileNetV2 dan EfficientNetB0 (dengan CLAHE)

MobileNetV2 menunjukkan konvergensi awal yang cepat dengan akurasi validasi mencapai kisaran 0,95 hingga 0,97 pada epoch-epoch awal, namun mengalami penurunan tajam yang bersifat sementara pada sekitar epoch ke-11, ditandai dengan lonjakan train loss hingga mendekati 0,7. Fenomena ini kemungkinan disebabkan oleh proses fine-tuning bertahap (unfreezing) pada lapisan atas jaringan yang untuk sementara mengganggu bobot yang telah konvergen sebelum stabil kembali pada epoch berikutnya. Setelah melewati fase tersebut, model kembali stabil dengan akurasi validasi akhir di atas 0,96. Sebaliknya, EfficientNetB0 menunjukkan pola konvergensi yang jauh lebih halus di sepanjang 20 epoch pelatihan, dengan train accuracy dan validation accuracy meningkat secara konsisten hingga mencapai kisaran 0,97 sampai 0,98 tanpa lonjakan loss yang berarti. Kestabilan ini mengindikasikan bahwa compound scaling pada EfficientNetB0 menghasilkan representasi fitur yang lebih robust terhadap perubahan skema fine-tuning dibandingkan MobileNetV2 pada dataset ini.



Gambar 5. Kurva akurasi dan loss pelatihan MobileNetV2 dan EfficientNetB0 (tanpa CLAHE)

Pola serupa juga teramati pada skema tanpa CLAHE sebagaimana ditunjukkan pada Gambar 5, dengan MobileNetV2 kembali menunjukkan lonjakan loss pada epoch yang hampir sama. Konsistensi pola ini pada kedua skema mengindikasikan bahwa fenomena tersebut lebih dipengaruhi oleh strategi pelatihan dan arsitektur model dibandingkan oleh praproses citra yang digunakan.


3.3 Kinerja Klasifikasi dengan CLAHE

Evaluasi pada data uji menunjukkan bahwa EfficientNetB0 secara konsisten mengungguli MobileNetV2 pada seluruh metrik ketika CLAHE diterapkan. Tabel 2 merangkum hasil evaluasi kedua model pada skema dengan CLAHE.

Tabel 2. Hasil evaluasi kinerja klasifikasi dengan CLAHE

Model	Accuracy	Precision	Recall	F1-score
MobileNetV2	0,9570	0,9591	0,9570	0,9566
EfficientNetB0	0,9919	0,9921	0,9919	0,9919

EfficientNetB0 mencapai akurasi 99,19%, unggul 3,49 poin persentase dibandingkan MobileNetV2 yang mencapai 95,70%. Keunggulan tersebut juga terlihat pada nilai precision, recall, dan F1-score, sehingga menunjukkan bahwa EfficientNetB0 memberikan performa yang lebih konsisten pada kedua kelas pengujian. Selisih ini juga konsisten pada metrik presisi, recall, dan F1-score, yang mengindikasikan bahwa keunggulan EfficientNetB0 tidak hanya terjadi pada satu kelas tertentu, melainkan merata pada kedua kelas. Detail kesalahan klasifikasi masing-masing model divisualisasikan melalui confusion matrix pada Gambar 6.



Gambar 6. Confusion matrix MobileNetV2 dan EfficientNetB0 pada skema dengan CLAHE

Berdasarkan Gambar 6, MobileNetV2 berhasil mengklasifikasikan 135 dari 150 citra Bacterial_spot dengan benar (recall kelas Bacterial_spot sebesar 90,0%) dan 221 dari 222 citra healthy dengan benar (recall kelas healthy sebesar 99,5%), menghasilkan total 16 kesalahan klasifikasi dari 372 citra uji. EfficientNetB0 menunjukkan hasil yang jauh lebih baik dengan seluruh 150 citra Bacterial_spot terklasifikasi benar (recall 100%) dan 219 dari 222 citra healthy terklasifikasi benar (recall 98,6%), menghasilkan hanya 3 kesalahan klasifikasi dari total 372 citra uji. Hasil ini menunjukkan bahwa EfficientNetB0 memiliki sensitivitas yang sangat tinggi dalam mendeteksi kelas Bacterial_spot, yang secara praktis penting karena kesalahan false negative pada penyakit tanaman dapat berakibat pada keterlambatan penanganan dan penyebaran infeksi yang lebih luas.


3.4 Kontribusi Pengaruh CLAHE terhadap Kinerja Klasifikasi

Untuk mengukur kontribusi CLAHE secara terisolasi, kedua arsitektur dilatih ulang pada data identik tanpa praproses CLAHE (hanya resize) menggunakan pembagian data yang sama persis dengan skema utama. Hasil perbandingan disajikan pada Tabel 3 dan Gambar 7.


Tabel 3. Perbandingan Evaluasi Model: Dengan CLAHE vs Tanpa CLAHE

Model	Praproses	Accuracy	Precision	Recall	F1-score	Training Time
MobileNetV2	Dengan CLAHE	0,9570	0,9591	0,9570	0,9566	85,70 s
MobileNetV2	Tanpa CLAHE	0,9570	0,9599	0,9570	0,9565	78,21 s
EfficientNetB0	Dengan CLAHE	0,9919	0,9921	0,9919	0,9919	138,45 s
EfficientNetB0	Tanpa CLAHE	0,9758	0,9763	0,9758	0,9759	105,56 s

Selain meningkatkan akurasi, hasil pada Tabel 3 juga menunjukkan perbedaan waktu pelatihan antar arsitektur. MobileNetV2 memerlukan waktu pelatihan sekitar 78,21 detik tanpa CLAHE dan 85,70 detik dengan CLAHE. Sebaliknya, EfficientNetB0 membutuhkan waktu lebih lama, yaitu 105,56 detik tanpa CLAHE dan 138,45 detik dengan CLAHE. Perbedaan ini menunjukkan bahwa MobileNetV2 lebih efisien secara komputasi karena memiliki arsitektur lightweight dengan jumlah parameter yang lebih sedikit dibandingkan EfficientNetB0, meskipun EfficientNetB0 memberikan performa klasifikasi yang lebih tinggi.




Gambar 7. Perbandingan metrik evaluasi antara skema dengan CLAHE dan tanpa CLAHE




Gambar 8. Kontribusi CLAHE terhadap accuracy dan F1-score (delta = dengan CLAHE – tanpa CLAHE)

Hasil pada gambar 7 dan gambar 8 menunjukkan pola yang menarik dan berbeda antara kedua arsitektur. Pada MobileNetV2, penerapan CLAHE praktis tidak memberikan perubahan pada akurasi (delta accuracy = 0,0000) dan hanya memberikan peningkatan yang sangat kecil pada F1-score (delta F1-score = +0,0001). Sebaliknya, pada EfficientNetB0, CLAHE memberikan peningkatan yang jauh lebih besar dan konsisten, yaitu +0,0161 pada accuracy dan +0,0161 pada F1-score, meningkatkan akurasi dari 0,976 tanpa CLAHE, dan menjadi 0,992 dengan CLAHE. Pada Gambar 7, nilai tersebut ditampilkan dalam bentuk pembulatan menjadi 0,976 dan 0,992 agar lebih mudah dibaca. Perbedaan confusion matrix ditunjukkan pada Gambar 9.



Gambar 9. Perbedaan confusion matrix

Berdasarkan Gambar 9, grafik batang tersebut memperlihatkan bahwa EfficientNetB0 secara konsisten berada di atas MobileNetV2 pada keempat metrik evaluasi, dengan selisih yang paling terlihat pada metrik recall dan F1-score.




Gambar 10. Confusion matriks (tanpa CLAHE)

Pada skema tanpa CLAHE, MobileNetV2 mengklasifikasikan 134 dari 150 citra Bacterial_spot dengan benar dan seluruh 222 citra healthy dengan benar (recall 100%), menghasilkan total 16 kesalahan klasifikasi, angka yang sama persis dengan skema CLAHE meskipun sebaran kesalahannya sedikit berbeda pada tingkat kelas. Kondisi ini menjelaskan mengapa metrik akurasi keseluruhan MobileNetV2 relatif tidak berubah akibat CLAHE, karena peningkatan pada satu kelas diimbangi oleh penurunan kecil pada kelas lain. Pada EfficientNetB0, sebaliknya, skema tanpa CLAHE hanya berhasil mengklasifikasikan 148 dari 150 citra Bacterial_spot dan 215 dari 222 citra healthy dengan benar, menghasilkan 9 kesalahan klasifikasi, tiga kali lebih banyak dibandingkan skema dengan CLAHE. Selisih ini menegaskan bahwa EfficientNetB0 memperoleh manfaat nyata dari peningkatan kontras lokal yang dihasilkan CLAHE, kemungkinan karena mekanisme compound scaling pada EfficientNetB0 lebih sensitif terhadap detail tekstur halus pada permukaan daun yang menjadi lebih tampak setelah CLAHE diterapkan.


Perbedaan sensitivitas ini dapat dijelaskan dari sudut pandang desain augmentasi dan arsitektur. MobileNetV2 pada penelitian sejenis umumnya dilatih dengan rentang augmentasi data yang relatif agresif, seperti rotasi, pergeseran, dan variasi kecerahan yang luas, sehingga model kemungkinan telah memperoleh invariansi terhadap variasi kontras selama pelatihan, membuat kontribusi tambahan dari CLAHE menjadi tidak signifikan. Sebaliknya, EfficientNetB0 dengan mekanisme squeeze-and-excitation pada setiap blok MBConv memberikan bobot lebih besar pada kanal fitur yang informatif, sehingga peningkatan kontras lokal dari CLAHE secara langsung memperkuat sinyal fitur yang relevan untuk klasifikasi. Temuan ini sejalan dengan hasil Yamaçlı dan Yildirim [11] yang melaporkan peningkatan akurasi setelah penyaringan dan peningkatan citra, namun juga menunjukkan bahwa manfaat teknik praproses citra tidak bersifat universal dan perlu diuji pada setiap arsitektur secara spesifik, sebagaimana ditekankan dalam eksperimen ensemble Ali dkk [12].

3.5 Interpretasi Model melalui Grad-CAM

Untuk memastikan bahwa kinerja klasifikasi yang tinggi tidak dihasilkan dari pembelajaran fitur yang keliru, seperti tekstur latar belakang atau bayangan, visualisasi Grad-CAM diterapkan pada kedua model. Hasil visualisasi ditunjukkan pada Gambar 11 dan Gambar 12.



Gambar 11. Visualisasi Grad-CAM pada beberapa sampel citra uji




Gambar 12. Visualisasi Grad-CAM EfficientNetB0 pada beberapa sampel citra uji

Heatmap Grad-CAM pada kedua gambar menunjukkan area dengan intensitas tertinggi (berwarna merah) terkonsentrasi pada bagian tengah lamina daun, khususnya pada area yang berdekatan dengan tulang daun utama dan area yang menunjukkan perubahan warna maupun tekstur permukaan. Pola ini konsisten pada berbagai sampel citra, baik pada citra dengan gejala bacterial spot yang jelas maupun pada citra daun sehat, mengindikasikan bahwa kedua model benar-benar mempelajari fitur morfologis daun, bukan artefak latar belakang berupa permukaan meja atau bayangan di sekeliling daun. Hal ini penting karena kesesuaian antara area perhatian model dan lokasi gejala yang relevan secara agronomis menjadi indikator keandalan model dalam konteks aplikasi nyata, sebagaimana ditekankan oleh Hoque dan Islam [13] pada studi Grad-CAM untuk penyakit daun kentang.

3.5 Prototipe Sistem Deployment

Sebagai bukti konsep penerapan praktis, hasil kedua model diintegrasikan ke dalam purwarupa antarmuka berbasis web yang memungkinkan pengguna memilih model, mengaktifkan visualisasi Grad-CAM, mengatur intensitas heatmap, serta membandingkan hasil prediksi dari MobileNetV2 dan EfficientNetB0 secara berdampingan. Purwarupa ini dibangun menggunakan framework Streamlit, yaitu framework berbasis Python yang bersifat open source dan dirancang untuk mempermudah pengembangan aplikasi web interaktif di bidang data science dan machine learning tanpa memerlukan keahlian pengembangan front-end secara mendalam [14]. Sebagai bentuk implementasi praktis, model MobileNetV2 dan EfficientNetB0 hasil pelatihan diintegrasikan ke dalam aplikasi web sederhana berbasis Streamlit. Aplikasi ini memungkinkan pengguna mengunggah citra daun paprika, memilih satu atau kedua model untuk dibandingkan, serta menampilkan hasil klasifikasi beserta tingkat keyakinan dan visualisasi Grad-CAM secara langsung, sebagaimana ditunjukkan pada Gambar 13. Fitur perbandingan model pada aplikasi ini memudahkan pengguna melihat konsistensi

prediksi antar arsitektur pada citra yang sama, sekaligus menjadi sarana edukasi mengenai area citra yang menjadi dasar keputusan model melalui visualisasi heatmap yang ditampilkan berdampingan dengan citra asli. Pemilihan Streamlit pada penelitian ini juga sejalan dengan praktik pada berbagai studi terapan lain yang mengintegrasikan analitik berbasis machine learning ke dalam aplikasi Streamlit untuk mempercepat proses dari model terlatih menuju sistem yang dapat digunakan langsung oleh pengguna akhir[15].



Gambar 13. Antarmuka prototipe sistem deteksi penyakit daun paprika

Pada gambar 13 yang ditampilkan, kedua model secara konsisten memprediksi kelas Bacterial Spot dengan tingkat keyakinan 100% pada citra uji yang diunggah, dan heatmap Grad-CAM menunjukkan fokus perhatian pada area bercak yang tampak secara visual pada daun. Konsistensi prediksi antar model pada purwarupa ini memberikan lapisan validasi tambahan sebelum sistem digunakan oleh pengguna akhir, sekaligus menunjukkan bahwa kedua arsitektur, meskipun berbeda dalam kompleksitas komputasi, dapat saling melengkapi dalam skenario penggunaan nyata di lapangan. Secara keseluruhan, hasil penelitian ini memperkuat temuan As'ad dan Pramudya [10]. Secara keseluruhan, hasil penelitian ini menunjukkan bahwa EfficientNetB0 lebih unggul dibandingkan MobileNetV2 pada seluruh metrik evaluasi untuk kasus klasifikasi penyakit daun paprika, dengan selisih akurasi mencapai 3,49 poin persen. Penerapan CLAHE pada kanal L ruang warna LAB terbukti memberikan kontribusi positif yang signifikan khususnya bagi EfficientNetB0, sementara pengaruhnya terhadap MobileNetV2 relatif marginal, sebuah temuan yang menegaskan bahwa efektivitas teknik pra-proses citra bersifat arsitektur-spesifik dan tidak dapat digeneralisasi begitu saja lintas model. Kombinasi antara akurasi tinggi, kualitas pra-proses yang terjaga (SSIM 0,79), dan interpretabilitas yang baik melalui Grad-CAM menjadikan pipeline yang diusulkan dalam penelitian ini kandidat yang kuat untuk diadopsi pada pengembangan sistem deteksi penyakit tanaman berbasis citra secara lebih luas.

4. KESIMPULAN

Penelitian ini berhasil membangun dan mengevaluasi sistem klasifikasi penyakit daun paprika berbasis transfer learning dengan membandingkan arsitektur MobileNetV2 dan EfficientNet-B0 yang dipadukan dengan teknik pra-pemrosesan CLAHE pada kanal luminance ruang warna LAB. Hasil pengujian pada 372 citra data uji menunjukkan bahwa EfficientNetB0 secara konsisten mengungguli MobileNetV2 dengan akurasi 99,19% berbanding 95,70% dan F1-score 99,19% berbanding 95,66%, meskipun MobileNetV2 unggul dari sisi efisiensi waktu pelatihan. Studi ablasi antara citra dengan dan tanpa CLAHE membuktikan bahwa kontribusi teknik pra-pemrosesan ini bersifat arsitektur-dependen, yaitu memberikan peningkatan akurasi yang cukup berarti sebesar 1,61 poin persentase pada EfficientNet-B0, namun relatif tidak berpengaruh signifikan pada MobileNetV2 yang tampaknya sudah cukup andal terhadap variasi kontras citra input. Analisis kuantitatif menggunakan PSNR sebesar 21,101 dB dan SSIM sebesar 0,79 mengindikasikan bahwa CLAHE mengubah distribusi intensitas piksel secara nyata tanpa merusak struktur morfologis daun secara berlebihan. Lebih lanjut, visualisasi Grad-CAM pada kedua model menunjukkan pola aktivasi yang secara konsisten terpusat pada area bercak dan lesi daun, bukan pada latar belakang citra, yang memperkuat kepercayaan bahwa keputusan klasifikasi model didasarkan pada fitur visual yang relevan secara agronomis dan bukan sekadar artefak dataset. Temuan ini memberikan implikasi praktis bahwa pemilihan arsitektur CNN untuk sistem deteksi penyakit tanaman perlu mempertimbangkan trade-off antara akurasi dan efisiensi komputasi sesuai dengan konteks penerapan, misalnya EfficientNet-B0 lebih sesuai untuk skenario yang mengutamakan akurasi maksimal, sedangkan MobileNetV2 lebih sesuai untuk penerapan pada perangkat dengan sumber daya terbatas. Sebagai tindak lanjut, prototipe aplikasi berbasis Streamlit yang dikembangkan dalam penelitian ini dapat menjadi dasar pengembangan sistem deteksi dini penyakit daun paprika yang siap digunakan oleh petani maupun penyuluh pertanian di lapangan. Penelitian selanjutnya disarankan untuk memperluas cakupan kelas penyakit,

memperbesar variasi kondisi pengambilan citra di lapangan, serta menguji arsitektur yang lebih baru guna meningkatkan generalisasi model pada kondisi dunia nyata.

REFERENCES

- [1] M. Dai *et al.*, “Pepper leaf disease recognition based on enhanced lightweight convolutional neural networks,” *Front. Plant Sci.*, vol. 14, no. August, pp. 1–18, 2023, doi: 10.3389/fpls.2023.1230886.
- [2] T. Sultan *et al.*, “LeafDNet: Transforming Leaf Disease Diagnosis Through Deep Transfer Learning,” *Plant Direct*, vol. 9, no. 2, p. e70047, 2025, doi: 10.1002/pld3.70047.
- [3] J. Pardede and A. S. Purohita, “The Advantage of Transfer Learning with Pre-Trained Model in CNN Towards Ct-Scan Classification,” *Khazanah Inform. J. Ilmu Komput. dan Inform.*, vol. 9, no. 2, pp. 155–161, 2023, doi: 10.23917/khif.v9i2.19872.
- [4] S. Ahmed, M. B. Hasan, T. Ahmed, M. R. K. Sony, and M. H. Kabir, “Less is More: Lighter and Faster Deep Neural Architecture for Tomato Leaf Disease Classification,” *IEEE Access*, vol. 10, pp. 68868–68884, 2022, doi: 10.1109/ACCESS.2022.3187203.
- [5] H. Y. Itsnaini Irvina Khoirunnisa, Abdul Fadlil, “Perbandingan Kinerja MobileNetV2 dan VGG16 dalam Klasifikasi Penyakit pada Citra Daun Tanaman Cabai,” *J. Inform. Sunan Kalijaga*, vol. 11, no. 1, pp. 70–82, 2026, doi: 10.14421/jiska.5075.
- [6] T. Turahman and K. A. , Erfan Hasmin, “Jurnal JTIK (Jurnal Teknologi Informasi dan Komunikasi) Analisis Perbandingan Metode Convolutional Neural Network,” vol. 9, no. 1, pp. 368–377, 2025, doi: 10.35870/jtik.v9i1.3218.
- [7] G. Tsaura Halwa Qur’ani, Saeful Bahri, “Optimalisasi Model Convolutional Neural Network dengan Arsitektur MobileNetV2 Pada Sistem Otomatis Deteksi Penyakit Tanaman Jagung Berdasarkan Citra Daun,” *Simpatik J. Sist. Inf. dan Inform.*, vol. 5, no. 2, pp. 82–91, 2025, doi: 10.31294/simpatik.v5i2.9976.
- [8] I. H. Citha Nastitie, “Perbandingan Metode Mobilenetv2 Dan Efficientnetb0 Untuk Klasifikasi Jenis Pisang,” *INTECOMS J. Inf. Technol. Comput. Sci.*, vol. 8, no. 6, pp. 1990–1999, 2025, [Online]. Available: <https://journal.ipm2kpe.or.id/index.php/INTECOM>
- [9] Mochammad Faisal Nur Sayyid, “Klasifikasi Penyakit Daun Jagung Menggunakan Metode CNN Dengan Image Processing HE Dan CLAHE,” *J. Tek. Inform. dan Teknol. Inf.*, vol. 4, no. 1, pp. 86–95, 2024, doi: 10.55606/jutiti.v4i1.3425.
- [10] E. R. P. Ahmad Nabilul As’ad, “Implementasi Deep Learning Berbasis MobileNetV2 untuk Deteksi Real- Time Bacterial Spot dengan Pendekatan Arsitektur Lightweight,” vol. 7, no. 4, pp. 2286–2299, 2026, doi: 10.47065/bits.v7i4.9252.
- [11] V. Yamaçlı and M. K. Yildirim, “Plant Disease Detection By Using Mobilentv2 and Xception on Filtered and Enhanced Images,” *Eng. Technol. J.*, vol. 9, no. 01, pp. 3266–3270, 2024, doi: 10.47191/etj/v9i01.02.
- [12] M. A. R. Ali Hussein Ali , Ayman Youssef, Mahmoud Abdelal, “An ensemble of deep learning architectures for accurate plant disease classification,” *Ecol. Inform.*, vol. 81, p. 102618, 2024, doi: 10.1016/j.ecoinf.2024.102618.
- [13] M. J. Hoque and M. S. Islam, “An Explainable and Lightweight CNN Framework for Robust Potato Leaf Disease Classification Using Grad-CAM Visualization,” *Appl. AI Lett.*, vol. 7, no. 1, p. e70011, 2026, doi: 10.1002/ail2.70011.
- [14] G. A. Syafarina, “Implementasi Framework Streamlit Sebagai Prediksi Harga Jual Rumah Dengan Linear Regresi lain menjelaskan bahwa Pegujian akurasi dilakukan dengan mengukur Root Mean Squared Error (RMSE). Nilai rata-rata jual rumah yang akurat di Kota Banjarmasin , mengg,” vol. 7, no. 2, pp. 121–125, 2023, doi: 10.47002/metik.v7i2.680.
- [15] N. Aendikov and A. Azayeva, “Integration of GIS and machine learning analytics into Streamlit application,” *Procedia Comput. Sci.*, vol. 231, pp. 691–696, 2024, doi: 10.1016/j.procs.2023.12.160.