

Klasifikasi Penyakit Daun Tanaman Jagung Menggunakan Pendekatan *Transfer Learning* Arsitektur *MobileNetV4*

Muhammad Naufal Anugrah¹, Nur Rachmat²

^{1,2} Fakultas Ilmu Komputer dan Rekayasa, Universitas Multi Data Palembang
Jl. Rajawali No.14, 9 Ilir, Kec. Ilir Tim. II, Kota Palembang, Sumatera Selatan 30113
Email: naufal.anugrah@mhs.mdp.ac.id, nur.rachmat@mdp.ac.id

ABSTRAK

Jagung (*Zea mays*) merupakan komoditas pangan utama, namun produktivitasnya terhambat oleh serangan penyakit daun. Identifikasi penyakit daun jagung secara manual memakan waktu dan bersifat subjektif. Penelitian ini bertujuan mengembangkan model klasifikasi otomatis menggunakan *Convolutional Neural Network* (CNN) berbasis *transfer learning* dengan mengevaluasi tiga varian arsitektur *MobileNetV4* (*Small*, *Medium*, *Large*) serta membandingkan *optimizer* Adam dan SGD. Peneliti menggunakan 4000 citra daun jagung dari empat kelas dengan pembagian 80% data pelatihan, 10% data validasi dan 10% data pengujian. Hasil eksperimen menunjukkan bahwa model terbaik diperoleh dari *MobileNetV4-Conv-Medium* dengan *optimizer* SGD, yang mencapai akurasi validasi tertinggi 95,25% dan F1-Score 92,00% dengan penggunaan *hyperparameter learning rate* 0.01, *epoch* 50 dan *batch size* 32. Kinerja ini menegaskan potensi *MobileNetV4*, khususnya varian *Medium*, dalam mencapai keseimbangan optimal antara efisiensi komputasi dan kinerja klasifikasi, menjadikannya model yang sangat menjanjikan untuk implementasi sebagai sistem *mobile* dalam pertanian presisi.

Kata kunci: *MobileNetV4*, Penyakit Daun Jagung, *Convolutional Neural Network* (CNN), *Transfer Learning*, *Optimizer*, Klasifikasi.

ABSTRACT

Corn (*Zea mays*) is a key global commodity, yet its productivity is often hindered by damaging leaf diseases. Manual identification of these corn leaf diseases is time-consuming and inherently subjective. This study aims to develop an automatic classification model using a *Convolutional Neural Network* (CNN) based on *transfer learning*. We evaluated three variants of the *MobileNetV4* architecture (*Small*, *Medium*, *Large*) and compared them using two different optimizers: Adam and SGD. The study utilized 4,000 corn leaf images across four classes, divided into 80% for training, 10% for validation, and 10% for testing. Experimental results show that the best model was achieved by the *MobileNetV4-Conv-Medium* with the SGD optimizer, yielding the highest validation accuracy of 95.25% and an F1-Score of 92.00% using a learning rate of 0.01, 50 epochs, and a batch size of 32. This performance underscores the potential of *MobileNetV4*, particularly the *Medium* variant, in achieving an optimal balance between computational efficiency and classification performance, making it an up-and-coming model for mobile system implementation in precision agriculture.

Keywords: *MobileNetV4*, Corn Leaf Diseases, *Convolutional Neural Network* (CNN), *Transfer Learning*, *Optimizer*, Classification.

Pendahuluan

Jagung (*Zea mays*) merupakan salah satu komoditas pangan utama di Indonesia yang berperan penting dalam ketahanan pangan dan perekonomian nasional. Selain sebagai makanan pokok, jagung dimanfaatkan sebagai bahan baku industri pakan, makanan, *biofuel*, dan industri lainnya, menegaskan peran strategisnya [1]. Meskipun penting, produksi jagung di Indonesia seringkali tidak menentu. Berdasarkan data dari pusat data dan sistem informasi pertanian Indonesia, Data menunjukkan fluktuasi, 14,46 juta ton produksi jagung pada tahun 2023 yang mana mengalami penurunan 12,5% dari tahun 2022 [2], diikuti oleh kenaikan kembali pada tahun 2024 mencapai 20,48 juta ton [3]. Salah satu faktor utama yang menyebabkan naik turunnya produksi adalah serangan berbagai penyakit daun yang dapat menurunkan hasil panen secara signifikan [4]. Oleh karena itu, identifikasi dan klasifikasi penyakit pada daun tanaman jagung menjadi salah satu hal yang penting dalam upaya pencegahan dan pengendalian penyebaran penyakit tersebut serta untuk menjaga produksi jagung tiap tahunnya.

Beberapa faktor terjadinya penyakit pada tanaman jagung antara lain organisme virus, mikroplasma, bakteri, jamur, nematoda, dan tumbuhan parasit[5]. Penyakit utama jagung, seperti bercak daun, karat daun, dan hawar daun, menghambat fotosintesis dan menyebabkan kerugian besar [6]. Tantangan utamanya diagnosis yang masih mengandalkan pengamatan visual. Metode konvensional ini menuntut keahlian khusus, memakan waktu, dan rentan kesalahan, menyebabkan kesenjangan kritis antara kebutuhan identifikasi yang cepat dan akurat dengan keterbatasan metode saat ini [7]. Kesalahan diagnosis ini dapat berakibat pada tindak pengendalian yang tidak tepat, yang justru dapat memperburuk kondisi tanaman. Kesenjangan antara kebutuhan mendesak untuk identifikasi penyakit yang cepat dan akurat, dan keterbatasan metode konvensional ini menjadi masalah kunci yang diatasi oleh penelitian ini.

Perkembangan pesat Kecerdasan Buatan, khususnya *deep learning* menawarkan solusi transformatif untuk tantangan ini. *Deep learning* merupakan sebuah subbidang *machine learning* yang dapat memproses data dalam jumlah besar dan kompleks, seperti gambar dengan akurasi tinggi [8]. Model *deep learning* yang banyak digunakan untuk keperluan analisa citra/visual adalah *Convolutional Neural Network* (CNN). CNN meniru *visual cortex* pada mamalia yang memiliki neuron-neuron yang disusun secara tiga dimensi yaitu panjang, lebar dan tinggi sehingga memiliki kemampuan mengolah informasi citra [9]. Kemampuan ini menjadikan CNN sangat efektif untuk aplikasi klasifikasi gambar, termasuk identifikasi penyakit tanaman.

Awalnya, studi menunjukkan akurasi tinggi menggunakan CNN sederhana hingga 97,92% akurasi [10], atau arsitektur berat (*heavyweight*) seperti ResNet50 [11] dan kombinasi EfficientNetB0 dan DenseNet [12]. Misalnya, ResNet50 dilaporkan mencapai akurasi hingga 98,40% yang menggunakan optimizer Adam, Nadam dan SGD[12]. Arsitektur lain juga mendapat akurasi yang tinggi, seperti DarkNet-53 [4] (98,6%) dan DFCANet [13] (98,47%) serta AlexNet [14] juga melaporkan hasil yang solid. Meskipun akurat, model-model CNN ini seringkali menuntut sumber daya komputasi tinggi dan waktu pelatihan yang lama [15], sehingga kurang ideal untuk penerapan *on-device* atau *edge computing* di lingkungan pertanian.

Untuk mengatasi keterbatasan komputasi tersebut, pendekatan *Transfer Learning* menggunakan arsitektur ringan (*lightweight*) semakin populer [16]. Arsitektur seperti MobileNetV2 telah mencatat akurasi yang sangat tinggi, mencapai hingga 99,34% [6]. Penelitian lain juga telah mengeksplorasi MobileNetV3, membandingkan varian *small* dan *large* dengan *optimizer* berbeda, akurasi tertinggi didapat sebesar 99,50% pada varian *small* dengan optimizer SGD, learning rate 0,01, dan ukuran batch 32 [8]. Varian modifikasi dari MobileNetV3 alias CD-MobileNetV3 juga menunjukkan performa solid dengan akurasi 98,23% [17], bahkan ketika dibandingkan dengan EfficientNetB5 (96,27%) [18] Model-model ini menjadi contoh *deep learning* yang berfokus pada efisiensi dengan tetap mempertahankan akurasi tinggi, menjadikannya kandidat ideal untuk perangkat bergerak di lapangan.


Meskipun berbagai studi telah membuktikan keampuhan *Transfer Learning* dengan arsitektur CNN ringan (*ResNet*, *EfficientNet*, *MobileNetV2/V3*) dalam klasifikasi penyakit daun jagung, terdapat gap yang signifikan yang perlu diisi. Pertama, banyak studi telah membahas MobileNetV2/V3 sebagai solusi *edge computing*, tetapi belum ada evaluasi sistematis yang memadai terhadap MobileNetV4 yang notabene merupakan arsitektur terbaru yang unggul. Pengujian mendalam yang membandingkan varian MobileNetV4 (*conv-small*, *conv-medium*, dan *conv-large*) dengan dua *optimizer* berbeda (*Adam* dan *SGD*) dalam penyakit daun jagung belum pernah dilakukan.. Belum ada studi khusus domain jagung yang secara eksplisit menguji MobileNetV4 melalui pendekatan *Transfer Learning* untuk klasifikasi multikelas.

Oleh karena itu, penelitian ini menjadi penting karena bertujuan untuk secara argumentatif mengisi celah tersebut dengan secara sistematis mengevaluasi dan membandingkan kinerja ketiga varian MobileNetV4 yang dikombinasikan dengan *Adam* dan *SGD*. Kontribusi utama dari penelitian ini adalah menyajikan analisis perbandingan terlengkap MobileNetV4 untuk identifikasi penyakit daun jagung, guna mengidentifikasi konfigurasi model yang paling optimal, akurat, dan efisien untuk implementasi praktis di sektor pertanian Indonesia.

Metode Penelitian

Tahapan Penelitian

Penelitian ini melibatkan tahapan-tahapan kerja yang telah direncanakan dan dikoordinasikan secara efektif, Gambar 1 mengilustrasikan alur dari penelitian ini. Proses dimulai dengan studi literatur yang relevan terkait penelitian ini untuk memahami penggunaan metode CNN dalam mengklasifikasi penyakit daun tanaman jagung. Proses selanjutnya adalah pengumpulan dataset, tahap ini melibatkan Pengumpulan Dataset citra daun jagung. Tahap Perancangan adalah inti dari metodologi, di mana model klasifikasi disiapkan. Ini mencakup tiga langkah penting yaitu, *preprocessing*, konfigurasi *transfer learning*. Selanjutnya tahap Implementasi melibatkan pelatihan (*training*) model berdasarkan perancangan yang telah dibuat. Dan terakhir tahap Pengujian yang bertujuan untuk mengevaluasi kinerja akhir dari enam konfigurasi model MobileNetV4 yang telah dilatih menggunakan data pengujian yang sepenuhnya baru dan tidak pernah dilihat oleh model.




Gambar 1. Diagram alir Metodologi Penelitian

MobileNetV4

MobileNetV4 (MNv4) merupakan iterasi terbaru dari arsitektur *Convolutional Neural Network* (CNN) yang dikembangkan oleh Google pada tahun 2024. MobileNetV4 dirancang untuk mencapai efisiensi universal dan performa optimal di berbagai *platform* perangkat seluler. Tujuan utamanya adalah mencapai kinerja *mostly Pareto optimal* yang seimbang antara akurasi dan latensi di berbagai perangkat keras [19]. MobileNetV4 memperkenalkan dua blok bangunan utama yaitu *Universal Inverted Bottleneck* (UIB) dan *Mobile Multi-Query Attention* (hanya digunakan pada varian *Hybrid*) [19].

UIB memperluas *Inverted Bottleneck* (IB) yang diperkenalkan sejak MobileNetV2/V3. UIB berfungsi sebagai blok pencarian terpadu dan fleksibel yang mengintegrasikan fitur dari desain jaringan mutakhir seperti *Inverted Bottleneck*, *ConvNext*, *Feed Forward Network* (FFN), dan varian baru *Extra Depthwise*. Ini memungkinkan fleksibilitas pada setiap tahap jaringan untuk menyeimbangkan *spatial mixing* dan *channel mixing* yang optimal, menyesuaikan operasi yang paling efisien dengan kemampuan *hardware* target. Gambar 2 menunjukkan semua kemungkinan UIB untuk tiap *optional depthwise* [20].



Gambar 2. Universal Inverted Bottleneck (UIB) blocks[19]

MobileNetV4 dirancang untuk meningkatkan efisiensi *inference* dengan mengoptimalkan *depthwise separable convolution* dan *block conv dynamic*, menjadikannya kandidat kuat untuk aplikasi *mobile* dan pertanian presisi. Meskipun MobileNetV2 dan V3 sudah efisien, MobileNetV4 dalam paper resminya berjudul “*MobileNetV4 -- Universal Models for the Mobile Ecosystem*” meng-*claim* mendapatkan peningkatan akurasi hingga 87% pada ImageNet-1K, dan juga memberikan peningkatan kecepatan yang signifikan sebesar 39% [19]. Dengan membandingkan varian small, medium, dan large dari MobileNetV4, penelitian ini bertujuan untuk mengidentifikasi model yang tidak hanya akurat tetapi juga paling efisien dan siap diimplementasikan untuk diagnosis penyakit daun jagung di lapangan.

Pengumpulan Datastet

Pada tahap ini dilakukan pengumpulan data berupa gambar daun jagung. Tabel 1 menyajikan deskripsi rinci mengenai sumber, kondisi pengambilan foto, pembagian, jumlah kelas, dan total gambar dari dataset yang digunakan.

Tabel 1. Deskripsi dataset

Karakteristik	Deskripsi
Sumber <i>dataset</i>	Kaggle “Corn Leaf Disease” [21] [22]. dikumpulkan dari lahan jagung seluas 10 hektar di Kabupaten Sampang milik Dinas Pertanian
Resolusi Kamera	Diambil menggunakan kamera ponsel resolusi 16 Megapiksel
Kondisi pengambilan foto	Gambar diambil dengan meletakkan kertas putih di belakang daun dan menghindari gangguan dari objek lain. Citra diambil 5 kali. Pemotretan dilakukan pada siang hari (12.00 - 14.00 WIB)
Pembagian data	80 % data pelatihan, 10% data validasi dan 10% data pengujian
Jumlah Kelas	4 Kelas (Bercak Daun, Hawar Daun, Karat Daun, dan Daun Sehat)
Total Gambar	4000 Gambar, 1000 Gambar pada tiap kelasnya

Perancangan

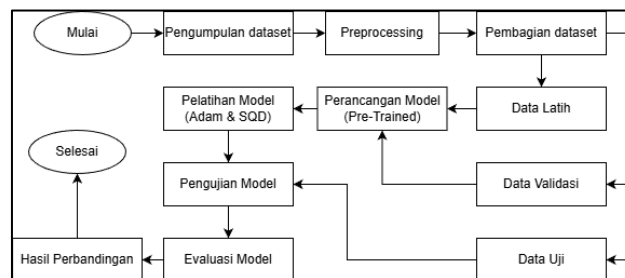
Pada tahap ini dilakukan perancangan sistem yang dibutuhkan, dimulai dengan pengumpulan data, lalu data citra yang telah dikumpulkan diunggah pada folder terpisah tiap kelasnya. Selanjutnya dilakukan preprocessing data. Semua citra distandarisasi ukurannya berdasarkan spesifikasi varian MobileNetV4 (224, 256, atau 384 piksel) dan nilai intensitas piksel dinormalisasi dari rentang 0-255 ke rentang 0-1 agar jaringan lebih cepat beradaptasi pada saat proses pelatihan.

Tahap selanjutnya data dibagi dengan bobot 80% untuk data pelatihan, 10% untuk data validasi dan 10% untuk data pengujian. Untuk mengurangi *overfitting* akan dilakukan data augmentasi yang diterapkan hanya pada data pelatihan. Augmentasi data adalah menggabungkan kumpulan metode yang meningkatkan atribut dan ukuran dataset pelatihan [23], meliputi beberapa metode seperti *random rotation*, *horizontal* dan *vertical flipping*, serta *zooming*.

Proses selanjutnya adalah Pemodelan CNN dilakukan menggunakan arsitektur *MobileNetV4-Conv-Small*, *MobileNetV4-Conv-Medium*, dan *MobileNetV4-Conv-Large*, yang semuanya telah dilatih sebelumnya pada *dataset ImageNet (pretrained model)*. Pelatihan dilakukan menggunakan skema *Feature Extraction* sehingga bobot base MobileNetV4 tetap beku (*frozen*), sedangkan lapisan *Classification Head* yang baru dilatih dengan strategi *early convergence*. Membekukan *backbone* model karena model *pretained* telah dilatih pada *dataset ImageNet* yang sangat besar, diharapkan telah berhasil mempelajari fitur-fitur fundamental dan generik (tepi, tekstur, bentuk) yang relevan untuk klasifikasi citra. Dengan hanya melatih lapisan *head* yang relatif kecil, waktu pelatihan menjadi jauh lebih singkat dan efisien, yang sejalan dengan tujuan penelitian untuk mengembangkan solusi yang optimal dan *deployable*.

Setelah tahap pemodelan, dilakukan optimasi model menggunakan dua algoritma *optimizer* yaitu Adam dan SGD, untuk membandingkan performa keduanya dalam proses pelatihan. *Hyperparameter* yang digunakan meliputi *learning rate*, *batch size* serta jumlah *epoch* untuk mengatur laju pembelajaran selama *training*.

Setelah pelatihan selesai, model kemudian melalui tahap terakhir yaitu Evaluasi Model, dilakukan Evaluasi Model guna mengukur metrik kinerjanya dalam mengklasifikasikan penyakit. Kinerja model dinilai dengan menghitung *accuracy*, *precision*, *recall* dan *F1-Score* yang diperoleh melalui *confusion matrix*. Hasil kedua skenario pelatihan (Adam dan SGD) kemudian dibandingkan untuk melihat pengaruh masing-masing *optimizer* terhadap performa klasifikasi. Gambar 3 merupakan skema perancangan penelitian dengan *MobileNetV4*.



Gambar 3. Skema perancangan penelitian

Implementasi

Pada tahapan ini dilakukan implementasi dari sistem yang telah dirancang pada tahap sebelumnya menggunakan data training agar sistem dapat mengenali dan melakukan klasifikasi terhadap data uji yang telah dipisahkan sebelumnya. Sistem dirancang menggunakan *google colab* dengan menggunakan bahasa pemrograman *python* dengan *library PyTorch* sebagai *framework* utama dan *timm (PyTorch Image Models)* sebagai *MobileNetV4 pre-trained model*. Data validasi digunakan pada akhir setiap *epoch* pelatihan. Model dievaluasi menggunakan data ini untuk menghitung *Validation Loss* dan *Validation Accuracy*. Untuk memastikan model tidak mengalami *overfitting*, *Training Accuracy* dan *Validation Accuracy* harus bergerak berdekatan. Jika *Training Accuracy* terus meningkat sementara *Validation Accuracy* stagnan atau menurun, ini mengindikasikan *overfitting*. Tabel 2 menampilkan *hyperparameter* yang digunakan pada penelitian ini. Penetapan *hyperparameter* yang digunakan berdasarkan penelitian terdahulu yang terkait yang menggunakan *optimizer*, *learning rate*, *epoch* dan *batch size* yang sama pada model terbaiknya [8].

Tabel 2. Hyperparameter penelitian

Hyperparameter	Konfigurasi
Batch Size	32
Epoch	50
Optimizer	Adam dan SGD
Learning Rate	0,01
Momentum SGD	0,9
Beta Adam	β_1 : 0,9; β_2 : 0,999

Pengujian

Pada tahap ini, dilakukan serangkaian pengujian terhadap fungsionalitas sistem yang telah dibangun dengan memanfaatkan data pengujian.. Setelah tahapan uji coba, hasil pengujian dihitung untuk mendapatkan tingkat keberhasilan metode yang digunakan dengan *Confusion Matrix* dalam menghitung nilai *precision*, *recall*, dan *accuracy* yang dapat dilihat pada Persamaan (1), (2), (3) dan (4).

Accuracy adalah metrik yang mengukur proporsi total hasil prediksi model yang benar (baik prediksi positif maupun negatif) dibandingkan dengan total keseluruhan data atau prediksi yang dievaluasi. [24]. Dapat dilihat pada persamaan (1), dimana TP adalah *True Positive*, FP adalah *False Positive*, TN adalah *True Negative* dan FN adalah *False Negative*.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$

Precision adalah metrik yang menunjukkan proporsi dari semua hasil yang diprediksi positif oleh model yang sebenarnya merupakan kasus positif yang benar [24], seperti ditunjukkan pada persamaan (2).

$$precision = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

Recall adalah metrik yang menunjukkan proporsi kasus positif yang sebenarnya berhasil diidentifikasi dengan benar oleh model dari total keseluruhan kasus positif yang ada. [24], seperti ditunjukkan pada persamaan (3).

$$recall = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

F1 score merupakan metrik yang dihitung sebagai rata-rata harmonik dari Presisi dan Recall, yang berfungsi untuk memberikan nilai tunggal yang merepresentasikan keseimbangan antara kedua metrik tersebut [24], seperti ditunjukkan pada persamaan (4).

$$F1\ score = \frac{precision \times recall}{precision + recall} \times 100\% \quad (4)$$

Hasil Dan Pembahasan

Pada bagian ini dilakukan analisis terhadap hasil eksperimen yang telah dilakukan untuk melihat pengaruh penggunaan *optimizer* pada arsitektur *MobileNetV4-Conv-Small*, *MobileNetV4-Conv-Medium*, dan *MobileNetV4-Conv-Large* dengan *batch size* 32, *Epoch* 50 dan *Learning rate* 0,01. Hasil pengujian dapat dilihat pada Tabel 3 untuk *MobileNetV4-Conv-Small*, tabel 4 untuk *MobileNetV4-Conv-Medium* dan Tabel 5 untuk *MobileNetV4-Conv-Large*.

Tabel 3. Hasil Pengujian MobileNetV4-Conv-Small

No	Optimizer	Accuracy Validasi	Precision	Recall	F1 Score
1	Adam	0,9325	0,9063	0,9025	0,9031
2	SGD	0,9350	0,9225	0,9225	0,9222

Tabel 4. Hasil Pengujian MobileNetV4-Conv-Medium

No	Optimizer	Accuracy Validasi	Precision	Recall	F1 Score
1	Adam	0,9450	0,9003	0,8950	0,8940
2	SGD	0,9525	0,9284	0,9225	0,9200

Tabel 5. Hasil Pengujian MobileNetV4-Conv-Large

No	Optimizer	Accuracy Validasi	Precision	Recall	F1 Score
1	Adam	0,9350	0,9268	0,9250	0,9252
2	SGD	0,9375	0,9343	0,9325	0,9312


Berdasarkan data pada Tabel 3, penggunaan arsitektur *MobileNetV4-Conv-Small* terbaik menggunakan *optimizer Stochastic Gradient Descent* (SGD) dibandingkan dengan menggunakan *optimizer* Adam. Model ini mendapatkan akurasi tertinggi sebesar 93,50%, metrix evaluasi yang lain juga menunjukan hasil yang lebih baik dibanding penggunaan *optimizer* Adam seperti *precision* (0,9225), *recall* (0,9225) dan *F1 score* (0,9222).

Pada Tabel 4, pengujian pada arsitektur *MobileNetV4-Conv-Medium* juga memberikan kinerja yang lebih baik dengan *optimizer* SGD. Hasil pengujian ini meraih akurasi tertinggi 95,25% *accuracy*, berbeda sedikit

dengan penggunaan *optimizer* Adam yang meraih 94,5%, metrix evaluasi yang lain juga menunjukkan hasil yang lebih baik dibanding *optimizer* Adam seperti *precision* (0,9284), *recall* (0,9225) dan *F1 score* (0,9200).

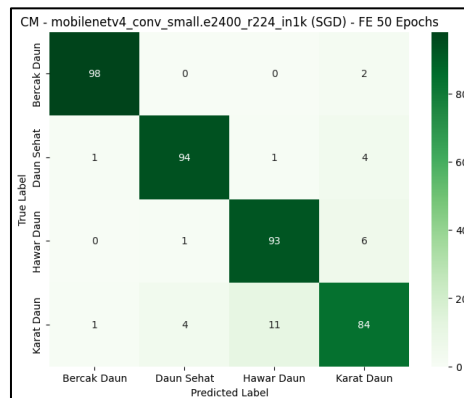
Pada Tabel 5, pengujian pada arsitektur *MobileNetV4-Conv-Large* meraih hasil kinerja yang lebih baik saat penggunaan *optimizer* SGD. Berdasarkan data, *optimizer* SGD meraih *accuracy* tertinggi sebesar 93,75% lebih unggul sedikit dibanding *optimizer* Adam yang meraih *accuracy* 93,50%. metrix evaluasi yang lain juga menunjukkan hasil yang lebih baik dibanding penggunaan *optimizer* Adam seperti *precision* (0,9343), *recall* (0,9325) dan *F1 score* (0,9252).

Gambar 4, grafik *loss* (kiri) menunjukkan *training loss* dan *eval loss* menurun sangat cepat, menyatu, dan stabil pada nilai rendah (~ 0.25) setelah *epoch* ke-10, yang menyiratkan proses pembelajaran yang sangat efisien dan stabil. Sementara itu, grafik *accuracy* (kanan) menunjukkan kurva akurasi pelatihan dan validasi meningkat secara bertahap dan konsisten hingga 90-93% pada *epoch* akhir. Kedua kurva akurasi yang bergerak sangat berdekatan menegaskan generalisasi yang sangat baik dan superioritas *optimizer* SGD dalam mencapai konvergensi yang stabil dan performa puncak yang tinggi.




Gambar 4. Grafik loss dan accuracy model MobileNetV4-Conv-Small SGD (terbaik)

Gambar 5 menunjukan *confusion matrix* yang menunjukkan model *small* terbaik berhasil mengklasifikasikan tiga dari empat kelas (Bercak Daun, Daun Sehat, dan Hawar Daun) dengan tingkat *recall* yang sangat tinggi (93-98%), sementara kelas Karat Daun memiliki *recall* terendah (84%), menegaskan kemampuan klasifikasi yang sangat baik pada 3 kelas namun masih memiliki kendala dalam mengklasifikasi kelas karat daun.



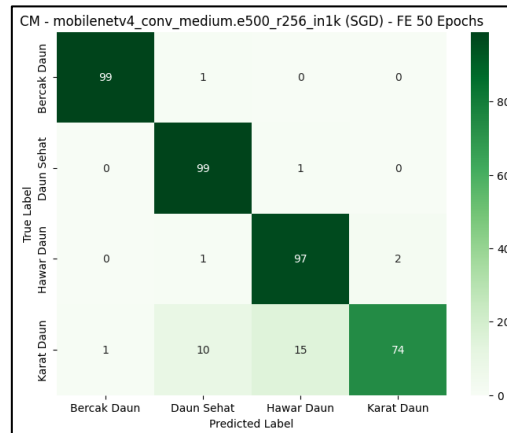
Gambar 5. Confusion matrix model MobileNetV4-Conv-Small SGD (terbaik)

Pada Gambar 6 menunjukan Grafik *Loss* dan *Accuracy* untuk model terbaik *MobileNetV4-Conv-Medium* (SGD), grafik *loss* (kiri) menunjukkan *loss* pelatihan dan validasi yang menurun dengan cepat dan kemudian stabil di tingkat rendah, sekitar 0.25 hingga 0.40, menunjukkan efisiensi dalam proses pembelajaran. Sementara itu, grafik akurasi (kanan) menunjukkan kurva akurasi yang meningkat pesat dan stabil pada tingkat sangat tinggi, dengan *eval_accuracy* mencapai hingga 95%. Namun, fluktuasi yang jelas pada kurva akurasi validasi mengindikasikan variabilitas yang lebih tinggi dalam generalisasi model per *epoch* dibandingkan model *Small*, meskipun kinerja puncaknya tetap kuat.




Gambar 6. Grafik loss dan accuracy model MobileNetV4-Conv-Medium SGD (terbaik)

Gambar 7 menunjukkan *confusion matrix* yang menampilkan akurasi klasifikasi yang sangat tinggi (97-99% *recall*) untuk kelas Bercak Daun, Daun Sehat, dan Hawar Daun. Satu-satunya kelemahan model ini terlihat pada kelas Karat Daun, di mana hanya 74% yang diklasifikasikan dengan benar (26 kesalahan), terutama karena pada kesalahan dengan memprediksinya sebagai Daun Sehat (10) dan Hawar Daun (15).



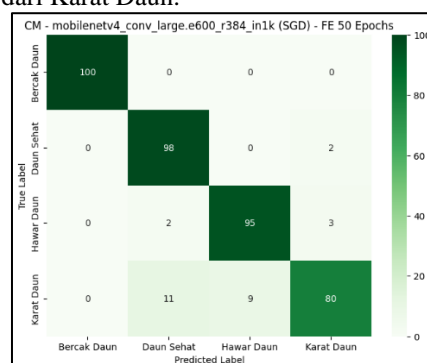
Gambar 7. Confusion matrix model MobileNetV4-Conv-Medium SGD (terbaik)

Pada Gambar 8 menunjukkan Grafik *Loss* dan *Accuracy* untuk model terbaik *MobileNetV4-Conv-Medium* (SGD), Grafik *Loss* (kiri) untuk model *MobileNetV4-Conv-Large* dengan *optimizer* SGD menunjukkan proses pembelajaran yang sangat efisien dan stabil, di mana *training_loss* dan *eval_loss* menurun dengan cepat pada awal dan kemudian stabil pada tingkat rendah, berkisar antara 0.4 hingga 0.5 setelah *epoch* 10. Kestabilan ini menunjukkan bahwa model tidak mengalami *overfitting* yang signifikan. Sementara itu, grafik Akurasi (kanan) menunjukkan peningkatan yang pesat dan stabil pada tingkat sangat tinggi, dengan *eval_accuracy* mencapai puncak hingga 93–94%. Kurva *training_accuracy* dan *eval_accuracy* berjalan berdekatan dan relatif stabil, mengindikasikan bahwa *MobileNetV4-Conv-Large* dengan *optimizer* SGD memiliki kemampuan generalisasi yang baik.



Gambar 8. Grafik loss dan accuracy model MobileNetV4-Conv-Large SGD (terbaik)

Gambar 9 menampilkan *confusion matrix* dari model MobileNetV4-Conv-Large terbaik dengan *optimizer* SGD, menunjukkan kinerja klasifikasi yang sangat kuat untuk sebagian besar kelas, dengan Bercak Daun (100%), Daun Sehat (98%), dan Hawar Daun (95%) mencapai *recall* yang sangat tinggi. Namun, kelemahan utama model terletak pada kelas Karat Daun, di mana hanya 80% dari kasus yang diklasifikasikan dengan benar; kesalahan klasifikasi yang signifikan terjadi karena model keliru memprediksi Karat Daun sebagai Daun Sehat (11 kasus) dan Hawar Daun (9 kasus), mengindikasikan adanya ambiguitas visual yang perlu diatasi model pada pemisahan kedua penyakit tersebut dari Karat Daun.



Gambar 9. Confusion matrix model MobileNetV4-Conv-Large SGD (terbaik)

Setelah menganalisis kinerja komparatif di enam skenario eksperimen, kami menemukan bahwa perbedaan performa antar konfigurasi model, meskipun belum diuji signifikansi statistiknya secara formal, menunjukkan konsistensi yang kuat pada seluruh metrik evaluasi (Akurasi, Presisi, *Recall*, dan *F1-Score*). Pada setiap varian arsitektur (Small, Medium, dan Large), SGD secara konsisten mengungguli Adam dengan margin akurasi validasi yang berkisar antara 0.25% hingga 1.75%. SGD dikenal memiliki kemampuan generalisasi yang lebih baik dan cenderung menemukan titik minimum *loss* yang lebih datar (*flatter minima*). Ini terbukti lebih tangguh terhadap variasi data validasi dan pengujian, yang menghasilkan akurasi yang lebih tinggi dan stabil [25].

MobileNetV4-Conv-Medium secara konsisten menghasilkan Akurasi Validasi tertinggi (95.25%), yang lebih tinggi dari varian Small dan Large. Keunggulan Medium disebabkan oleh tercapainya keseimbangan kapasitas model yang ideal terhadap *dataset* yang diuji, Analisis kurva *loss* dan *accuracy* menegaskan tidak adanya *overfitting* yang signifikan, yang didukung oleh strategi *Feature Extraction*.

Analisis *Confusion Matrix* secara konsisten menunjukkan bahwa Kelas Karat Daun (*Common Rust*) mencatat *Recall* terendah di semua skenario. Karat daun memiliki pola visual yang tumpang tindih dengan daun sehat dan hawar. Meskipun *dataset* seimbang, variasi *intra-kelas* pada Karat Daun kurang memadai bagi model *MobileNetV4* untuk mengekstrak fitur yang kuat, yang mendesak perlunya diversifikasi citra kelas tersebut untuk mengatasi kelemahan model dalam memisahkan sinyal fitur halus penyakit ini.

Simpulan

Berdasarkan analisis eksperimental yang membandingkan tiga varian *MobileNetV4-Conv* dan pengaruh *optimizer* Adam & SGD, penelitian ini berhasil mengimplementasikan dan mengevaluasi *benchmark* awal *MobileNetV4* di domain klasifikasi penyakit daun jagung, yang merupakan kontribusi teoritis signifikan. Hasil utama menunjukkan model *MobileNetV4-Conv-Medium* dengan *optimizer* SGD mencapai akurasi tertinggi sebesar 95,25%, menegaskan bahwa terjadi keseimbangan kapasitas model yang optimal pada varian Medium untuk *dataset* ini. Secara konsisten, SGD terbukti lebih unggul daripada Adam, mendukung teori optimasi bahwa *optimizer* dengan Momentum menghasilkan kemampuan generalisasi yang lebih baik (*flatter minima*) dalam strategi *Feature Extraction* di arsitektur ini.

Dengan akurasi yang melebihi 95% dan efisiensi komputasi *MobileNetV4*, model ini dianggap memadai untuk dipertimbangkan dalam *deployment* sebagai bagian dari sistem pendukung keputusan *mobile* di lapangan. Kontribusi praktis ini harus diikuti dengan mitigasi kendala implementasi yang ditemukan yaitu model secara konsisten kesulitan mengklasifikasikan Karat Daun (*Common Rust*) akibat ambiguitas visual pada *dataset*. Untuk pengembangan lebih lanjut, disarankan untuk meningkatkan diversifikasi citra Karat Daun serta melakukan pengujian skema *fine-tuning* dan *hyperparameter* yang lebih beragam. Model terbaik ini direkomendasikan untuk dirilis sebagai aplikasi *prototipe* atau melalui repositori publik untuk memvalidasi kinerja di dunia nyata dan memperkuat kontribusi ilmiah.

Daftar Pustaka

- [1] N. S. Amin, "Efisiensi Pemasaran Jagung Bisi-18 (Zea Mays) Di Desa Keang Kecamatan Kalukku Kabupaten Mamuju," *Journal Agrimu*, Vol. 2, Pp. 22–28, Jul. 2022, Doi: 10.26618/Agm.V2i2.7810.
- [2] Kementrian Pertanian, "Analisis Kinerja Perdagangan Jagung Pusat Data Dan Sistem Informasi Pertanian Sekretariat Jenderal Kementerian Pertanian 2024," Jakarta, 2024.
- [3] Dinas Pertanian, "Luas Panen Dan Produksi Jagung Di Indonesia 2024," Aug. 2025.
- [4] M. Fraiwan, E. Faouri, And N. Khasawneh, "Classification Of Corn Diseases From Leaf Images Using Deep Transfer Learning," *Mdpi Plants*, Vol. 11, No. 20, Oct. 2022, Doi: 10.3390/Plants11202668.
- [5] M. A. Setyawan, P. Kasih, And M. A. D. Widyadara, "Klasifikasi Penyakit Daun Jagung Berdasarkan Ruang Warna Hsv Dan Fitur Tekstur Dengan Algoritma K-Nn," *Prosiding Semnas Inotek (Seminar Nasional Inovasi Teknologi)*, No. 3, Pp. 067–072, Jul. 2022, Doi: 10.29407/Inotek.V6i3.2655.
- [6] S. S. Putro, N. Ansori, M. Fuad, E. M. S. Rochman, Y. P. Asmara, And A. Rachmad, "Corn Leaf Disease Classification Using Convolutional Neural Network Based On Mobilenetv2 With Rmsprop Optimization," *Mathematical Modelling Of Engineering Problems*, Vol. 12, No. 2, Pp. 465–474, 2025, Doi: 10.18280/Mmep.120211.
- [7] B. Widiyanto, E. Utami, And D. Ariatmanto, "Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan Convolutional Neural Network," *Techno.Com*, Vol. 22, No. 3, Pp. 599–608, Aug. 2023, Doi: 10.33633/Tc.V22i3.8425.
- [8] W. Maximilliano And N. Rachmat, "Comparative Analysis Of Mobilenetv3-Large And Small For Corn Leaf Disease Classification," *Brilliance: Research Of Artificial Intelligence*, Vol. 5, No. 1, Pp. 325–332, Jul. 2025, Doi: 10.47709/Brilliance.V5i1.6259.

- [9] J. B. J. R. Openg, M. Endah Hiswati, And H. Hamzah, “Klasifikasi Unggas Ordo Anseriformes Berdasarkan Citra Menggunakan Metode Deep Learning Dengan Algoritma Convolutional Neural Network (Cnn),” *Seminar Nasional Teknik Elektro, Informatika Dan Sistem Informasi*, Vol. 1, No. 1, Aug. 2022, Doi: 10.35842/Sintaks.V1i1.3.
- [10] R. Mawarni, R. Wulaningrum, And R. Helilintar, “Implementasi Metode Cnn Pada Klasifikasi Penyakit Jagung,” *Prosiding Semnas Inotek (Seminar Nasional Inovasi Teknologi)*, Vol. 7, No. 3, Pp. 1256–1263, 2023, Doi: 10.29407/Inotek.V7i3.3566.
- [11] I. P. Putra, R. Rusbandi, And D. Alamsyah, “Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network,” *Jurnal Algoritme*, Vol. 2, No. 2, Pp. 102–112, Apr. 2022, Doi: 10.35957/Algoritme.V2i2.2360.
- [12] H. Amin, A. Darwish, A. E. Hassanien, And M. Soliman, “End-To-End Deep Learning Model For Corn Leaf Disease Classification,” *Ieee Access*, Vol. 10, Pp. 31103–31115, 2022, Doi: 10.1109/Access.2022.3159678.
- [13] Y. Chen *Et Al.*, “Dfcanet: A Novel Lightweight Convolutional Neural Network Model For Corn Disease Identification,” *Agriculture (Switzerland)*, Vol. 12, No. 12, P. 2047, Dec. 2022, Doi: 10.3390/Agriculture12122047.
- [14] Q. N. Azizah, “Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network Alexnet,” *Sudo Jurnal Teknik Informatika*, Vol. 2, No. 1, Pp. 28–33, Feb. 2023, Doi: 10.56211/Sudo.V2i1.227.
- [15] D. R. Fernandes And N. Rachmat, “Klasifikasi Non-Destruktif Kemanisan Semangka Manohara Menggunakan Transfer Learning Vgg-16,” *Jurnal Teknologi Dan Manajemen Industri Terapan (Jtmit)*, Vol. 4, No. 4, Pp. 1330–1339, 2025, Doi: 10.55826/81wv2s06.
- [16] A. N. Inaya, A. U. Rahma, M. Jannah, L. R. K. Arafah, L. L. Ishak, And M. R. Edy, “Klasifikasi Citra Dengan Pendekatan Transfer Learning Pada Gambar Fauna Terbang,” *Jurnal Mediatik: Jurnal Media Pendidikan Teknik Informatika Dan Komputer*, Vol. 85, No. 1, 2024, Doi: 10.59562/Mediatik.V7i1.2785.
- [17] C. Bi, S. Xu, N. Hu, S. Zhang, Z. Zhu, And H. Yu, “Identification Method Of Corn Leaf Disease Based On Improved Mobilenetv3 Model,” *Agronomy*, Vol. 13, No. 2, P. 300, Feb. 2023, Doi: 10.3390/Agronomy13020300.
- [18] R. T. Wahyuningrum, R. Erfian, A. Kusumaningsih, And H. P. A. Tjahyaningtjas, “Klasifikasi Penyakit Daun Jagung Menggunakan Model Deep Learning Efficientnetb5,” *Jurnal Pekommas*, Vol. 10, No. 1, Jun. 2025, Doi: 10.56873/Jpkm.V9i1.5322.
- [19] D. Qin *Et Al.*, “Mobilenetv4: Universal Models For The Mobile Ecosystem,” Apr. 2024. Doi: 10.48550/Arxiv.2404.10518.
- [20] R. Rastogi, “Papers Explained 232: Mobilenetv4 | By Ritvik Rastogi | Medium,” Medium.Com. Accessed: Nov. 07, 2025. [Online]. Available: <https://Ritvik19.Medium.Com/Papers-Explained-232-Mobilenetv4-83a526887c30>
- [21] S. I. Saputra, “Corn Leaf Disease [Dataset],” Kaggle. Accessed: Nov. 22, 2025. [Online]. Available: <https://www.kaggle.com/datasets/ndisan/corn-leaf-disease>
- [22] S. Ghose, “Corn Or Maize Leaf Disease Dataset,” Kaggle. Accessed: Nov. 22, 2025. [Online]. Available: <https://www.kaggle.com/datasets/smaranjitghose/corn-or-maize-leaf-disease-dataset>
- [23] D. Trimakno And Kusriani, “Impact Of Augmentation On Batik Classification Using Convolution Neural Network And K-Nearest Neighbor,” In *2021 4th International Conference On Information And Communications Technology (Icoiact)*, Ieee, Aug. 2021, Pp. 285–289. Doi: 10.1109/Icoiact53268.2021.9564000.
- [24] L. Hakim, A. Sobri, L. Sunardi, And D. Nurdiansyah, “Prediksi Penyakit Jantung Berbasis Mesin Learning Dengan Menggunakan Metode K-Nn,” *Jurnal Digital Teknologi Informasi*, Vol. 7, No. 2, P. 14, Feb. 2025, Doi: 10.32502/Digital.V7i2.9429.
- [25] Z. Xie, I. Sato, And M. Sugiyama, “A Diffusion Theory For Deep Learning Dynamics: Stochastic Gradient Descent Exponentially Favors Flat Minima,” Jan. 2021, [Online]. Available: <http://arxiv.org/abs/2002.03495>