

Komparasi CNN dan SVM untuk Klasifikasi Penyakit Daun Jagung Berbasis CLAHE dan Explainable AI

Comparing CNN and SVM for Corn Leaf Disease Classification Using CLAHE and Explainable AI

Muhammad Azka Najih Al Wafa*, Adzhal Arwani Mahfudh, Masy Ari Ulinuha

Fakultas Sains dan Teknologi, Program Studi Teknologi Informasi, Universitas Islam Negeri Walisongo, Semarang, Indonesia

Email: ¹*2208096108@student.walisongo.ac.id, ²adzhal@walisongo.ac.id, ³ulinuha@walisongo.ac.id

Email Penulis Korespondensi: 2208096108@student.walisongo.ac.id

Received: 19/08/2026, Revised: 09/09/2026, Accepted: 21/09/2026, Published: 22/09/2026

Abstrak—Penurunan produktivitas jagung akibat penyakit daun masih menjadi persoalan serius, sementara pengamatan manual bersifat subjektif. Model yang akurat pun sulit dipercaya bila dasar keputusannya tidak dapat ditelusuri. Kontribusi penelitian ini terletak pada pengujian terkendali yang memisahkan sumbangan CLAHE dari pengaruh arsitektur, penetapan parameter pra-pemrosesan berdasarkan pengujian, serta perbandingan langsung kedua metode pada data dan perlakuan yang identik. Penelitian ini membandingkan Convolutional Neural Network (CNN) dan Support Vector Machine (SVM) untuk klasifikasi penyakit daun jagung pada kondisi pengujian yang setara, dengan Contrast Limited Adaptive Histogram Equalization (CLAHE) sebagai pra-pemrosesan bersama dan LIME sebagai alat penelusur keputusan. Pengujian menggunakan 4.188 citra dalam empat kelas dengan pembagian 80:20 tanpa augmentasi. CNN berbasis EfficientNet-B0 mencapai akurasi 94,98%, unggul 2,52 poin atas SVM berbasis fitur GLCM dan histogram warna yang mencapai 92,46%. Selisih ini jauh lebih tipis daripada yang umum diasumsikan. Pendekatan hibrida yang memadukan fitur EfficientNet-B0 dengan pengklasifikasi SVM justru mencatat akurasi tertinggi 95,33%, menandakan keunggulan CNN bersumber dari kualitas representasi fiturnya, bukan dari lapisan pengambilan keputusan. SVM juga memproses seluruh data uji seratus enam puluh kali lebih cepat tanpa akselerator grafis. Pengujian ablasi memperlihatkan manfaat CLAHE bergantung pada metode: SVM naik 1,19 poin, sedangkan CNN tidak menunjukkan perbaikan. Visualisasi LIME menunjukkan sebagian besar wilayah berpengaruh berada pada area bercak, meskipun sebagian masih terdeteksi di latar belakang. Temuan ini menempatkan SVM sebagai pilihan yang tetap relevan ketika sumber daya komputasi terbatas.

Kata Kunci: CLAHE; CNN; Explainable AI; Penyakit Daun Jagung; SVM

Abstract—Corn productivity losses from leaf diseases remain a serious problem, while manual observation is subjective and accurate models are hard to trust when their decisions cannot be traced. The contribution of this research lies in controlled testing that isolates the contribution of CLAHE from architectural influences, establishing preprocessing parameters based on empirical testing, and directly comparing both methods under identical data and treatment conditions. This study compares Convolutional Neural Network (CNN) and Support Vector Machine (SVM) for corn leaf disease classification under equivalent conditions, using CLAHE preprocessing and LIME. Testing used 4,188 images in four classes. The CNN based on EfficientNet-B0 reached 94.98%, outperforming the SVM based on GLCM and color histogram features at 92.46%. This 2.52-point margin is narrower than assumed, and the additional SVM errors concentrate in one class. A hybrid combining EfficientNet-B0 features with an SVM classifier reached 95.33%, indicating the CNN advantage stems from its feature representation rather than its decision layer. The SVM also predicted one hundred sixty times faster without a graphics accelerator. An ablation test shows the CLAHE benefit is method-dependent: the SVM gained 1.19 points, the CNN did not. LIME shows most influential regions fall on lesion areas, though some appear in the background. These findings keep the SVM relevant when computational resources are limited.

Keywords: CLAHE; CNN; Corn Leaf Disease; Explainable AI; SVM

1. PENDAHULUAN

Jagung (*Zea mays* L.) merupakan salah satu komoditas pangan strategis di Indonesia. Selain sebagai bahan pangan, jagung juga berperan penting dalam industri pakan ternak dan bahan baku olahan, sehingga produktivitasnya berpengaruh langsung terhadap ketahanan pangan dan pendapatan petani. Ancaman penyakit daun seperti *blight* (hawar), *common rust* (karat), dan *gray leaf spot* (bercak abu-abu) menjadi hambatan serius yang dapat memangkas hasil panen secara drastis bila tidak terdeteksi sejak dini. Sayangnya, petani di lapangan masih sangat bergantung pada pengamatan visual mata telanjang, yang bersifat subjektif, tidak konsisten, dan kerap mengakibatkan keterlambatan penanganan [1].

Kehadiran *deep learning* menjawab sebagian keterbatasan itu. Kajian komprehensif terbaru menempatkannya sebagai standar baru dalam *smart agriculture* karena kemampuannya membaca pola visual rumit yang sulit dirumuskan secara manual [2]. Pada kasus daun jagung, penelitian yang ada sebagian besar bergerak di ranah arsitektur. EfficientNet-B0 terbukti menandingi model yang jauh lebih besar meski parameternya lebih hemat [3], [4], sementara varian berkapasitas lebih besar seperti EfficientNetB5 dan MobileNetV4 melaporkan akurasi di atas 95% [5], [6]. Modifikasi yang lebih dalam, mulai dari penyempurnaan modul MBConv, fusi fitur multiskala, hingga mekanisme atensi, bahkan mendorong akurasi melewati 98% [7], [8], [9]. Angka-angka itu mengesankan. Namun hampir semuanya lahir dari citra dataset yang seragam dan dibantu augmentasi, sehingga belum menyentuh persoalan pencahayaan yang berubah-ubah di lahan. Kenaikan akurasinya pun kian tipis seiring model bertambah rumit,

pertanda ruang perbaikan dari sisi arsitektur mulai menyempit. Model yang makin besar juga makin sulit dijalankan pada perangkat sederhana, padahal deteksi dini paling berguna bila bisa dilakukan langsung di lahan.

Sebagian peneliti lain memilih memperbaiki citra sebelum masuk ke model. Pencahayaannya yang tidak merata terbukti menurunkan akurasi [10], dan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) kerap dipilih karena bekerja per blok lokal serta membatasi penguatan kontras, tidak seperti *Histogram Equalization* global yang mudah memperkuat derau [11], [12]. Penerapannya pada daun jagung maupun tanaman lain konsisten menaikkan akurasi [13], [14]. Masalahnya, laporan-laporan itu berhenti pada selisih angka. Nyaris tidak ada yang menyertakan kelompok pembandingan tanpa CLAHE pada kondisi yang sama, apalagi menjelaskan dari mana nilai parameternya berasal. Kontribusi CLAHE pun jadi sulit dipisahkan dari pengaruh augmentasi atau perbedaan pembagian data.

Persoalan berikutnya menyangkut kepercayaan. Akurasi tinggi tidak serta-merta membuat sebuah model layak dipakai bila alasan di balik prediksinya tidak bisa ditelusuri, sebab petani dan ahli agronomi menuntut kejelasan sebelum bersedia mengandalkan teknologi [15], [16]. *Explainable AI* (XAI) seperti LIME dan Grad-CAM menjawabnya dengan menyorot bagian citra yang paling menentukan prediksi [17], [18], [19]. Sayangnya visualisasi itu sering diperlakukan sebagai pelengkap di akhir laporan, sekadar memperkuat kesimpulan yang sudah diambil. Nilainya terletak pada kemampuannya menunjukkan di mana model keliru menaruh perhatian, misalnya ketika prediksi ternyata bersandar pada latar belakang alih-alih pada bercak penyakit.

Jarang pula capaian pembelajaran mendalam diadu langsung dengan metode pembelajaran mesin konvensional. Sebelum CNN banyak digunakan, klasifikasi penyakit daun umumnya mengandalkan ekstraksi fitur secara manual, misalnya deskriptor tekstur berbasis Gray Level Co-occurrence Matrix (GLCM) dan fitur warna, yang kemudian diklasifikasikan menggunakan Support Vector Machine (SVM) [20]. Pendekatan itu masih dilaporkan kompetitif pada dataset berskala menengah dan menuntut sumber daya komputasi yang jauh lebih ringan [21]. Kajian ulasan pada objek daun jagung bahkan menunjukkan bahwa metode pembelajaran mesin dengan rekayasa fitur yang tepat masih mampu mencapai rentang akurasi yang lebar, meskipun secara umum pembelajaran mendalam memberikan hasil yang lebih konsisten [22]. Perbandingan langsung antara kedua metode pada kondisi data, pra-pemrosesan, dan pembagian data yang benar-benar identik masih jarang dilakukan, sehingga besarnya keunggulan CNN atas SVM pada kasus penyakit daun jagung belum terukur secara adil [20], [21], [22].

Kesenjangan penelitian ini menjadi lebih jelas bila dibandingkan langsung dengan empat penelitian terdahulu yang paling berdekatan. Wahyuningrum dkk. [5] melatih EfficientNetB5 pada objek yang sama dan memperoleh 96,27%, namun capaian itu diraih dengan bantuan augmentasi dan tanpa menguji apakah perbaikan kualitas citra ikut menyumbang, sehingga sumber kenaikannya tidak dapat dipilah. Sun dan Huo [7] menempuh jalur berbeda dengan memodifikasi modul MBConv EfficientNet hingga mencapai 98,32%, tetapi penambahan komponen itu justru menaikkan kompleksitas model dan menjauhkannya dari kebutuhan penerapan di perangkat sederhana. Okyere-Gyamfi dkk. [14] memadukan CLAHE dengan fitur perbedaan warna pada Capsule Network dan melaporkan 97,40%, namun tanpa kelompok pembandingan tanpa CLAHE sehingga kontribusi pra-pemrosesan tetap berupa asumsi. Gopalan dkk. [18] melengkapi ResNet152 dengan Grad-CAM sehingga keputusan model dapat ditelusuri, tetapi arsitekturnya jauh lebih berat dan pembandingnya sesama jaringan saraf, bukan metode pembelajaran mesin konvensional.

Dari keempat penelitian tersebut terlihat pola yang sama. Tidak satu pun menguji kontribusi pra-pemrosesan melalui kelompok kontrol, tidak satu pun menjelaskan dasar pemilihan nilai parameternya, dan tidak satu pun mengadu pembelajaran mendalam dengan pembelajaran mesin konvensional pada data serta perlakuan yang identik. Akibatnya besaran keunggulan CNN, sumbangan CLAHE, dan keterbatasan penjelasan model masih bercampur menjadi satu angka akurasi. Kesenjangan inilah yang dijawab penelitian ini dengan memisahkan ketiganya melalui pengujian terkendali.

Penelitian ini menempatkan komparasi metode sebagai kontribusi utamanya. CNN berbasis EfficientNet-B0 diadu dengan *Support Vector Machine* berbasis fitur *handcrafted* pada kondisi pengujian yang setara, dengan CLAHE sebagai pra-pemrosesan bersama dan LIME sebagai alat penelusur keputusan. Kontribusi yang ditawarkan mencakup pengujian terkendali yang memisahkan sumbangan CLAHE dari pengaruh arsitektur melalui kelompok kontrol tanpa CLAHE, penetapan nilai parameter pra-pemrosesan berdasarkan pengujian enam konfigurasi dan bukan kelaziman, perbandingan langsung pembelajaran mendalam dengan pembelajaran mesin konvensional pada data dan perlakuan yang identik sehingga selisih kinerjanya terukur adil, serta penggunaan LIME bukan sekadar untuk membenarkan prediksi melainkan untuk mengungkap batas penalaran model. Ada tiga pertanyaan yang hendak dijawab. Pertama, seberapa besar sebenarnya sumbangan CLAHE bila diukur terhadap kelompok kontrol tanpa CLAHE. Kedua, seberapa jauh pembelajaran mendalam unggul atas pembelajaran mesin konvensional pada kondisi yang sama. Ketiga, sejauh mana keputusan model dapat ditelusuri ke area lesi. Ketiganya dijawab berurutan pada bagian hasil dan pembahasan.

2. METODOLOGI PENELITIAN

2.1 Desain Penelitian


Penelitian ini menggunakan pendekatan eksperimental kuantitatif untuk membandingkan dua metode klasifikasi penyakit daun jagung pada kondisi pengujian yang setara. Alur penelitian meliputi enam tahapan utama, yaitu (1) pengumpulan dan persiapan dataset, (2) pra-pemrosesan citra dengan CLAHE, (3) pembagian data latih dan validasi,

(4) penerapan dua metode klasifikasi yang diuji secara terpisah yakni CNN dan SVM, (5) komparasi dan evaluasi kinerja kedua metode, serta (6) interpretasi keputusan model menggunakan *Explainable AI*. Rancangan ini disusun agar perbedaan kinerja yang muncul benar-benar bersumber dari perbedaan metode, bukan dari perbedaan data maupun perlakuan pra-pemrosesan.

Secara garis besar, tiga tahapan pertama bersifat tunggal dan berlaku sama bagi kedua metode. Tahap pertama adalah pengumpulan citra daun jagung dari sumber publik. Tahap kedua berupa pra-pemrosesan yang mencakup penerapan CLAHE pada kanal L, penyeragaman ukuran menjadi 224×224 piksel, dan penyesuaian rentang nilai piksel. Tahap ketiga adalah pembagian data menjadi himpunan pelatihan dan validasi dengan proporsi 80:20, menghasilkan 3.352 citra latih dan 836 citra validasi, dilakukan secara acak dengan nilai acuan yang dikunci agar pembagiannya dapat diulang.

Alur penelitian kemudian bercabang pada tahap keempat menjadi dua jalur metode. Jalur pertama menggunakan CNN, yaitu pemuatan arsitektur EfficientNet-B0 beserta bobot pra-latih ImageNet, penambahan kepala klasifikasi untuk empat kelas keluaran, lalu pelatihan dua fase berupa *warm-up* dengan lapisan dasar dibekukan dan dilanjutkan *fine-tuning* pada seluruh lapisan. Jalur kedua menggunakan SVM, yaitu ekstraksi fitur tekstur dan warna secara manual dari citra yang sama, standarisasi nilai fitur, kemudian pelatihan pengklasifikasi bermarginal maksimum. Keduanya dilatih dan diuji pada himpunan data yang identik.

Kedua jalur tersebut bertemu kembali pada tahap kelima, yaitu komparasi dan evaluasi. Pada tahap ini kinerja kedua metode diukur menggunakan metrik yang sama, kemudian tahap keenam menerapkan *Explainable AI* pada metode dengan kinerja terbaik untuk menelusuri dasar pengambilan keputusannya. Rancangan bercabang ini menegaskan dua penekanan penelitian: perbaikan kualitas citra melalui CLAHE yang diterapkan seragam pada kedua jalur, serta pengujian sejauh mana keunggulan pembelajaran mendalam atas pembelajaran mesin konvensional benar-benar terukur. Keseluruhan alur tersebut ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.2 Prosedur Penelitian

Data yang digunakan bersumber dari dataset *Corn or Maize Leaf Disease Dataset* yang tersedia secara publik di Kaggle [23]. Terdiri dari 4.188 citra daun jagung yang terbagi ke dalam empat kelas: *Blight* (Hawar Daun), *Common Rust* (Karat Daun), *Gray Leaf Spot* (Bercak Daun), dan *Healthy* (Sehat). Dataset dibagi dengan rasio 80:20 untuk data latih (*training*), validasi (*validation*). Setiap citra diproses dengan CLAHE sebelum dimasukkan ke model, tanpa teknik augmentasi tambahan.

Tahap pra-pemrosesan diawali dengan penerapan teknik *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Berbeda dengan *Histogram Equalization* konvensional yang bekerja secara global pada seluruh citra, CLAHE bekerja secara adaptif pada petak-petak kecil dan membatasi penguatan kontras sehingga derau tidak ikut diperkuat. Secara teknis, citra RGB terlebih dahulu dikonversi ke ruang warna LAB, kemudian CLAHE diterapkan secara eksklusif pada kanal L (*luminance*) yang merepresentasikan kecerahan, sehingga warna asli pada kanal A dan B tetap terjaga. Parameter yang digunakan adalah *clip limit* sebesar 2,0 dengan ukuran *grid* 8×8 . Citra hasil pra-

pemrosesan inilah yang selanjutnya digunakan oleh kedua metode klasifikasi, tanpa perlakuan tambahan yang membedakan keduanya.

2.3 Metode Utama: CNN EfficientNet-B0

Pada tahap klasifikasi, arsitektur yang dipilih adalah EfficientNet-B0. Pemilihan ini didasarkan pada keseimbangan optimal antara akurasi dan efisiensi komputasi dibandingkan arsitektur yang lebih berat seperti ResNet-50 [3]. Model diinisialisasi menggunakan bobot pralatih (*pretrained weights*) dari dataset ImageNet melalui teknik *transfer learning*. Lapisan *fully connected* bawaan digantikan dengan kepala klasifikasi (*classification head*) baru yang terdiri atas: GlobalAveragePooling2D untuk mereduksi dimensi fitur spasial, BatchNormalization untuk menstabilkan distribusi aktivasi, Dropout dengan laju 0,3 sebagai regularisasi, lapisan Dense 128 neuron dengan aktivasi ReLU, dan lapisan Dense 4 neuron dengan aktivasi Softmax sebagai keluaran klasifikasi akhir. Proses pelatihan dibagi menjadi dua tahap: (1) tahap *Warm-Up* selama 10 epoch dengan membekukan (*frozen*) seluruh *base layer* menggunakan *learning rate* awal 1×10^{-3} , dan (2) tahap *Fine-Tuning* dengan mencairkan seluruh layer menggunakan *learning rate* kecil 1×10^{-4} . Fungsi kerugian yang digunakan adalah *Categorical Cross-Entropy* dengan *optimizer* Adam. Fungsi *Early Stopping* diterapkan dengan *patience* 5 epoch untuk mencegah *overfitting*, dengan pemantauan *validation loss* sebagai metrik acuan. Pemilihan pendekatan transfer learning ini berpijak pada prinsip dasar pelatihan jaringan saraf dalam, yakni pemanfaatan representasi fitur yang telah dipelajari model pada domain data berskala besar untuk mempercepat konvergensi pada domain baru dengan data terbatas [24].

Tahap evaluasi dilengkapi dengan penerapan *Explainable AI* (XAI) menggunakan algoritma LIME (*Local Interpretable Model-Agnostic Explanations*) untuk memvalidasi relevansi keputusan model secara visual [15]. Berbeda dengan metode *Grad-CAM* yang menghasilkan *heatmap* berbasis gradien, LIME bekerja dengan membagi citra menjadi segmen-segmen *superpiksel*, kemudian mengidentifikasi superpiksel mana yang paling berkontribusi terhadap prediksi model melalui perturbasi lokal sebanyak 2.000 sampel acak. Hasil segmentasi ini divisualisasikan sebagai *overlay* batas area (*boundary*) pada citra uji untuk memverifikasi bahwa model berfokus pada area lesi penyakit yang relevan secara agronomis, bukan pada *noise* atau latar belakang citra.

Sebagai bentuk transparansi penelitian dan untuk mendukung reproduktibilitas eksperimen, seluruh kode sumber komputasi, konfigurasi parameter model, serta hasil pengujian LIME yang digunakan dalam studi ini telah didokumentasikan secara terbuka dan dapat diakses publik melalui repositori berikut: <https://github.com/meliodass-s/Komparasi-Metode-CNN-dan-SVM-Klasifikasi-Penyakit-Daun-Jagung-Preprocessing-CLAHE-dan-Explainable-AI>

2.4 Metode Pembandingan: SVM dengan Fitur Handcrafted

Sebagai pembandingan terhadap pendekatan CNN, penelitian ini menerapkan metode klasifikasi konvensional berupa *Support Vector Machine* (SVM). Agar perbandingan berlangsung adil, kedua metode menggunakan sumber data, hasil pra-pemrosesan CLAHE, serta pembagian data latih dan validasi yang sama persis. Perbedaannya hanya terletak pada cara fitur diperoleh dan cara keputusan klasifikasi dibentuk.

Berbeda dengan CNN yang mempelajari representasi fitur secara otomatis, SVM memerlukan fitur yang dirancang terlebih dahulu. Fitur tekstur diambil menggunakan *Gray Level Co-occurrence Matrix* (GLCM) pada citra keabuan yang telah dikuantisasi menjadi 64 aras intensitas, dihitung pada dua jarak piksel dan empat arah sudut, lalu diringkas melalui enam properti statistik yaitu *contrast*, *dissimilarity*, *homogeneity*, *energy*, *correlation*, dan *angular second moment*. Informasi warna diwakili oleh histogram ternormalisasi pada ketiga kanal ruang warna HSV serta nilai rata-rata dan simpangan baku tiap kanal RGB. Seluruh nilai tersebut digabungkan menjadi satu vektor fitur untuk setiap citra.

Vektor fitur kemudian distandardisasi agar setiap dimensi memiliki rata-rata nol dan simpangan baku satu, karena SVM sensitif terhadap perbedaan skala antar-fitur. Klasifikasi dilakukan menggunakan SVM dengan *kernel* RBF, parameter penalti C sebesar 10, dan nilai *gamma* mengikuti pengaturan *scale*. Pemilihan *kernel* RBF didasarkan pada kemampuannya memetakan data ke ruang berdimensi lebih tinggi sehingga kelas yang tidak terpisah secara linear tetap dapat dibedakan.

Selain kedua metode utama tersebut, penelitian ini turut menguji pendekatan hibrida, yaitu SVM yang dilatih menggunakan vektor fitur hasil ekstraksi EfficientNet-B0. Skenario ini disertakan untuk memisahkan pengaruh kualitas representasi fitur dari pengaruh mekanisme pengambilan keputusan, sehingga dapat diketahui apakah keunggulan CNN berasal dari fitur yang dipelajarinya atau dari lapisan klasifikasi *softmax* di ujung jaringan.

2.5 Prosedur Evaluasi dan Komparasi

Evaluasi dilakukan pada himpunan validasi yang sama untuk seluruh metode. Metrik utama yang digunakan adalah akurasi keseluruhan, *precision*, *recall*, dan *F1-score* untuk setiap kelas, serta *confusion matrix* untuk menelusuri pola kesalahan antar-kelas. Selain rerata berbobot, dilaporkan pula rerata *macro* agar kinerja pada kelas dengan jumlah data paling sedikit tidak tertutupi oleh kelas mayoritas. Sebagai pelengkap, diukur pula waktu yang dibutuhkan setiap metode untuk memproses seluruh data validasi. Ukuran ini disertakan karena kebutuhan penerapan di lapangan tidak hanya menuntut ketepatan, tetapi juga kecepatan dan keterbatasan sumber daya perangkat. Seluruh eksperimen dijalankan pada lingkungan komputasi yang sama untuk menjaga keterbandingan hasil.

3. HASIL DAN PEMBAHASAN

Bagian ini menguraikan hasil dari setiap tahapan penelitian, mulai dari perbaikan kualitas citra, evaluasi performa klasifikasi model, hingga interpretasi keputusan menggunakan pendekatan *Explainable AI*. Seluruh komputasi dijalankan menggunakan bahasa pemrograman Python.

3.1 Hasil Preprocessing Citra dengan CLAHE

Tahap pertama sebelum citra dilatih pada jaringan saraf tiruan adalah penyeragaman dan peningkatan kualitas visual menggunakan algoritma *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Pada penelitian ini, pengaturan CLAHE menggunakan parameter *clip limit* 2.0 dan ukuran *grid* 8x8. Hasil pengujian menunjukkan bahwa citra asli penyakit daun jagung yang semula memiliki pencahayaan tidak merata berhasil diperbaiki kontrasnya secara signifikan. Perbandingan citra sebelum dan sesudah pra-pemrosesan untuk keempat kelas ditampilkan pada Gambar 2.



Gambar 2. Perbandingan Citra Asli (kiri) dan Hasil CLAHE (kanan)

Berdasarkan Gambar 2, implementasi CLAHE terbukti mampu mempertegas tekstur dan tepi dari bercak penyakit tanpa memperkuat *noise* pada latar belakang. Peningkatan kontras lokal ini sangat krusial karena mempermudah model dalam mengekstraksi fitur visual yang membedakan daun sakit dan daun sehat. Pemilihan kanal L, sebagaimana diuraikan pada bagian metodologi, menjaga komposisi warna daun tetap utuh[25]. Hal ini penting karena warna merupakan penanda pembeda antara *common rust* yang kemerahan dan *blight* yang kecokelatan. Pengujian terhadap pilihan nilai *clip limit* dan ukuran *grid* dibahas tersendiri pada sub-bagian ablasi[11]. Secara visual, perbedaan paling terlihat pada citra yang diambil dalam kondisi redup atau berbayang. Pada citra asli, batas antara jaringan sehat dan terinfeksi sering landai sehingga tepi lesi sulit ditentukan. Setelah CLAHE, gradien intensitas di sekitar lesi menjadi lebih curam dan pola bercak tampak lebih tegas terhadap sekitarnya.

3.2 Kinerja Metode CNN EfficientNet-B0

Proses pelatihan model dilakukan dalam dua tahapan untuk menjaga stabilitas pembaharuan bobot, yaitu tahap *Warm Up* selama 10 *epoch* (dengan membekukan *base layer*) dan tahap *Fine Tuning* (dengan mencairkan seluruh *layer* dan menggunakan *learning rate* kecil $1e-4$). Fungsi *Early Stopping* juga diterapkan dengan *patience* 5 untuk mencegah terjadinya *overfitting*.

Pada tahap *fine-tuning*, mekanisme *early stopping* menghentikan pelatihan setelah delapan *epoch* berjalan dan mengembalikan bobot ke kondisi terbaiknya, yaitu *epoch* ke-13 terhitung dari awal pelatihan. Pada titik tersebut *validation loss* menyentuh angka terendah 0,1505 dengan akurasi validasi 95,33%. Rendahnya nilai *loss* ini menandakan model tidak hanya menebak dengan benar, tetapi juga memiliki tingkat keyakinan yang tinggi pada prediksinya. Pemisahan pelatihan menjadi dua tahap bertujuan menjaga bobot pra-latih. Bila seluruh lapisan dibuka sejak awal, gradien besar dari kepala klasifikasi yang masih acak akan merambat ke lapisan konvolusi dan merusak representasi fitur yang sudah terbentuk dari ImageNet.

Setelah kepala klasifikasi stabil, seluruh lapisan dibuka pada tahap *fine-tuning* dengan *learning rate* diturunkan sepuluh kali lipat menjadi $1e-4$. Penurunan ini penting karena pada tahap tersebut yang dibutuhkan hanyalah penyesuaian halus terhadap karakteristik citra daun jagung, bukan pembelajaran ulang dari awal. Penggunaan *batch size* 32 menjaga estimasi gradien tetap cukup stabil tanpa membebani memori, sementara *optimizer* Adam membantu penyesuaian laju pembelajaran secara adaptif untuk tiap parameter.

Dinamika pelatihan memperlihatkan pola yang sehat pada pembelajaran transfer. Sejak *epoch* pertama tahap *warm-up*, akurasi validasi sudah berada di kisaran 93% meskipun seluruh lapisan dasar masih dibekukan. Hal ini menunjukkan bahwa representasi fitur bawaan ImageNet memang relevan untuk tekstur daun, sehingga kepala klasifikasi cukup mempelajari pemetaan akhir saja. Ketika *fine-tuning* dimulai, terjadi lonjakan *loss* sesaat akibat pembukaan seluruh lapisan, namun nilainya segera turun kembali dan stabil dalam dua *epoch* berikutnya.

Keputusan untuk tidak menggunakan augmentasi memiliki konsekuensi ganda. Di satu sisi, hasil yang diperoleh mencerminkan kemampuan arsitektur dan *preprocessing* secara apa adanya, tanpa bantuan perluasan data buatan, sehingga kontribusi CLAHE dan EfficientNet-B0 lebih mudah ditelusuri. Di sisi lain, ketiadaan augmentasi membuat model lebih cepat mencapai titik jenuh dan lebih rentan terhadap variasi sudut pengambilan maupun kondisi pencahayaan yang belum pernah ditemui. Hal ini menjadi salah satu ruang perbaikan yang paling terbuka untuk penelitian lanjutan.

Rincian kinerja model pada setiap kelas, mencakup presisi, sensitivitas, dan F1-score, dirangkum pada Tabel 1.

Tabel 1. Laporan Klasifikasi Metode CNN EfficientNet-B0

Kelas Penyakit	Presisi (Precision)	Sensitivitas (Recall)	F1-Score	Jumlah Data (Support)
<i>Blight</i> (Hawar Daun)	0,92	0,91	0,91	229
<i>Common Rust</i> (Karat Daun)	0,98	1,00	0,99	261
<i>Gray Leaf Spot</i> (Bercak Daun)	0,85	0,82	0,84	114
<i>Healthy</i> (Sehat)	0,99	1,00	1,00	232
Akurasi Keseluruhan			0,95	836

Tabel 1 menunjukkan model mengenali 794 dari 836 citra uji dengan benar, setara akurasi 94,98%. Kesalahannya tidak tersebar merata. Kelas *Healthy* dan *Common Rust* praktis bersih, sementara hampir seluruh kekeliruan menumpuk pada dua kelas sisanya.


Rerata macro sebesar 0,934 dan rerata berbobot 0,949 terpaut sekitar satu setengah poin. Jarak itu menandakan ada kelas minoritas yang tertinggal, yaitu *Gray Leaf Spot* dengan 114 data uji berbanding 261 milik *Common Rust*. Ketimpangan hampir satu berbanding dua ini membatasi variasi pola yang sempat dipelajari model.

Pembacaan per kelas memperjelas letak persoalannya. *Healthy* tidak menyisakan satu pun kesalahan, yang penting di lapangan karena keliru menilai daun sehat berpotensi memicu penyemprotan pestisida yang tidak perlu. *Common Rust* juga hampir sempurna, sejalan dengan pustula karatnya yang membentuk bintik oranye kecoklatan dengan pola sangat khas.

Persoalan utama terletak pada kelas *blight* dan *gray leaf spot*. Dengan sensitivitas 0,91, sebanyak 208 dari 229 citra *blight* dikenali dengan benar sehingga 21 citra sisanya jatuh ke kelas lain, terutama 16 citra yang diprediksi sebagai *gray leaf spot*. Kondisi pada *gray leaf spot* lebih berat lagi, dengan sensitivitas 0,82 yang berarti hanya 94 dari 114 citra yang tepat sasaran, sementara 18 citranya justru diprediksi sebagai *blight*. Nilai presisi *gray leaf spot* sebesar 0,85 menunjukkan bahwa dari 110 citra yang diprediksi sebagai bercak abu-abu, 16 di antaranya berasal dari kelas lain. Dengan demikian, kesalahan model terkonsentrasi pada pasangan kedua kelas ini dan terbukti bersifat dua arah.

Penyebabnya terletak pada kemiripan gejala kedua penyakit saat lesi belum berkembang penuh, yang diuraikan lebih lanjut pada sub-bagian komparasi. Kondisinya diperberat oleh jumlah data *Gray Leaf Spot* yang paling sedikit, sehingga model punya lebih sedikit contoh untuk mempelajari batas pemisah antara keduanya.

Untuk mengamati distribusi prediksi metode CNN secara spesifik, dibentuk matriks kebingungan (confusion matrix) yang memetakan tebakan model terhadap label data aktual. Hasilnya ditampilkan pada Gambar 3, sedangkan matriks untuk metode pembandingan SVM disajikan pada sub-bagian berikutnya.



Gambar 3. Confusion Matrix Metode CNN EfficientNet-B0

Gambar 3 memperlihatkan sebaran kekeliruan itu secara lebih rinci. Dari 42 kesalahan yang terjadi, 34 di antaranya atau sekitar 81% berlangsung di antara *Blight* dan *Gray Leaf Spot*, dengan arah yang berimbang pada kedua sisi. Di luar pasangan tersebut model nyaris tidak tergelincir.

3.3 Kinerja Metode SVM dengan Fitur Handcrafted


Metode pembandingan SVM dilatih menggunakan vektor fitur *handcrafted* berdimensi 102 yang terdiri atas 48 fitur tekstur GLCM, 48 fitur histogram warna HSV, dan 6 fitur statistik kanal RGB. Berbeda dengan CNN yang memerlukan pelatihan bertahap selama belasan epoch, SVM tidak menjalankan proses iteratif berbasis epoch sehingga seluruh pelatihan selesai dalam waktu kurang dari satu detik pada perangkat tanpa akselerator grafis. Tidak ada mekanisme *early stopping* maupun penurunan *learning rate* yang perlu diatur, karena penentuan bidang pemisah dilakukan melalui optimasi bermarginal maksimum dalam satu kali proses.

Hasil evaluasi metode SVM pada data validasi yang sama disajikan pada Tabel 2. Susunan metrik dibuat identik dengan Tabel 1 agar kinerja kedua metode dapat dibaca secara berdampingan.

Tabel 2. Laporan Klasifikasi Metode SVM dengan Fitur Handcrafted

Kelas Penyakit	Presisi (Precision)	Sensitivitas (Recall)	F1-Score	Jumlah Data (Support)
Blight (Hawar Daun)	0,90	0,83	0,87	229
Common Rust (Karat Daun)	0,94	1,00	0,97	261
Gray Leaf Spot (Bercak Daun)	0,80	0,81	0,80	114
Healthy (Sehat)	0,99	0,99	0,99	232
Akurasi Keseluruhan			0,92	836

Pola kesalahan kedua metode dapat ditelusuri lebih rinci melalui confusion matrix SVM pada Gambar 4, yang dapat disandingkan dengan confusion matrix CNN pada Gambar 3. Perbandingan keduanya memperlihatkan bahwa selisih akurasi sebesar 2,52 poin tidak tersebar merata pada seluruh kelas, melainkan terkonsentrasi pada satu kelas saja.



Gambar 4. Confusion Matrix Metode SVM dengan Fitur GLCM dan Warna

Kelas Blight menjadi sumber utama perbedaan. CNN menyisakan 21 kesalahan pada kelas ini, sedangkan SVM menyisakan 39 kesalahan, sehingga selisihnya mencapai 18 citra atau hampir seluruh selisih kesalahan kedua metode yang berjumlah 21 citra. Perbedaan paling mencolok terjadi pada kekeliruan Blight yang diprediksi sebagai Common Rust, yaitu 4 citra pada CNN dibandingkan 14 citra pada SVM. Temuan ini masuk akal karena fitur *handcrafted* yang digunakan SVM bertumpu pada statistik tekstur dan sebaran warna global, sementara pembeda antara jaringan nekrotik Blight dan pustula Common Rust terletak pada pola sebaran lesi yang bersifat spasial. Informasi keruangan semacam itu justru merupakan kekuatan lapisan konvolusi pada CNN.

Menariknya, keunggulan tidak sepenuhnya berpihak pada CNN. Pada kelas Common Rust, SVM justru mengenali seluruh 261 citra tanpa satu pun kesalahan, sedangkan CNN menyisakan satu kekeliruan. Sebaliknya pada kelas Healthy, CNN mengenali seluruh 232 citra dengan tepat sementara SVM menyisakan dua kekeliruan. Perbedaan sekecil ini tidak cukup untuk menyimpulkan keunggulan salah satu metode, tetapi menunjukkan bahwa fitur warna yang dirancang manual tetap sangat efektif untuk kelas dengan penanda warna yang khas dan konsisten seperti karat daun.

Kesamaan yang paling menonjol justru terletak pada kelemahan keduanya. Kekeliruan Gray Leaf Spot yang diprediksi sebagai Blight tercatat sama persis pada kedua metode, yaitu 18 citra. Ketiga metode yang diuji juga sama-sama mencatat F1-score terendah pada kelas tersebut, yakni pada rentang 0,80 hingga 0,86, sekaligus mencatat kinerja terbaik pada kelas Healthy dan Common Rust. Kesamaan pola ini memperkuat simpulan bahwa kesulitan membedakan Gray Leaf Spot dari Blight berakar pada karakteristik data, bukan pada mekanisme klasifikasi. Selama

lesi Gray Leaf Spot pada fase awal masih menyerupai gejala Blight dan jumlah sampelnya tetap paling sedikit di antara keempat kelas, penambahan data pada kelas minoritas diperkirakan lebih berpengaruh daripada penggantian metode klasifikasi.

Kemiripan pola kesalahan itu punya penjelasan dari sisi patologi tanaman. Blight disebabkan cendawan *Exserohilum turcicum*, sedangkan Gray Leaf Spot oleh *Cercospora zeae-maydis*. Pada fase awal infeksi keduanya nyaris tidak terbedakan. Blight muncul sebagai guratan sempit cokelat muda yang memanjang searah tulang daun, bertepi kabur dan tampak basah. Gray Leaf Spot diawali bercak nekrotik kecil ber-halo kuning yang kemudian juga memanjang mengikuti tulang daun. Ciri pembedanya baru muncul belakangan: lesi Blight melebar melintasi tulang daun hingga berbentuk cerutu, sementara lesi Gray Leaf Spot tetap terkurung di antara tulang daun, bertepi sejajar dan menyerupai persegi panjang[26].


Konsekuensinya perlu dibaca hati-hati. Kekeliruan model pada kedua kelas ini sebagian besar bukan berasal dari kelemahan algoritma, melainkan dari informasi yang belum tersedia pada citra saat lesi belum berkembang penuh. Kedua patogen juga tumbuh pada kondisi lingkungan serupa dalam satu musim tanam, sehingga bisa muncul bersamaan di helai daun yang sama. Salah membedakan keduanya bukan perkara sepele karena tindakan pengendaliannya berbeda, dan kekeliruan diagnosis dilaporkan berpotensi memangkas hasil panen lebih dari sepuluh persen. Dengan demikian, memastikan lesi terekam pada fase yang cukup berkembang kemungkinan lebih menentukan daripada mengganti arsitektur klasifikasi[26].

3.4 Komparasi Metode CNN dan SVM

Bagian ini membandingkan metode CNN dengan metode klasifikasi konvensional SVM. Seluruh metode diuji pada data, hasil pra-pemrosesan CLAHE, dan pembagian data latih serta validasi yang sama persis, sehingga selisih kinerja yang muncul murni berasal dari perbedaan metodenya. Hasil pengujian ketiga metode dirangkum pada Tabel 3, dengan perbandingan akurasinya divisualisasikan pada Gambar 5.

Tabel 3. Komparasi Kinerja Metode CNN dan SVM

Metode Klasifikasi	Akurasi	Macro F1	Weighted F1	Waktu Prediksi
CNN EfficientNet-B0 (Softmax)	94,98%	0,934	0,949	15,98 detik
SVM + Fitur GLCM dan Warna	92,46%	0,907	0,924	0,10 detik
SVM + Fitur EfficientNet-B0	95,33%	0,940	0,953	0,98 detik



Gambar 5. Perbandingan Akurasi Metode CNN dan SVM

Tabel 3 beserta visualisasinya pada Gambar 5 mengungkap beberapa hal sekaligus. CNN EfficientNet-B0 unggul 2,52 poin atas SVM dengan fitur handcrafted, yaitu 94,98% berbanding 92,46%. Selisih itu mengonfirmasi keunggulan pembelajaran mendalam, tetapi besarnya jauh lebih kecil daripada yang sering diasumsikan. Fitur tekstur GLCM dan histogram warna yang dirancang manual ternyata masih menangkap sebagian besar ciri pembeda penyakit daun jagung.

Yang lebih menarik, pendekatan hibrida yang memadukan fitur hasil ekstraksi EfficientNet-B0 dengan pengklasifikasi SVM memperoleh akurasi tertinggi 95,33%, sedikit melampaui CNN dengan lapisan softmax bawaannya. Selisih 0,35 poin itu tipis dan belum tentu bermakna secara statistik pada 836 citra uji. Meski begitu, arahnya menunjukkan keunggulan CNN bersumber dari kualitas representasi fitur yang dipelajarinya, bukan dari mekanisme pengambilan keputusan di lapisan akhir.

Perbedaan paling mencolok tidak terletak pada akurasi, melainkan pada efisiensi komputasi. SVM dengan fitur handcrafted merampungkan pelatihan dalam waktu kurang dari satu detik dan memproses seluruh 836 citra uji hanya dalam 0,10 detik, sedangkan CNN memerlukan 15,98 detik untuk tugas yang sama. Dengan mengorbankan sekitar dua setengah poin akurasi, metode konvensional menawarkan kecepatan prediksi sekitar seratus enam puluh kali lipat

tanpa memerlukan akselerator grafis. Pertimbangan ini penting bila sistem hendak dijalankan pada perangkat bergerak di lapangan.

Berdasarkan keseluruhan hasil komparasi, metode CNN dipilih sebagai model utama yang dianalisis lebih lanjut menggunakan *Explainable AI*. Pertimbangannya bukan semata akurasi, melainkan juga kemampuannya menghasilkan representasi fitur yang dapat ditelusuri secara visual melalui LIME. Pendekatan hibrida yang berbasis SVM, meskipun berakurasi sedikit lebih tinggi, tidak menyediakan jalur interpretasi yang setara karena keputusannya terbentuk pada ruang fitur berdimensi tinggi yang sulit dipetakan kembali ke wilayah citra.

3.5 Ablasi CLAHE dan Justifikasi Parameter

Klaim bahwa perbaikan kontras menyumbang kinerja perlu dibuktikan, bukan diasumsikan. Karena itu kedua metode diuji ulang pada citra tanpa CLAHE, dengan seluruh pengaturan lain dibiarkan sama persis mulai dari pembagian data, arsitektur, hingga nilai acuan acak. Satu-satunya yang berbeda adalah ada atau tidaknya tahap perbaikan kontras. Hasilnya dirangkum pada Tabel 4.

Tabel 4. Ablasi CLAHE pada Metode CNN dan SVM

Metode	Tanpa CLAHE	Dengan CLAHE	Selisih	Macro F1 (tanpa - dengan)
CNN EfficientNet-B0	95,93%	94,14%	-1,79 poin	0,9475 - 0,9265
SVM + GLCM dan Warna	91,27%	92,46%	+1,19 poin	0,8971 - 0,9067

Angka pada Tabel 4 bergerak ke arah yang berlawanan. SVM naik 1,19 poin ketika citra diperbaiki kontrasnya, sedangkan CNN justru turun 1,79 poin. Temuan ini tidak sesuai dugaan awal, sehingga perlu dibaca dengan hati-hati.

Ada dua hal yang membedakan keandalan kedua angka itu. Pelatihan CNN mengandung unsur acak. Konfigurasi yang sama dapat menghasilkan capaian sedikit berbeda pada setiap pengulangan. Gejalanya terlihat di sini: konfigurasi CNN dengan CLAHE menghasilkan 94,98% pada pengujian utama dan 94,14% pada pengujian ablasi, terpaut 0,84 poin meski pengaturannya identik. Selisih 1,79 poin hanya sekitar dua kali ragam itu, belum cukup untuk menyimpulkan CLAHE merugikan CNN. SVM tidak menghadapi persoalan itu karena fiturnya tetap dan pelatihannya tidak melibatkan proses acak, sehingga kenaikan 1,19 poin pada metode ini dapat dipercaya.

Perbedaan arah itu tetap dapat dijelaskan. SVM bekerja pada fitur yang dirancang lebih dahulu dan nilainya tidak dapat menyesuaikan diri terhadap variasi pencahayaan. Penyeragaman kontras di tahap awal langsung terasa manfaatnya. CNN menempuh jalan berbeda. Lapisan konvolusi awalnya mempelajari sendiri cara menanggapi perbedaan intensitas selama fine-tuning, sehingga perbaikan dari luar tidak lagi banyak menambah dan berpotensi menghapus sebagian variasi asli yang sebenarnya membawa informasi. Manfaat CLAHE dengan demikian bergantung pada metode yang memakainya, bukan berlaku seragam.

Pemilihan nilai parameter juga diuji, tidak sekadar mengikuti kelaziman. Enam konfigurasi dibandingkan menggunakan metode SVM yang pelatihannya cepat dan memungkinkan banyak percobaan. Selain akurasi, diukur pula entropi citra sebagai penanda seberapa kaya informasi yang terkandung setelah perbaikan kontras. Hasilnya disajikan pada Tabel 5.

Tabel 5. Pengaruh Parameter CLAHE terhadap Kinerja dan Entropi Citra

Clip Limit	Ukuran Grid	Akurasi SVM	Macro F1	Entropi Citra
1,0	8×8	91,87%	0,9027	7,3072
2,0	8×8	92,46%	0,9067	7,5077
3,0	8×8	92,11%	0,9059	7,6417
4,0	8×8	91,27%	0,8970	7,7233
2,0	4×4	93,06%	0,9164	7,5757
2,0	16×16	91,15%	0,8936	7,4766

Pola pada Tabel 5 menjelaskan mengapa penguatan kontras tidak boleh berlebihan. Entropi citra naik terus seiring bertambahnya clip limit, dari 7,3072 pada nilai 1,0 hingga 7,7233 pada nilai 4,0. Akurasi tidak mengikuti pola yang sama. Capaian tertinggi berada di clip limit 2,0, lalu menurun pada nilai yang lebih besar. Artinya informasi yang bertambah setelah titik itu sebagian berupa derau, bukan penanda penyakit. Penguatan yang lebih agresif malah mengaburkan batas antar-kelas. Temuan ini memberi dasar terukur bagi pemilihan clip limit 2,0.

Pada ukuran grid, hasilnya sedikit di luar dugaan. Konfigurasi 4×4 mencapai 93,06%, lebih tinggi 0,60 poin daripada 8×8 yang dipakai sepanjang penelitian ini, sementara 16×16 turun ke 91,15%. Petak yang terlalu besar membuat perbaikan kontras kehilangan sifat lokalnya. Ukuran 8×8 dipilih sejak awal mengikuti praktik yang lazim dilaporkan pada penelitian terdahulu, dan hasil pengujian ini menunjukkan pilihan tersebut belum optimal. Penyesuaian ke petak yang lebih rapat menjadi salah satu ruang perbaikan yang paling terbuka untuk penelitian berikutnya.

3.6 Interpretasi Keputusan dengan Explainable AI (LIME)

Salah satu kritik utama terhadap model *Deep Learning* konvensional adalah cara kerjanya yang mirip "kotak hitam" (*black-box*). Untuk membuktikan bahwa model mengenali penyakit dari bercaknya (dan bukan karena kebetulan

mempelajari latar belakang atau objek acak), diterapkan algoritma LIME (*Local Interpretable Model-Agnostic Explanations*) dengan pengambilan 2000 sampel acak. Wilayah citra yang paling menentukan prediksi pada masing-masing kelas ditampilkan pada Gambar 6.



Gambar 6. Visualisasi LIME: Citra Asli (kiri) dan Area Fokus Model (kanan)

Hasil segmentasi superpixels dari LIME pada Gambar 6 memperlihatkan batas wilayah yang paling menentukan keputusan model. Pada keempat kelas, sebagian besar wilayah berpengaruh jatuh pada permukaan daun, terutama pada area yang berubah warna dan teksturnya akibat infeksi.

Segmentasi *superpixels* bekerja dengan mengelompokkan piksel-piksel bertetangga yang memiliki kemiripan warna dan tekstur menjadi satu wilayah. LIME kemudian menonaktifkan sebagian wilayah tersebut secara acak, mengamati perubahan keluaran model, dan menyusun model linear sederhana yang menjelaskan wilayah mana yang paling menentukan prediksi. Dengan cara ini, penjelasan yang dihasilkan tidak bergantung pada arsitektur tertentu sehingga dapat diterapkan pada EfficientNet-B0 tanpa memodifikasi struktur modelnya.

Meskipun demikian, hasil visualisasi juga memperlihatkan bahwa sebagian wilayah berpengaruh masih jatuh di luar daun. Gejala ini paling terlihat pada kelas Blight, di mana sekelompok *superpixel* pada latar belakang berwarna gelap di sisi kanan bawah citra ikut tercatat sebagai wilayah yang berkontribusi positif. Temuan ini tidak dapat diabaikan karena menandakan model belum sepenuhnya mengabaikan konteks di luar objek pengamatan. Kemungkinan penyebabnya adalah kemiripan rentang intensitas antara jaringan daun yang mengering dan latar belakang gelap setelah penerapan CLAHE, serta ketiadaan tahap segmentasi daun maupun augmentasi yang dapat melatih model agar lebih tahan terhadap variasi latar.

LIME dengan demikian tidak hanya membenarkan keputusan model, tetapi juga mengungkap batasnya. Penjelasan yang dihasilkan bersifat lokal, hanya berlaku bagi citra yang sedang diamati, dan dipengaruhi jumlah sampel gangguan serta parameter segmentasi. Karena itu visualisasi ini diposisikan sebagai alat verifikasi kualitatif, bukan ukuran kinerja tambahan.

3.7 Pembahasan

Untuk menempatkan hasil penelitian ini secara proporsional, capaian akurasi 94,98% perlu dibandingkan dengan penelitian sejenis yang telah diuraikan pada bagian pendahuluan. Perbandingan dilakukan dengan tetap memperhatikan perbedaan dataset, jumlah kelas, dan perlakuan data, karena ketiga faktor tersebut sangat menentukan angka akhir yang dilaporkan.

Terhadap penelitian yang menggunakan dataset dan jumlah kelas serupa, hasil penelitian ini berada pada posisi yang menjanjikan. Implementasi EfficientNetV2-S dengan strategi pembelajaran transfer pada kasus yang sama melaporkan akurasi 84% [16], sehingga capaian 94,98% dalam penelitian ini menunjukkan bahwa penambahan CLAHE pada alur pra-pemrosesan memberikan kontribusi yang berarti meskipun arsitektur yang digunakan justru lebih ringan. Capaian ini juga setara dengan MobileNetV4 yang melaporkan 95,25% [6], padahal penelitian tersebut menggunakan augmentasi data sementara penelitian ini tidak.

Sejumlah penelitian lain melaporkan akurasi lebih tinggi, mulai dari EfficientNetB5 dengan 96,27% [5] dan penggabungan CLAHE pada Capsule Network dengan 97,40% [14], hingga modifikasi arsitektur yang menembus 98,32% [7] dan 98,85% [8]. Selisih itu tidak dapat langsung dibaca sebagai keunggulan metode, karena sebagian besar penelitian tersebut memakai augmentasi, dataset berkomposisi lebih seimbang, atau modifikasi yang menaikkan kompleksitas model.

Pada aspek transparansi, penelitian yang memasang ResNet152 dengan Grad-CAM melaporkan akurasi 98,34% [18] dan penerapan VGG16 dengan penjelasan berbasis XAI menunjukkan arah serupa [19]. Keduanya memakai arsitektur dengan parameter jauh lebih besar. Penelitian ini menawarkan pertukaran berbeda: akurasi sedikit lebih rendah pada model yang jauh lebih ringan, dengan keputusan yang tetap dapat ditelusuri [18], [19].

Dari keseluruhan perbandingan tersebut, kontribusi penelitian ini terletak bukan semata pada pencapaian akurasi tertinggi, melainkan pada pengujian ketiga komponen dalam satu kerangka kerja yang utuh sekaligus membandingkannya secara langsung dengan metode klasifikasi konvensional. Sebagian besar penelitian terdahulu

menempatkan optimasi arsitektur, perbaikan kualitas citra, dan transparansi keputusan sebagai upaya yang terpisah, serta jarang menyandingkan pendekatan pembelajaran mendalam dengan pembelajaran mesin klasik pada kondisi data yang benar-benar setara.

Untuk memudahkan pembacaan, posisi penelitian ini terhadap sejumlah penelitian terdahulu yang menggunakan objek penyakit daun jagung dirangkum pada Tabel 6. Perbandingan difokuskan pada arsitektur yang digunakan, akurasi yang dilaporkan, ada tidaknya augmentasi data, serta ada tidaknya komponen interpretasi keputusan model.

Tabel 6. Perbandingan dengan Penelitian Terdahulu pada Objek Penyakit Daun Jagung

Penelitian	Arsitektur / Metode	Akurasi	Augmentasi	XAI
Wahyuningrum et al. [16] (2025)	EfficientNetV2-S	84,00%	Tanpa augmentasi	Tidak
Anugrah & Rachmat [6] (2025)	MobileNetV4	95,25%	Dengan augmentasi	Tidak
Wahyuningrum et al. [5] (2025)	EfficientNetB5	96,27%	Dengan augmentasi	Tidak
Okyere-Gyamfi et al. [14] (2025)	CapsNet + CLAHE + CDH	97,40%	Dengan augmentasi	Tidak
Sun & Huo [7] (2025)	EfficientNet-B0 termodifikasi	98,32%	Dengan augmentasi	Tidak
Gopalan et al. [18] (2025)	ResNet152 + Grad-CAM	98,34%	Dengan augmentasi	Ya
Penelitian ini	CNN EfficientNet-B0 + CLAHE + LIME (dikomparasi dengan SVM)	94,98%	Tanpa augmentasi	Ya

Tabel 6 memperlihatkan bahwa penelitian berakurasi tertinggi umumnya memakai augmentasi atau modifikasi arsitektur, sementara komponen interpretasi masih jarang disertakan. Penelitian ini menempati posisi berbeda: akurasi menengah pada arsitektur ringan tanpa augmentasi, tetapi disertai transparansi keputusan. Angka pada tabel tidak sepenuhnya setara karena perbedaan dataset dan perlakuan data, sehingga lebih tepat dibaca sebagai pemetaan posisi daripada peringkat.

4. KESIMPULAN

Komparasi pada kondisi pengujian yang setara menempatkan CNN berbasis EfficientNet-B0 di posisi teratas dengan akurasi 94,98%, sementara SVM berbasis fitur GLCM dan histogram warna mencapai 92,46%. Selisih 2,52 poin itu nyata, tetapi jauh lebih tipis daripada yang lazim diasumsikan, dan seluruh kesalahan tambahan SVM ternyata menumpuk pada kelas Blight alih-alih menyebar merata. Petunjuk mengenai asal keunggulan CNN justru muncul dari skenario hibrida. Ketika fitur hasil ekstraksi EfficientNet-B0 diserahkan kepada pengklasifikasi SVM, akurasinya naik menjadi 95,33%. Kekuatan CNN lebih terletak pada representasi fitur yang dipelajarinya ketimbang pada lapisan pengambilan keputusan di ujung jaringan. Sebaliknya, SVM menyelesaikan prediksi seratus enam puluh kali lebih cepat tanpa akselerator grafis, pertimbangan yang sulit diabaikan bila sistem hendak dijalankan langsung di lahan. Pengujian ablasi menambah catatan penting: perbaikan kontras menaikkan kinerja SVM 1,19 poin, tetapi tidak pada CNN yang tampaknya sudah mempelajari penyesuaian kontras sendiri selama fine-tuning. Penelusuran dengan LIME memperlihatkan sebagian besar wilayah berpengaruh memang jatuh pada area bercak, meski sebagian masih tertinggal di latar belakang, sehingga model belum sepenuhnya mengabaikan konteks di luar daun. Secara keseluruhan, penelitian ini terletak pada tiga hal yang selama ini jarang disatukan, yaitu pemisahan sumbangan CLAHE melalui kelompok kontrol, penetapan parameter pra-pemrosesan berdasarkan pengujian enam konfigurasi, dan perbandingan pembelajaran mendalam dengan pembelajaran mesin konvensional pada kondisi yang benar-benar setara. Keterbatasan terbesar tetap pada Gray Leaf Spot dengan sensitivitas 0,82. Ketiga metode melemah pada kelas yang sama, pertanda hambatannya berasal dari kemiripan gejala di fase awal infeksi, bukan dari pilihan algoritma. Karena itu penelitian lanjutan lebih baik diarahkan pada penambahan sampel Gray Leaf Spot fase awal, penerapan segmentasi daun untuk menekan pengaruh latar pada penjelasan LIME, serta pengukuran tumpang tindih antara wilayah penjelasan dan area lesi.

5. PERNYATAAN PENULIS

5.1 Kontribusi Penulis

Konseptualisasi: M. A. N. A. W., A. A. M., dan M. A. U.;

Metodologi: M. A. N. A. W., A. A. M., dan M. A. U.;

Perangkat Lunak: M. A. N. A. W.;

Validasi: M. A. N. A. W., A. A. M., dan M. A. U.;

Analisis Formal: M. A. N. A. W., A. A. M., dan M. A. U.;

Investigasi: M. A. N. A. W., A. A. M., dan M. A. U.;

Sumber Daya: M. A. N. A. W., A. A. M., dan M. A. U.;

Kurasi Data: M. A. N. A. W.;

Penulisan Draf Awal: M. A. N. A. W., A. A. M., dan M. A. U.;

Penulisan, Peninjauan, dan Penyuntingan: M. A. N. A. W., A. A. M., dan M. A. U.;

Visualisasi: M. A. N. A. W., A. A. M., dan M. A. U.;

Seluruh penulis telah membaca dan menyetujui versi manuskrip yang telah diterbitkan.

5.2 Ketersediaan Data

Data yang disajikan dalam penelitian ini tersedia berdasarkan permintaan kepada penulis korespondensi.

5.3 Pendanaan

Penelitian ini tidak menerima pendanaan eksternal.

5.4 Pernyataan Dewan Peninjau Institusional

Tidak Berlaku (Not applicable).

5.5 Pernyataan Persetujuan Berdasarkan Informasi

Tidak Berlaku (Not applicable).

5.6 Pernyataan Konflik Kepentingan

Para penulis menyatakan bahwa mereka tidak memiliki kepentingan keuangan yang bersaing atau hubungan pribadi yang diketahui yang dapat dianggap memengaruhi pekerjaan yang dilaporkan dalam artikel ini.

5.7 Penggunaan AI Generatif dan Teknologi Berbantuan AI dalam Proses Penulisan

Para penulis menggunakan AI Generatif untuk meningkatkan kejelasan penulisan dalam artikel ini. Para penulis telah meninjau dan menyunting konten yang dihasilkan dengan bantuan AI serta bertanggung jawab penuh atas versi akhir publikasi.

REFERENCES

- [1] Q. N. Azizah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet," *sudo J. Tek. Inform.*, vol. 2, no. 1, pp. 28–33, Feb. 2023, doi: 10.56211/sudo.v2i1.227.
- [2] M. I. Keskes, "Review of The Current State of Deep Learning Applications in Agriculture," May 06, 2025. doi: 10.20944/preprints202504.1290.v2.
- [3] N. P. Maylianti, I. G. N. L. Wijayakusuma, and I. P. C. Arta Wiguna, "Comparison of EfficientNet-B0 and ResNet-50 for Detecting Diseases in Cocoa Fruit," *J. Appl. Informatics Comput.*, vol. 9, no. 1, pp. 115–120, Jan. 2025, doi: 10.30871/jaic.v9i1.8868.
- [4] S. Riyadi, R. Mulya, and A. Nabila Realisti, "Comparison of MobilenetV2 and EfficientnetB3 Method to Classify Diseases on Corn Leaves," *E3S Web Conf.*, vol. 595, p. 02006, Nov. 2024, doi: 10.1051/e3sconf/202459502006.
- [5] R. T. Wahyuningrum, R. Erfian, A. Kusumaningsih, and H. P. A. Tjahyaningtjas, "Klasifikasi Penyakit Daun Jagung Menggunakan Model Deep Learning EfficientNetB5," *J. Pekommas*, vol. 10, no. 1, pp. 1–7, Jun. 2025, doi: 10.56873/jpkm.v9i1.5322.
- [6] Muhammad Naufal Anugrah and Nur Rachmat, "Klasifikasi Penyakit Daun Tanaman Jagung Menggunakan Pendekatan Transfer Learning Arsitektur MobileNetV4," *J. Teknol. dan Manaj. Ind. Terap.*, vol. 4, no. 4, pp. 2174–2182, Dec. 2025, doi: 10.55826/jtmnit.v4i4.1393.
- [7] X. Sun and H. Huo, "Corn leaf disease recognition based on improved EfficientNet," *IET Image Process.*, vol. 19, no. 1, pp. 1–12, Jan. 2025, doi: 10.1049/ipr2.13288.
- [8] F. Rajeeva P. P., A. S. U., M. A. Moustafa, and M. A. S. Ali, "Detecting Plant Disease in Corn Leaf Using EfficientNet Architecture—An Analytical Approach," *Electronics*, vol. 12, no. 8, p. 1938, Apr. 2023, doi: 10.3390/electronics12081938.
- [9] S. Albahli and M. Masood, "Efficient attention-based CNN network (EANet) for multi-class maize crop disease classification," *Front. Plant Sci.*, vol. 13, no. October, pp. 1–18, Oct. 2022, doi: 10.3389/fpls.2022.1003152.
- [10] R. Ariska, C. A. Sari, and E. H. Rachmawanto, "Classification of Corn Leaf Disease Using Convolutional Neural Network," *Adv. Sustain. Sci. Eng. Technol.*, vol. 6, no. 4, p. 0240408, Aug. 2024, doi: 10.26877/asset.v6i4.772.
- [11] I. Majid Mohammed and N. Ashidi Mat Isa, "Contrast Limited Adaptive Local Histogram Equalization Method for Poor Contrast Image Enhancement," *IEEE Access*, vol. 13, no. March, pp. 62600–62632, 2025, doi: 10.1109/ACCESS.2025.3558506.
- [12] N. Sulaiya, "Enhanced Plant Leaf Disease Detection Using CLAHE-Processed Images and Custom CNN Deep Learning Architecture," *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 13, no. 9, pp. 906–915, Sep. 2025, doi: 10.22214/ijraset.2025.74149.
- [13] 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, Jan. 2024, doi: 10.55606/jutiti.v4i1.3425.
- [14] S. Okyere-Gyamfi, M. Asante, K. O. Peasah, Y. M. Missah, and V. Akoto-Adjepong, "Contrast limited adaptive histogram equalization (CLAHE) and colour difference histogram (CDH) feature merging capsule network (CCFMCapsNet) for complex image recognition," *PLoS One*, vol. 20, no. 10, p. e0335393, Oct. 2025, doi: 10.1371/journal.pone.0335393.
- [15] A. Pavithran and M. Punithavalli, "Explainable AI for Plant Leaf Disease Detection: Techniques, Applications, and Future Directions," *Discov. Appl. Sci.*, vol. 2, no. 7, pp. 244–256, Jul. 2024, [Online]. Available: <https://theacademic.in/wp-content/uploads/2024/08/22.pdf>
- [16] R. Tri Wahyuningrum, C. Very Angkoso, S. Hafizah Ab Hamid, I. Syah Putra, M. Mahreza Rizky Fahrenzi, and A.

- Bhagaskara, “Implementation of a corn leaf disease classification system using EfficientNetV2-S and transfer learning,” *EPJ Web Conf.*, vol. 344, p. 01020, Dec. 2025, doi: 10.1051/epjconf/202534401020.
- [17] R. Rashid, W. Aslam, R. Aziz, and G. Aldehim, “An Early and Smart Detection of Corn Plant Leaf Diseases Using IoT and Deep Learning Multi-Models,” *IEEE Access*, vol. 12, no. December 2023, pp. 23149–23162, 2024, doi: 10.1109/ACCESS.2024.3357099.
- [18] K. Gopalan, S. Srinivasan, M. Singh, and S. K. Mathivanan, “Corn leaf disease diagnosis: enhancing accuracy with resnet152 and grad-cam for explainable AI,” *BMC Plant Biol.*, vol. 25, no. 440, pp. 1–21, 2025, doi: 10.1186/s12870-025-06386-0.
- [19] M. Tariq *et al.*, “Corn leaf disease: insightful diagnosis using VGG16 empowered by explainable AI,” *Front. Plant Sci.*, vol. 15, no. June, pp. 1–12, Jun. 2024, doi: 10.3389/fpls.2024.1402835.
- [20] R. Khan, N. Ud Din, A. Zaman, and B. Huang, “Automated Tomato Leaf Disease Detection Using Image Processing: An SVM-Based Approach with GLCM and SIFT Features,” *J. Eng.*, vol. 2024, no. 1, pp. 1–10, Jan. 2024, doi: 10.1155/2024/9918296.
- [21] K. Rajiv, N. Rajasekhar, K. Prasanna Lakshmi, D. Srinivasa Rao, and P. Sabitha Reddy, “Accuracy Evaluation of Plant Leaf Disease Detection and Classification Using GLCM and Multiclass SVM Classifier,” Springer, 2021, pp. 41–54. doi: 10.1007/978-981-33-4582-9_4.
- [22] W. Setiawan, E. M. S. Rochman, B. D. Satoto, and A. Rachmad, “Machine Learning and Deep Learning for Maize Leaf Disease Classification: A Review,” *J. Phys. Conf. Ser.*, vol. 2406, no. 1, p. 012019, Dec. 2022, doi: 10.1088/1742-6596/2406/1/012019.
- [23] S. Ghose, “Corn or Maize Leaf Disease Dataset,” Kaggle. Accessed: Jun. 24, 2026. [Online]. Available: <https://www.kaggle.com/datasets/smaranjitghose/corn-or-maize-leaf-disease-dataset>
- [24] R. Szeliski, *Computer Vision: Algorithms and Applications*, 2nd ed. Cham, Switzerland: Springer, 2022.
- [25] S. J. D. Prince, *Understanding Deep Learning*. Cambridge, MA, USA: MIT Press, 2023.
- [26] D. L. Nsibo, I. Barnes, and D. K. Berger, “Recent advances in the population biology and management of maize foliar fungal pathogens *Exserohilum turcicum*, *Cercospora zeina* and *Bipolaris maydis* in Africa,” *Front. Plant Sci.*, vol. 15, p. 1404483, Aug. 2024, doi: 10.3389/fpls.2024.1404483.