



# Optimisasi VGG16 dengan Transfer Learning dalam Mendeteksi Penyakit Pada Daun Jagung

Ade Ismiaty Ramadhona Ht. Barat<sup>1\*</sup>, Wiwik Sri Astuti<sup>1</sup>, Anjar Wanto<sup>2</sup>, Solikhun Solikhun<sup>3</sup>

<sup>1</sup> Magister Program, Mahasiswa Program Studi Magister Informatika, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

<sup>2</sup> Program Studi Informatika, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

<sup>3</sup> Program Studi Teknik Informatika, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Email: <sup>1\*</sup>ade@amiktunasbangsa.ac.id, <sup>2</sup>wiwikastuti@amiktunasbangsa.ac.id, <sup>3</sup>anjarwanto@amiktunasbangsa.ac.id, <sup>4</sup>solikhun@amiktunasbangsa.ac.id

Email Penulis Korespondensi: ade@amiktunasbangsa.ac.id

**Abstrak**—Jagung merupakan salah satu komoditas pangan utama yang memegang peranan strategis dalam ketahanan pangan nasional. Namun, produktivitas jagung kerap menurun akibat serangan penyakit pada daun seperti *Blight*, *Common Rust*, dan *Gray Leaf Spot*. Deteksi penyakit secara manual masih bersifat subjektif dan tidak efisien, terutama dalam skala besar. Penelitian ini bertujuan untuk mengembangkan sistem otomatis berbasis *deep learning* guna mengklasifikasikan penyakit daun jagung secara akurat. Model yang digunakan adalah arsitektur Convolutional Neural Network (CNN) VGG16 dengan pendekatan *transfer learning*. Dataset yang digunakan terdiri dari 1.200 citra daun jagung berlabel empat kelas penyakit, diperoleh dari *platform* Kaggle. Teknik augmentasi citra diterapkan untuk meningkatkan variasi data dan kemampuan generalisasi model. Kinerja VGG16 dengan *transfer learning* dibandingkan dengan VGG16 *Baseline* dan MobileNetV2 sebagai pembanding. Hasil pengujian menunjukkan bahwa model VGG16 dengan *transfer learning* mencapai akurasi klasifikasi tertinggi sebesar 96,25%, lebih unggul dibandingkan VGG16 *Baseline* (92,92%) dan MobileNetV2 (84,58%). Temuan ini membuktikan bahwa pemanfaatan VGG16 dengan *transfer learning* dapat menjadi solusi efektif dalam sistem deteksi dini penyakit daun jagung secara otomatis, serta mendukung penerapan teknologi pertanian presisi.

**Kata Kunci:** CNN; Klasifikasi Citra; Deteksi Penyakit Daun Jagung; Transfer Learning; VGG16

**Abstract**—Corn is one of the major agricultural commodities that plays a strategic role in national food security. However, its productivity often declines due to leaf diseases such as *Blight*, *Common Rust*, and *Gray Leaf Spot*. Manual disease detection is considered inefficient and prone to human error, especially on a large scale. This study aims to develop an automated deep learning-based system for accurate classification of corn leaf diseases. The proposed model utilizes the Convolutional Neural Network (CNN) architecture VGG16 with a transfer learning approach. The dataset comprises 1,200 labeled images of corn leaves categorized into four disease classes, obtained from Kaggle. Image augmentation techniques were applied to improve data diversity and enhance model generalization. The performance of VGG16 was compared with VGG16 *Baseline* architecture and MobileNetV2. Experimental results show that VGG16 with transfer learning achieved the highest classification accuracy of 96.25%, outperforming the baseline VGG16 (92.92%) and MobileNetV2 (84.58%). These findings demonstrate the effectiveness of VGG16-based transfer learning in automating corn leaf disease detection, supporting the implementation of precision agriculture technology.

**Kata Kunci:** CNN; Image Classification; Corn Leaf Disease; Transfer Learning; VGG16

## 1. PENDAHULUAN

Selain beras, jagung merupakan salah satu komoditas pangan utama di Indonesia yang memiliki peran vital dalam ketahanan pangan nasional, yang juga merupakan bahan pangan pokok yang banyak diminati masyarakat [1]. Tanaman jagung memiliki daya hasil tinggi dan kegunaan luas, selain digunakan sebagai bahan pangan pokok, dapat juga digunakan sebagai pakan ternak dan bahan baku industri [2]. Tanaman jagung memiliki tingkat konsumsi yang tinggi, sehingga penyakit pada daun jagung dapat menimbulkan ancaman yang signifikan terhadap produktivitas pertanian yang dapat mempengaruhi perekonomian petani [3]. Penyakit pada daun jagung seperti *Blight*, *Common Rust*, dan *Gray Leaf Spot* sangat mengganggu produktivitas tanaman jagung [4]. Penyakit pada daun jagung dapat menimbulkan kerugian yang besar bagi petani apabila tidak terdeteksi dan ditangani sejak dini [5].

Selama ini penyakit pada daun jagung dideteksi dengan metode tradisional, yang dilakukan secara manual oleh petani atau spesialis pertanian melalui pemeriksaan visual [6]. Metode tradisional ini tidak hanya memakan waktu, biaya, dan tenaga, tetapi juga rentan terhadap kesalahan manusia, terutama dalam pengaturan lingkungan yang kompleks [7]. Oleh karena itu, diperlukan pendekatan berbasis teknologi yang tepat untuk dapat mendeteksi penyakit pada daun jagung secara otomatis, cepat dan akurat [8].

Dengan perkembangan teknologi komputer, khususnya dalam bidang kecerdasan buatan, telah mendorong lahirnya pendekatan baru dalam pemrosesan data berbasis *citra*, salah satunya adalah *Deep learning* [9]. Algoritma yang paling banyak digunakan dalam *Deep learning* adalah Convolutional Neural Networks (CNN), yang dikenal efektif dalam tugas-tugas klasifikasi berbasis citra [10]. CNN memiliki kemampuan untuk mengenali pola visual dan mengekstraksi fitur kompleks secara otomatis, sehingga menghasilkan tingkat akurasi yang tinggi dalam pengenalan *citra* [11]. Oleh karena itu, CNN menjadi fondasi penting dalam berbagai aplikasi berbasis *citra digital*, termasuk dalam bidang pertanian untuk mendeteksi dan mengklasifikasikan penyakit tanaman [12]. Meskipun telah banyak pendekatan dilakukan, mayoritas penelitian sebelumnya masih mengandalkan arsitektur *Convolutional Neural Network* (CNN) dasar yang dirancang dari awal, cenderung membutuhkan jumlah data pelatihan yang besar dan waktu pelatihan yang panjang [13].

VGG16 adalah salah satu arsitektur CNN dalam yang pertama kali diperkenalkan oleh Simonyan & Zisserman pada tahun 2014, dalam kompetisi *ImageNet Large Scale Visual Recognition Challenge* dan terkenal karena



kemampuannya dalam mengekstraksi fitur visual yang kompleks dan halus [14]. Model ini terdiri dari 16 lapisan dan memiliki kemampuan menangkap pola penyakit yang kecil dan samar pada daun jagung [15]. Dengan penerapan *transfer learning*, bobot dari pelatihan sebelumnya pada dataset besar seperti ImageNet dapat dimanfaatkan dan disesuaikan dengan dataset yang lebih kecil dan spesifik, seperti citra daun jagung [16]. Pendekatan ini tidak hanya mempercepat proses pelatihan, tetapi juga meningkatkan akurasi model meskipun dengan data terbatas [17].

Penelitian-penelitian sebelumnya lebih banyak menggunakan CNN konvensional, AlexNet, atau model yang dioptimasi secara manual dengan ekstraksi fitur seperti pada [18], mengevaluasi berbagai arsitektur pembelajaran mendalam, termasuk VGGNet, InceptionV3, ResNet50, dan InceptionResNetV2. ResNet50 menunjukkan kinerja yang unggul, menggarisbawahi kemandirian arsitektur mendalam dalam aplikasi klasifikasi *citra*. ResNet50 mencapai akurasi validasi sebesar 87,51%, presisi sebesar 90,33%, dan *recall* sebesar 99,80% dalam klasifikasi penyakit daun jagung, dengan demikian menggarisbawahi keuntungan dari model jaringan saraf konvolusional yang lebih dalam dibandingkan dengan model yang lebih sederhana. Namun, belum mengeksplorasi penggunaan VGG16 dengan *transfer learning*.

Selanjutnya penelitian oleh [19], menggunakan campuran Gray-Level Co-occurrence Matrix (GLCM) untuk ekstraksi fitur tekstur dan karakteristik warna HSV, memanfaatkan K-Nearest Neighbors (KNN) untuk klasifikasi. Teknik hibrida ini mencapai akurasi 85% dalam pengaturan tertentu, tetapi tidak memiliki kemampuan pembelajaran fitur otomatis seperti yang dimiliki oleh model *deep learning* terkini.

Lalu, penelitian oleh [20], menilai efikasi AlexNet, ResNet-18, dan VGG16 dalam mengklasifikasikan penyakit daun jagung. VGG16 mencapai akurasi uji sebesar 94,31%, sama dengan AlexNet dan hanya dilampaui oleh ResNet-18, yang mencapai 95,50%. Hal ini menggarisbawahi efikasi VGG16 dalam tugas kategorisasi yang rumit. Ini menunjukkan efektivitas VGG16 dalam tugas klasifikasi multi-kelas yang kompleks. Sayangnya, studi tersebut belum secara sistematis menilai aspek evaluasi model dengan metrik lengkap seperti presisi, *recall*, dan *F1-Score*.

Kemudian, penelitian oleh [21] menggunakan AlexNet untuk klasifikasi penyakit daun jagung, mencapai akurasi 90%. Meskipun hasilnya menjanjikan, penelitian ini tidak menyelidiki pembelajaran transfer atau mengevaluasi kinerja terhadap sistem kontemporer lainnya.

Terakhir, penelitian oleh [22] menyarankan sebuah metode untuk mendeteksi penyakit daun jagung secara tepat menggunakan arsitektur Convolutional Neural Network (CNN). Model CNN yang disempurnakan ini menggunakan fungsi aktivasi Rectified Linear Unit (ReLU) dan dilatih serta dievaluasi pada empat kategori *citra* daun jagung yang terpisah. Model ini disempurnakan menggunakan pengoptimal Adam, dengan penyempurnaan tambahan yang dicapai melalui penyesuaian hiperparameter, pengoptimalan proses, dan pengurangan kompleksitas pengklasifikasi. Hasil eksperimen menunjukkan bahwa model tersebut mencapai akurasi deteksi rata-rata sebesar 93,75% dalam mengenali tiga bentuk penyakit daun jagung yang berbeda. Namun, belum mengeksplorasi VGG16 dengan *transfer learning* dengan empat kelas berbeda.

Penelitian – penelitan tersebut menunjukkan efektivitas dalam tugas klasifikasi multi-kelas yang kompleks. Namun, jarang mengevaluasi arsitektur VGG16 dengan *transfer learning* secara mendalam untuk daun jagung [23]. Selain itu, belum banyak yang membandingkan secara langsung antara VGG16 dan arsitektur ringan seperti MobileNetV2 dalam konteks penyakit daun jagung.

MobileNetV2 dikenal sebagai model CNN ringan yang dirancang untuk efisiensi komputasi tinggi, sehingga ideal untuk implementasi pada perangkat dengan sumber daya terbatas [24]. Namun, karena desainnya yang ringan, ia cenderung memiliki kedalaman representasi fitur yang lebih rendah dibandingkan dengan VGG16 [25]. Hal ini dapat berdampak pada kemampuannya dalam membedakan fitur penyakit daun yang kompleks atau memiliki pola tumpang tindih [26].

Berdasarkan tinjauan tersebut, dapat disimpulkan bahwa terdapat kesenjangan penelitian (*research gap*) yang signifikan, khususnya dalam pemanfaatan VGG16 berbasis *transfer learning* untuk klasifikasi multi-kelas penyakit daun jagung secara otomatis. Sebagian besar penelitian masih menggunakan arsitektur dasar atau model ringan tanpa mempertimbangkan potensi dari model dalam seperti VGG16 dalam konteks data terbatas. Selain itu, belum banyak penelitian yang mengintegrasikan teknik peningkatan data (*data augmentation*) dan *fine tuning* pada lapisan akhir untuk mengoptimalkan generalisasi model.

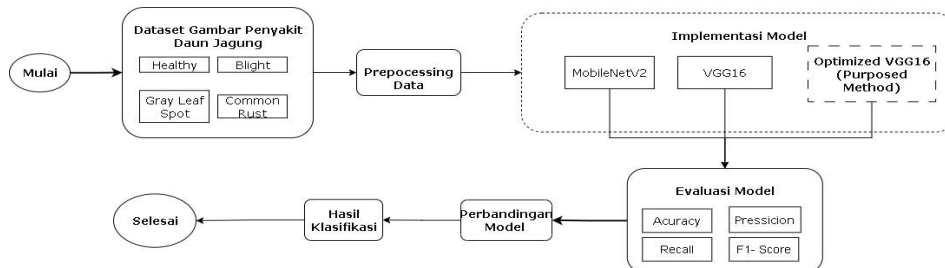
Oleh karena itu, penelitian ini bertujuan untuk mengembangkan dan mengoptimasi model CNN berbasis VGG16 menggunakan teknik *transfer learning* dalam mendeteksi dan mengklasifikasi penyakit daun jagung dari citra *digital*. Model ini akan dilatih dengan data citra yang telah diperkuat (*augmented*) dan disesuaikan melalui *fine tuning* untuk meningkatkan performa pada dataset terbatas. Untuk memperkuat hasil, model VGG16 dengan *transfer learning* akan dibandingkan dengan MobileNetV2 dan model VGG16 *Baseline* dari segi akurasi, *precision*, *recall*, *F1-Score*, serta efisiensi komputasi.

Kontribusi utama dari penelitian ini adalah, pengembangan sistem klasifikasi penyakit daun jagung berbasis VGG16 dengan *transfer learning* yang mampu bekerja efektif pada data terbatas, evaluasi komprehensif terhadap performa model menggunakan metrik evaluasi yang lengkap, serta analisis perbandingan terhadap MobileNetV2 dan model VGG16 dasar sebagai pembanding untuk menilai keseimbangan antara akurasi dan efisiensi komputasi. Penelitian ini diharapkan dapat memberikan solusi praktis dalam penerapan teknologi *deep learning* untuk pertanian presisi dan mendukung petani dalam diagnosis penyakit secara cepat dan akurat.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Tahapan penelitian ini mencakup beberapa fase penting, yaitu pengumpulan dataset, *preprocessing*, pembagian dataset, implementasi dan pengoptimalan model, pelatihan model, penilaian, dan keluaran klasifikasi akhir. Adapun Tahap - tahap spesifik digambarkan pada Gambar 1.



**Gambar 1.** Tahapan Penelitian

Gambar 1 mengilustrasikan tahapan penelitian yang diusulkan yang menguraikan pendekatan sistematis untuk mengklasifikasikan penyakit daun jagung menggunakan teknik *deep learning*. Tahapan penelitian ini bertujuan untuk menyampaikan model klasifikasi penyakit pada daun jagung yang akurat, efisien, dan stabil yang berkontribusi pada pengembangan pertanian dan kemajuan *deep learning*.

Penelitian dimulai dengan pengumpulan dataset gambar daun jagung yang terdiri atas empat kelas, yaitu *Healthy*, *Blight*, *Gray Leaf Spot*, dan *Common Rust*. Selanjutnya, data tersebut melalui tahap *preprocessing* yang mencakup *resize*, *normalisasi*, dan *augmentasi* untuk meningkatkan keragaman data dan mempersiapkan data agar sesuai dengan arsitektur model yang digunakan. Tahap implementasi model mencakup tiga pendekatan, yaitu *MobileNetV2*, *VGG16*, dan *VGG16* yang telah dioptimasi melalui teknik *transfer learning* dan *fine-tuning*, yang dalam penelitian ini merupakan metode yang diusulkan. Setelah proses pelatihan, ketiga model dievaluasi menggunakan metrik performa seperti akurasi, presisi, recall, dan *F1-score*. Hasil dari evaluasi ini digunakan dalam proses perbandingan model guna mengidentifikasi pendekatan terbaik dalam mengklasifikasikan penyakit daun jagung. Akhirnya, model dengan performa terbaik akan digunakan untuk menghasilkan klasifikasi akhir, yang kemudian menjadi dasar dalam menyimpulkan hasil penelitian.

### 2.2 Dataset Penyakit Daun Jagung

Salah satu faktor utama yang menyebabkan penurunan produktivitas tanaman penyakit pada daun jagung, deteksi dini terhadap penyakit daun dapat membantu petani dalam mengambil langkah pengendalian yang tepat dan efisien. Ada empat kondisi daun jagung yaitu *Blight*, *Common Rust*, dan *gray leaf spot* dapat sangat mengurangi hasil panen jika tidak diobati segera. Adapun sampel *citra* penyakit daun jagung ditunjukkan pada Gambar 2.



**Gambar 2.** Sampel Penyakit Daun Jagung

Gambar 2 menunjukkan ilustrasi visual dari empat kategori kondisi daun jagung yang digunakan sebagai data penelitian ini, setiap *citra* menunjukkan fitur unik dari kelasnya. Bercak nekrotik memanjang berwarna cokelat kehitaman menyerang permukaan daun pada *citra Blight* yang disebabkan oleh infeksi jamur *Puccinia sorghi* menunjukkan gejala infeksi berat yang mengganggu fotosintesis tanaman. Pada kelas *Healthy*, daun memiliki warna hijau yang merata tanpa bercak atau kerusakan jaringan, yang menunjukkan bahwa kondisi fisiologis daun normal dan tidak sakit. Bintik-bintik kecil berwarna jingga hingga cokelat kemerahan tersebar di permukaan daun dari kelas *Common Rust*. *Gray Leaf Spot*, daun menunjukkan gejala bercak memanjang berwarna abu-abu kecokelatan yang umumnya berkembang secara horizontal sejajar dengan tulang daun. Serangan jamur *Cercospora zeaе-maydis* sering terjadi di lingkungan yang lembap, dan ciri serangan ini adalah bercak ini [27]. Karena masing-masing kelas memiliki pola dan struktur visual yang berbeda, yang dapat diidentifikasi oleh model *Deep Learning*, keempat contoh visual ini memberikan *citraan* penting tentang proses klasifikasi Citra.

Dataset terdiri dari 1.200 citra daun jagung yang dikategorikan ke dalam 4 kelas diambil dari <https://www.kaggle.com/datasets/smaranjitghose/corn-or-maize-leaf-disease-dataset> dan digunakan untuk mempelajari model *VGG16*. Jumlah *citra* yang digunakan total adalah 1.200, dan pendistribusian datanya ditunjukkan dalam Tabel 1.

**Table 1.** Jumlah Citra

| No | Jenis Penyakit Daun Jagung | Jumlah Citra |
|----|----------------------------|--------------|
| 1  | <i>Blight</i>              | 300          |
| 2  | <i>Common Rust</i>         | 300          |
| 3  | Gray Leaf Spot             | 300          |
| 4  | Healthy                    | 300          |
|    | Total                      | 1200         |

Untuk mencapai hasil terbaik, data didistribusikan secara merata di antara 4 kelas daun jagung. Tabel 1 menunjukkan empat jenis penyakit pada daun jagung yang berbeda yaitu, kelas (*Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*).


### 2.3 Preprocessing Data

Untuk memastikan data seragam dan siap, citra daun jagung diproses sebelum digunakan dalam proses pelatihan model. Untuk memenuhi format input standar arsitektur VGG16, ukuran citra secara keseluruhan diubah menjadi 224 x 224 piksel. Nilai piksel juga dinormalisasi dari 0 hingga 1 untuk meningkatkan efisiensi dan stabilitas proses pembelajaran model. Teknik augmentasi data seperti rotasi, flipping, dan zooming digunakan untuk meningkatkan keragaman dataset dan mengurangi risiko overfitting, yang pada akhirnya berkontribusi pada kinerja model yang lebih kuat. Terakhir, label kelas, yang sebelumnya berbentuk teks, diubah menjadi format enkripsi satu panas sehingga algoritma klasifikasi berbasis pembelajaran mendalam dapat membedakan dan memprosesnya. Tujuan dari proses ini adalah untuk meningkatkan kualitas input dan mengoptimalkan kinerja model [32]. Dengan memperkenalkan variasi-variasi ini, model menjadi lebih tangguh terhadap perubahan orientasi daun, kondisi pencahayaan, dan posisi. Akibatnya, akurasi prediksi pada data uji meningkat.

### 2.4 Implementasi Arsitektur VGG16

Salah satu arsitektur Convolutional Neural Network (CNN) yang dikembangkan oleh Visual Geometry Group di University of Oxford adalah VGG16. Simonyan dan Zisserman pertama kali memperkenalkannya dalam kompetisi ILSVRC (ImageNet Large Scale Visual Recognition Challenge) pada tahun 2014. Jumlah 16 lapisan jaringan yang dapat dilatih, yang terdiri dari 13 lapisan konvolusi dan 3 lapisan terhubung sepenuhnya, disebut sebagai VGG16 [28].

Salah satu ciri khas VGG16 adalah penggunaan filter konvolusi kecil berukuran 3x3 yang diulang berulang kali serta penggunaan max pooling 2x2 untuk mengurangi dimensi ruang. Arsitektur ini memiliki tiga saluran warna (RGB) dan dimensi 224 x 224 piksel sebagai input standar. Model ini dirancang untuk mengekstraksi fitur rendah dari *citra* hingga fitur tinggi, seperti bentuk dan pola kompleks. VGG16 banyak digunakan dalam tugas *transfer learning* karena arsitekturnya yang sederhana meskipun konsisten [29]. Bagian konvolusi VGG16 digunakan sebagai *feature extractor* dalam penelitian ini, sedangkan lapisan klasifikasi disesuaikan dengan jumlah kelas penyakit daun jagung seperti pada Gambar 3.


**Gambar 3.** Arsitektur VGG16

Gambar 3 menggambarkan arsitektur dari model VGG16, yang dikenal dengan penggunaan berulang filter konvolusi berukuran kecil 3x3 serta lapisan max-pooling 2x2 untuk mengurangi dimensi feature map. Model ini menerima input berupa citra berukuran 224x224 piksel dengan 3 saluran warna (RGB). Selanjutnya, citra ini diproses secara bertahap melalui lima blok konvolusi, di mana setiap blok terdiri dari beberapa lapisan konvolusi yang diikuti oleh satu lapisan pooling. Setelah melewati seluruh blok, hasil ekstraksi fitur kemudian diratakan dan diteruskan ke dalam lapisan-lapisan *fully connected (dense)* untuk proses klasifikasi akhir. Pendekatan ini memungkinkan model untuk menangkap pola visual yang kompleks dan mendetail secara bertahap, mulai dari fitur rendah hingga tingkat abstraksi yang lebih tinggi.

#### 2.4.1 VGG16 Optimized dengan Transfer Learning

Model *Optimized VGG16* dalam penelitian ini dibangun dengan pendekatan *transfer learning*, yaitu teknik pemanfaatan bobot (*weights*) dari model yang telah dilatih sebelumnya pada dataset berskala besar (seperti ImageNet) untuk mempercepat dan meningkatkan kinerja model pada tugas klasifikasi baru yang memiliki dataset terbatas. Dalam hal ini, arsitektur VGG16 yang telah dilatih pada lebih dari 1 juta *citra* dalam ImageNet digunakan kembali untuk mendeteksi

penyakit pada daun jagung. Kemampuan ini telah terbukti efektif dalam berbagai tugas klasifikasi citra, terutama ketika diimplementasikan dalam skenario *transfer learning*, sebagaimana ditunjukkan pada Gambar 4.



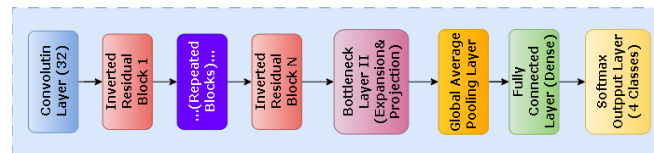
Gambar 4. *Optimized VGG16*

Dalam penelitian ini, proses klasifikasi citra daun jagung dilakukan dengan memanfaatkan arsitektur VGG16 yang dikombinasikan dengan pendekatan *transfer learning* seperti yang ditunjukkan pada Gambar 4. Proses *transfer learning* dilakukan dengan membekukan (*freeze*) sebagian besar lapisan awal dari VGG16, yang berfungsi sebagai ekstraktor fitur umum, dan hanya melatih ulang (*fine-tuning*) beberapa lapisan akhir yang lebih spesifik terhadap dataset baru. Khususnya untuk dataset berukuran kecil seperti yang umum digunakan dalam klasifikasi penyakit tanaman, metode *transfer learning* dengan VGG16 memberikan keuntungan signifikan dalam meningkatkan akurasi sekaligus mengurangi risiko *overfitting* [30]. Hal ini menjadikan VGG16 sangat cocok diterapkan pada skenario klasifikasi penyakit daun jagung yang melibatkan beberapa kelas penyakit dan jumlah data yang terbatas.

## 2.5 MobileNetV2

Sebagai model pembanding dalam penelitian ini, digunakan pula arsitektur MobileNetV2 yang dikenal sebagai salah satu CNN ringan dengan efisiensi komputasi tinggi. Arsitektur ini pertama kali diperkenalkan oleh Sandler et al., pada tahun 2018 sebagai pengembangan dari MobileNetV1. MobileNetV2 membawa sejumlah inovasi teknis yang secara signifikan meningkatkan kecepatan dan akurasi dalam tugas klasifikasi citra [31].

Dalam konteks penelitian ini, MobileNetV2 digunakan sebagai model yang dibandingkan dengan arsitektur lain seperti VGG16 dalam tugas klasifikasi penyakit daun jagung. Struktur dari model ini ditampilkan pada Gambar 5.



Gambar 5. Arsitektur MobileNetV2

Gambar 5 menunjukkan desain CNN yang ringan dan telah dioptimalkan secara khusus untuk efisiensi dalam pengolahan citra. Karakteristik MobileNetV2 menjadikannya pilihan yang relevan terutama untuk aplikasi berbasis perangkat Mobile tanpa mengorbankan performa klasifikasi secara signifikan.

## 2.6 Evaluasi Model

Setiap model dievaluasi menggunakan metrik kinerja termasuk akurasi, *presisi*, *recall*, dan *F1-Score*. Hasil evaluasi ini digunakan untuk menentukan model mana yang paling baik dalam mengklasifikasikan *citra* daun jagung. Rumus yang digunakan untuk menghitung setiap metrik adalah sebagai berikut,

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \quad (1)$$

$$Precision = TP / (TP + FP) \times 100 \quad (2)$$

$$Recall = TP / (TP + FN) \quad (3)$$

$$F1-Score = 2 \times (Precision \times Recall) / (Precision + Recall) \quad (4)$$

Dimana TP = *True Positive*, TN = *True Negative*, FP = *False Positive*, and FN = *False Negative*

## 2.7 Perbandingan Model

Hasil dari evaluasi dibandingkan antara VGG16 *Baseline*, *MobileNetV2*, dan *Optimized VGG16* untuk menentukan model yang berkinerja terbaik. Outputnya adalah perbandingan berperingkat yang menunjukkan keunggulan *Optimized VGG16*. Penelitian ini menyimpulkan, menunjukkan bahwa *Optimized VGG16* mencapai kinerja klasifikasi tertinggi, mendukung tujuan awal deteksi penyakit yang akurat dan efisien.

## 3. HASIL DAN PEMBAHASAN

Studi ini berhasil mengembangkan model klasifikasi penyakit daun jagung berbasis arsitektur VGG16, yang telah dioptimasi melalui pendekatan pembelajaran transfer untuk mengidentifikasi empat kondisi berbeda pada *citra* digital

daun jagung. Setelah proses pelatihan dan evaluasi, model yang dioptimasi menunjukkan kinerja yang baik dalam membedakan daun yang sehat dari yang terinfeksi penyakit, yang divisualisasikan melalui kurva akurasi dan *loss* selama pelatihan, confusion matrix, serta metrik evaluasi seperti *precision*, *recall*, dan *F1-score*. Hasil evaluasi menunjukkan bahwa VGG16 teroptimasi memiliki kinerja terbaik pada semua metrik pengujian, mengalahkan kedua model pembandingan dalam hal akurasi dan ketahanan klasifikasi. Hasil menunjukkan bahwa optimasi VGG16 melalui *transfer learning* dapat meningkatkan kemampuan model untuk mendeteksi penyakit daun jagung secara signifikan. Ini juga menawarkan solusi yang dapat diandalkan untuk membantu penerapan pertanian dalam diagnosis penyakit tanaman secara akurat dan dini.

Dataset *citra* daun jagung dibagi menjadi dua bagian utama, yaitu data pelatihan dan pengujian, untuk keperluan pelatihan dan evaluasi model. Dengan rasio 80:20, pembagian *citra* dilakukan. 80 persen dari *citra* digunakan untuk melatih model untuk memahami pola visual dari masing-masing kelas, dan 20 persen sisanya digunakan untuk menguji kemampuan model untuk menggeneralisasikannya ke data yang belum pernah dilihat sebelumnya. Tujuan dari bagian ini adalah untuk mencegah *overfitting* dan menjaga keseimbangan antara proses pembelajaran dan evaluasi. Tabel 2 menunjukkan rincian jumlah *citra* untuk masing-masing kategori dalam data pelatihan dan pengujian.

**Tabel 2.** Distribusi Pembagian Dataset

| No    | Jenis Penyakit<br>Daun Jagung | Jumlah Data<br>Traning | Jumlah Data<br>Testing | Jumlah<br>Citra |
|-------|-------------------------------|------------------------|------------------------|-----------------|
| 1     | Healthy                       | 240                    | 60                     | 300             |
| 2     | Blight                        | 240                    | 60                     | 300             |
| 3     | Common Rust                   | 240                    | 60                     | 300             |
| 4     | Gray leaf Spot                | 240                    | 60                     | 300             |
| Total |                               | 960                    | 240                    | 1,200           |


Tabel 2 menerangkan masing-masing kelas memiliki 300 *citra*, masing-masing 240 untuk pelatihan dan 60 untuk pengujian, sehingga dataset terdiri dari 1.200 *citra* yang dibagi dengan rasio 80:20. Distribusi yang merata menunjukkan bahwa pembagian dataset telah dilakukan secara proporsional dan seimbang antara data latihan dan uji. Ini menunjukkan bahwa proses pelatihan model dan evaluasi yang representatif telah dilakukan.

### 3.1 Evaluasi Model

Pada penelitian ini dilakukan implementasi dan pelatihan tiga arsitektur model CNN, yaitu *Optimized VGG16*, VGG16 standar (*baseline*), dan MobileNetV2 sebagai model pembandingan. Seluruh implementasi dilakukan menggunakan bahasa pemrograman Python dengan *framework* TensorFlow dan Keras, serta dijalankan pada lingkungan Visual Studio Code dengan CPU terintegrasi. Setelah tahap *preprocessing* dan augmentasi data selesai dilakukan, pelatihan model dimulai dengan menggunakan arsitektur VGG16 yang telah dimodifikasi melalui pendekatan *transfer learning*. Model ini dikompilasi menggunakan fungsi *loss categorical\_crossentropy* untuk tugas klasifikasi multi-kelas, dengan proses *tuning hyperparameter* untuk menemukan konfigurasi terbaik. Eksperimen dilakukan menggunakan GridSearchCV yang membungkus fungsi KerasClassifier, dengan variasi parameter *optimizer* (Adam dan RMSprop) serta *dropout rate* (0.3 dan 0.5).

Berdasarkan hasil evaluasi, kombinasi parameter terbaik diperoleh pada *optimizer* RMSprop dengan *dropout rate* 0.5, yang menghasilkan akurasi validasi sebesar 92,92%. Pelatihan model dilanjutkan dengan menggunakan learning rate sebesar 0,0001, selama 20 epoch, dan batch size 32. Dataset dibagi menjadi 80% untuk pelatihan dan 20% untuk validasi. Pada proses *transfer learning*, sebagian besar lapisan awal dari VGG16 dibekukan (*freeze*) karena berfungsi sebagai ekstraktor fitur umum, sementara beberapa lapisan akhir dilatih ulang (*fine-tuning*) agar dapat menyesuaikan dengan dataset citra daun jagung. Selain itu, lapisan *fully connected* bagian atas diubah dengan menambahkan Dense(128, *activation*='relu'), diikuti *dropout* 0.5 untuk mengurangi *overfitting*, dan diakhiri dengan Dense(4, *activation*='softmax') untuk klasifikasi empat kelas penyakit.

Untuk meningkatkan generalisasi model dan mencegah *overfitting*, penerapan *early stopping* untuk menghentikan pelatihan secara otomatis saat performa validasi tidak meningkat, serta model *checkpoint* untuk menyimpan bobot model terbaik selama proses pelatihan. Hasil performa pelatihan dan validasi divisualisasikan dalam bentuk kurva akurasi dan *loss* yang ditampilkan pada Gambar 6.



**Gambar 6.** Perbandingan Validasi Accuracy and Loss dari *Optimized VGG16*, *Baseline*, & *MobileNetV2*

Gambar 6 menyajikan analisis kinerja komparatif dari tiga model pembelajaran mendalam yang digunakan untuk klasifikasi penyakit daun jagung. Model *Optimized VGG16* memberikan kinerja terbaik di semua metrik, menunjukkan akurasi tinggi, konvergensi cepat, dan nilai kerugian yang secara konsisten rendah. Sebaliknya, *MobileNetV2*, meskipun ringan dan efisien secara komputasi, mengorbankan akurasi dan efektivitas pembelajaran. *Baseline VGG16* menawarkan kinerja yang cukup baik tetapi tidak mendapatkan manfaat dari penyempurnaan dan peningkatan transfer pembelajaran seperti yang terlihat pada versi yang dioptimalkan. Hasil pengujian model dapat dilihat pada Tabel 3.

**Table 3.** Hasil Pengujian Model

| Model       | Accuracy | Precision | Recall | F1 – Score |
|-------------|----------|-----------|--------|------------|
| Proposed    | 96,25    | 96,25     | 96,25  | 96,24      |
| Baseline    | 92,92    | 93,07     | 92,92  | 92,91      |
| MobileNetV2 | 84,58    | 84,66     | 84,58  | 84,35      |

Tabel 3 menyajikan kinerja klasifikasi dari tiga model yang berbeda, *Optimized VGG16*, *VGG16 Baseline*, dan *MobileNetV2*. Model yang diusulkan (*Optimized VGG16*) mencapai kinerja keseluruhan tertinggi, dengan akurasi 96,25%, dan nilai yang konsisten kuat di semua metrik: presisi 96,25%, *recall* 96,25%, dan *F1-Score* sebesar 96,24%. Ini menunjukkan kemampuan luar biasa model untuk mengklasifikasikan dengan benar keempat kelas kondisi daun jagung dengan keandalan dan keseimbangan yang tinggi.


Model *VGG16 Baseline*, yang menggunakan arsitektur yang sama tanpa optimasi atau penyempurnaan, mencatat kinerja yang sedikit lebih rendah, dengan akurasi 92,92% dan *F1-Score* sebesar 92,91%. Meskipun masih efektif, model ini kurang memiliki perbaikan yang terlihat pada versi yang diusulkan, yang mengonfirmasi manfaat dari *transfer learning* dan peningkatan model. *MobileNetV2*, meskipun dirancang untuk efisiensi komputasi, mencetak skor terendah di semua metrik. Model ini mencapai akurasi 84,58%, dengan *F1-Score* sebesar 84,35%, menunjukkan adanya *trade-off* antara kekompakan model dan kinerja klasifikasi. Meskipun lebih cepat dan lebih ringan, model ini kurang akurat untuk tugas klasifikasi dan deteksi penyakit pada daun jagung.

Hasil evaluasi menunjukkan bahwa model *VGG16* yang telah dioptimasi berhasil mencapai performa terbaik pada seluruh metrik yang diuji, mengungguli model *Baseline* maupun *MobileNetV2* dalam hal akurasi dan ketahanan klasifikasi. Temuan ini menegaskan bahwa optimasi *VGG16* melalui *transfer learning* mampu meningkatkan kemampuan model secara signifikan dalam mendeteksi penyakit daun jagung secara otomatis. Dengan demikian, pendekatan ini menawarkan solusi yang andal dan efisien untuk mendukung penerapan pertanian presisi (*precision agriculture*) dalam mendeteksi penyakit secara dini dan akurat.

### 3.2 Perbandingan Model

Hasil dari evaluasi dibandingkan antara *VGG16 Baseline*, *MobileNetV2*, dan *Optimized VGG16* untuk menentukan model yang berkinerja terbaik. Analisis ini bertujuan untuk mengukur peningkatan performa yang dihasilkan oleh metode yang diusulkan, sekaligus mengidentifikasi keunggulan dan kelemahan masing-masing pendekatan dalam mengklasifikasikan citra pada empat kategori: *Blight*, *CommonRust*, *GrayLeafSpot*, dan *Healthy*.

Evaluasi klasifikasi gambar dianalisis menggunakan *Confusion Matrix*, yang digunakan untuk mengukur keberhasilan model dalam mengklasifikasikan gambar. Analisis ini memberikan wawasan tentang kinerja model dalam mengidentifikasi setiap kelas dan menunjukkan jumlah prediksi yang benar dan kesalahan yang terjadi di setiap kategori seperti pada Gambar 7.



**Gambar 7.** Confusion Matrix dari Model *MobileNetV2*, *VGG16 Baseline*, dan *Optimized VGG16*,

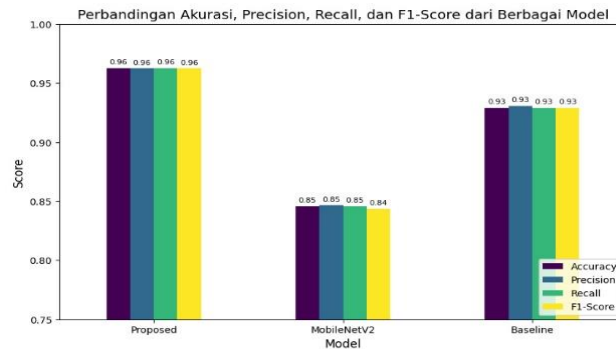
Gambar 7 menggambarkan Confusion Matrix dari *MobileNetV2*, *Baseline*, dan *Optimized VGG16* dalam mengklasifikasikan penyakit daun jagung. *MobileNetV2* mencapai klasifikasi sempurna untuk kelas *Common Rust*. Namun, kesalahan klasifikasi terlihat jelas pada kelas *Blight* dan *Gray Leaf Spot*, di mana beberapa citra diberi label yang salah, terutama dengan *Gray Leaf Spot* yang sering bingung dengan *Blight*. Meskipun ada kesalahan-kesalahan ini, kelas *Healthy* umumnya diklasifikasikan dengan akurasi tinggi. Hasil ini menunjukkan bahwa meskipun *MobileNetV2* berfungsi dengan baik untuk kelas-kelas tertentu, ia kesulitan dalam pemisahan kelas di mana gejala visual lebih halus atau tumpang tindih. Secara keseluruhan, perbedaan performa ini divisualisasikan melalui *Classification Report* yang disajikan pada Gambar 8, yang menunjukkan disparitas nilai *precision*, *recall*, dan *f1-score* di antara kelas-kelas target.



| Classification Report MobilenetV2: |           |        |          |         | Classification Report Baseline: |           |        |          |         | Classification Report Proposed Method: |           |        |          |         |
|------------------------------------|-----------|--------|----------|---------|---------------------------------|-----------|--------|----------|---------|--|-----------|--------|----------|---------|
|                                    | precision | recall | f1-score | support |                                 | precision | recall | f1-score | support |  | precision | recall | f1-score | support |
| Blight                             | 0.74      | 0.75   | 0.74     | 60      | Blight                          | 0.85      | 0.92   | 0.88     | 60      | Blight                                 | 0.92      | 0.93   | 0.93     | 60      |
| CommonRust                         | 0.86      | 1.00   | 0.92     | 60      | CommonRust                      | 0.97      | 1.00   | 0.98     | 60      | CommonRust                             | 0.98      | 1.00   | 0.99     | 60      |
| GrayLeafSpot                       | 0.84      | 0.72   | 0.77     | 60      | GrayLeafSpot                    | 0.91      | 0.83   | 0.87     | 60      | GrayLeafSpot                           | 0.95      | 0.92   | 0.93     | 60      |
| Healthy                            | 0.95      | 0.92   | 0.93     | 60      | Healthy                         | 1.00      | 0.97   | 0.98     | 60      | Healthy                                | 1.00      | 1.00   | 1.00     | 60      |
| accuracy                           |           |        | 0.85     | 240     | accuracy                        |           |        | 0.93     | 240     | accuracy                               |           |        | 0.96     | 240     |
| macro avg                          | 0.85      | 0.85   | 0.84     | 240     | macro avg                       | 0.93      | 0.93   | 0.93     | 240     | macro avg                              | 0.96      | 0.96   | 0.96     | 240     |
| weighted avg                       | 0.85      | 0.85   | 0.84     | 240     | weighted avg                    | 0.93      | 0.93   | 0.93     | 240     | weighted avg                           | 0.96      | 0.96   | 0.96     | 240     |

Gambar 8. Classification Report dari Model MobileNetV2, VGG16 Baseline, dan. Optimized VGG16,

Gambar 8 menyajikan perbandingan performa tiga model klasifikasi, yaitu MobileNetV2, model baseline, dan metode yang diusulkan, berdasarkan metrik precision, recall, dan f1-score pada empat kelas target (Blight, CommonRust, GrayLeafSpot, dan Healthy). MobileNetV2 menunjukkan akurasi keseluruhan sebesar 85%, dengan nilai precision dan recall yang bervariasi, di mana kelas Blight dan GrayLeafSpot memiliki performa lebih rendah dibandingkan kelas lainnya. Model baseline memberikan peningkatan signifikan dengan akurasi 93% dan performa relatif merata di seluruh kelas, meskipun GrayLeafSpot masih memiliki nilai recall yang sedikit lebih rendah. Metode yang diusulkan menghasilkan kinerja terbaik dengan akurasi 96% dan nilai precision, recall, serta f1-score yang konsisten tinggi di semua kelas, menunjukkan kemampuan model dalam meningkatkan akurasi sekaligus menjaga keseimbangan performa antar kelas. Hasil ini mengindikasikan bahwa metode yang diusulkan mampu mengatasi kelemahan pada MobileNetV2 dan melampaui performa model baseline secara menyeluruh. Adapun grafik perbandingannya dapat dilihat pada Gambar 9




Gambar 9. Grafik Perbandingan

Gambar 9 menyajikan perbandingan tiga model, perbandingan visual ini memperkuat efektivitas superior dari model *Optimized VGG16*. Variasi minimal di seluruh metrik pada semua model menunjukkan perilaku klasifikasi yang stabil, tetapi hanya metode yang diusulkan yang secara konsisten mencapai kinerja klasifikasi hampir sempurna. Hasilnya menunjukkan bahwa kombinasi *transfer learning*, *fine tuning*, dan teknik augmentasi memainkan peran kunci dalam memaksimalkan akurasi klasifikasi dalam deteksi penyakit daun jagung.

### 3.3 Hasil Prediksi Klasifikasi

Hasil klasifikasi dinilai dengan membandingkan arsitektur MobileNetV2, model baseline, dan strategi yang diusulkan. Penekanan khusus diberikan pada kemampuan masing-masing model untuk mengidentifikasi pola visual yang berbeda untuk setiap kelas. Gambar 10 menunjukkan hasil dari pengujian tersebut.



Gambar 10. Hasil Prediksi Klasifikasi.



Gambar 10 menggambarkan hasil prediksi visual dari model pada berbagai *citra* daun jagung, termasuk nilai probabilitas prediksi dan label aktual yang sesuai. Sebagian besar prediksi menunjukkan keselarasan yang kuat antara label yang diprediksi dan label aktual, dengan tingkat kepercayaan yang tinggi.

Metode yang diusulkan mencapai kinerja yang luar biasa, terutama pada kelas *Healthy*, yang diprediksi dengan akurasi rata-rata 100%. Namun, beberapa kesalahan klasifikasi teramati. Misalnya, sebuah *citra* yang diharapkan termasuk dalam kelas *Blight* atau *Gray Leaf Spot* diprediksi salah sebagai *Gray Leaf Spot* oleh model MobileNetV2, tetapi dengan probabilitas rendah. Sebagai perbandingan, Model *Baseline* mampu mengklasifikasikan *citra* dengan benar, meskipun dengan akurasi yang sedikit lebih rendah daripada metode yang diusulkan.

Kesalahan klasifikasi ini menunjukkan bahwa kategori penyakit tertentu, seperti *Blight* dan *Gray Leaf Spot*, memiliki karakteristik visual yang serupa terutama dalam tekstur dan warna yang menyebabkan kebingungan pada model. Secara keseluruhan, hasil prediksi menunjukkan bahwa meskipun model ini berfungsi dengan baik, masih ada ruang untuk perbaikan, terutama dalam membedakan antara gejala penyakit yang secara visual mirip.

#### 4. KESIMPULAN

Studi ini mengembangkan model klasifikasi penyakit daun jagung menggunakan arsitektur VGG16 yang dioptimalkan melalui *transfer learning*, dirancang untuk mendeteksi empat kondisi berbeda dari daun jagung dari gambar *digital*. Tiga model diperiksa, model VGG16 *baseline*, model MobileNetV2, dan *Optimized VGG16*. Berdasarkan hasil pengujian model yang disajikan, model *Proposed* (*Optimized VGG16*) menunjukkan performa terbaik dibandingkan dengan dua model pembanding lainnya, yaitu VGG16 *Baseline* dan MobileNetV2. Model *Proposed* berhasil mencapai akurasi sebesar 96,25%, dengan nilai *precision* dan *recall* yang juga tinggi, yakni masing-masing sebesar 96,25%, serta *F1-score* sebesar 96,24%. Sebagai perbandingan, model VGG16 *Baseline* mencatat akurasi sebesar 92,92%, *precision* sebesar 93,07%, *recall* 92,92%, dan *F1-score* 92,91%. Sementara itu, MobileNetV2 memiliki performa paling rendah dengan akurasi 84,58%, *precision* 84,66%, *recall* 84,58%, dan *F1-score* 84,35%. Hasil ini menegaskan bahwa optimasi VGG16 melalui *transfer learning* secara signifikan meningkatkan kemampuan klasifikasi, menjadikannya solusi yang lebih andal untuk mendeteksi penyakit daun jagung dibandingkan model standar dan arsitektur CNN ringan seperti MobileNetV2. Meskipun hasil yang menggembirakan ini, studi ini memiliki keterbatasan yang melekat. Pembatasan utama terletak pada tantangan model dalam membedakan penyakit dengan karakteristik visual yang halus dan tumpang tindih. Selain itu, dataset yang digunakan, meskipun luas, mungkin masih menunjukkan kekurangan dalam keragaman terkait kondisi pencahayaan, orientasi daun, dan kebisingan lingkungan, sehingga mempengaruhi generalisasi ke konteks dunia nyata. Selain itu, model-model tersebut belum dievaluasi dalam sistem waktu nyata atau sistem tertanam, yang sangat penting untuk penerapan di lapangan. Oleh karena itu, penelitian selanjutnya direkomendasikan untuk mengeksplorasi teknik augmentasi lanjutan, integrasi data multispektral, serta penerapan *attention mechanism* dan *ensemble learning* untuk meningkatkan kemampuan diskriminatif model. Implementasi pada platform real-time seperti *edge computing* juga perlu dilakukan untuk menguji kesiapan sistem dalam lingkungan pertanian nyata.

#### REFERENCES

- [1] I. P. Putra, R. Rusbandi, dan D. Alamsyah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network," *J. Algoritma*, vol. 2, no. 2, hal. 102–112, Apr 2022, doi: 10.35957/algoritme.v2i2.2360.
- [2] D. Iswanto dan D. Handayani UN, "Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN)," *J. Ilm. Univ. Batanghari Jambi*, vol. 22, no. 2, hal. 900, 2022, doi: 10.33087/jiubj.v22i2.2065.
- [3] P. Theerthagiri, A. U. Ruby, J. G. C. Chandran, T. H. Sardar, dan A. Shafeeq B. M, "Deep SqueezeNet learning model for diagnosis and prediction of maize leaf diseases," *J. Big Data*, vol. 11, no. 1, 2024, doi: 10.1186/s40537-024-00972-z.
- [4] C. Bi, S. Xu, N. Hu, S. Zhang, Z. Zhu, dan H. Yu, "Identification Method of Corn Leaf Disease Based on Improved Mobilenetv3 Model," *Agronomy*, vol. 13, no. 2, hal. 1–17, 2023, doi: 10.3390/agronomy13020300.
- [5] R. L. De Rossi *et al.*, "Crop damage, economic losses, and the economic damage threshold for northern corn leaf blight," *Crop Prot.*, vol. 154, hal. 105901, Apr 2022, doi: 10.1016/j.cropro.2021.105901.
- [6] M. A. H. Foysal, F. Ahmed, dan M. Z. Haque, "Multi-Class Plant Leaf Disease Detection: A CNN-based Approach with Mobile App Integration," 2024, doi: 10.5120/ijca2024924026.
- [7] M. Yusuf, D. Kurniawan, dan T. Agustin, "Klasifikasi Penyakit Tanaman Jagung dengan Kecerdasan Buatan Berbasis CNN," *Semin. Nas. AMIKOM SURAKARTA 2024*, no. November, hal. 355–368, 2024.
- [8] J. O. Olayiwola dan J. A. Adejoju, "Maize (Corn) Leaf Disease Detection System Using Convolutional Neural Network (CNN)," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, O. Gervasi, B. Murgante, D. Taniar, B. O. Apduhan, A. C. Braga, C. Garau, dan A. Stratigea, Ed., Cham: Springer Nature Switzerland, 2023, hal. 309–321. doi: 10.1007/978-3-031-36805-9\_21.
- [9] R. Singh, C. Prabha, M. Malik, dan A. Goyal, "A Robust Deep Learning Model for Brain Tumor Detection and Classification Using Efficient Net: A Brief Meta-Analysis," *J. Adv. Res. Appl. Sci. Eng. Technol.*, vol. 49, no. 2, hal. 26–51, Agu 2025, doi: 10.37934/araset.49.2.2651.
- [10] K. Adem, E. Kavalcı Yılmaz, F. Ölmez, K. Çelik, dan H. Bakır, "A Comparative Analysis of Deep Learning Parameters for Enhanced Detection of Yellow Rust in Wheat," *Uluslararası Muhendis. Arastirma ve Gelistirme Derg.*, vol. 16, no. 02, hal. 659–667, 2024, doi: 10.29137/umagd.1390763.
- [11] S. Solikhun, A. P. Windarto, dan P. Alkhairi, "Bone fracture classification using convolutional neural network architecture for high-accuracy image classification," *Int. J. Electr. Comput. Eng.*, vol. 14, no. 6, hal. 6466–6477, Des 2024, doi: 10.11591/ijece.v14i6.pp6466-6477.



- [12] N. W. Utami, I Nyoman Purnama, dan I Putu Restu Prajna, "Klasifikasi Tanaman Upakara Adat Hindu Di Kebun Raya Eka Karya Bali Menggunakan Algoritma Convolutional Neural Network," *J. Inform. Teknol. dan Sains*, vol. 5, no. 4, hal. 671–678, 2023, doi: 10.51401/jinteks.v5i4.3416.
- [13] M. Alkanan dan Y. Gulzar, "Enhanced corn seed disease classification: leveraging MobileNetV2 with feature augmentation and transfer learning," *Front. Appl. Math. Stat.*, vol. 9, hal. 1–12, 2023, doi: 10.3389/fams.2023.1320177.
- [14] M. N. Qureshi, M. S. Umar, dan S. Shahab, "A Transfer-Learning-Based Novel Convolution Neural Network for Melanoma Classification," *Computers*, vol. 11, no. 5, 2022, doi: 10.3390/computers11050064.
- [15] K. I. Nauval dan S. Lestari, "Implementasi Deteksi Objek Penyakit Daun Kentang dengan Metode Convolutional Neural Network," *J. Apl. Teknol. Inf. dan Manaj.*, vol. 3, no. 2, hal. 136–149, 2022, doi: 10.31102/jatim.v3i2.1576.
- [16] C. ÖZDEN, "Corn Disease Detection Using Transfer Learning," *Black Sea J. Eng. Sci.*, vol. 6, no. 4, hal. 387–393, 2023, doi: 10.34248/bsengineering.1322907.
- [17] S. Ahmed *et al.*, "Enhancing Brain Tumor Classification with Transfer Learning across Multiple Classes: An In-Depth Analysis," *BioMedInformatics*, vol. 3, no. 4, hal. 1124–1144, Des 2023, doi: 10.3390/biomedinformatics3040068.
- [18] I. Khan, S. S. Sohail, D. Ø. Madsen, dan B. K. Khare, "Deep transfer learning for fine-grained maize leaf disease classification," *J. Agric. Food Res.*, vol. 16, no. 4, hal. 1–9, 2024, doi: 10.1016/j.jafr.2024.101148.
- [19] 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, hal. 86–95, Jan 2024, doi: 10.55606/jutiti.v4i1.3425.
- [20] A. Rachmad, M. Fuad, dan E. M. S. Rochman, "Convolutional Neural Network-Based Classification Model of Corn Leaf Disease," *Math. Model. Eng. Probl.*, vol. 10, no. 2, hal. 530–536, 2023, doi: 10.18280/mmp.100220.
- [21] Q. N. Azizah, "Klasifikasi Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet," *sudo J. Tek. Inform.*, vol. 2, no. 1, hal. 28–33, 2023, doi: 10.56211/sudo.v2i1.227.
- [22] A. A. Kadam, H. Ganatra, A. R. Sawant, dan Y. Sivramkrishnan, "Corn Leaves Disease Detection Using Convolutional Neural Networks [CNN]," *Interantional J. Sci. Res. Eng. Manag.*, vol. 07, no. 10, hal. 1–11, 2023, doi: 10.55041/ijrsrem26275.
- [23] B. D. Mardiana, W. B. Utomo, U. N. Oktaviana, G. W. Wicaksono, dan A. E. Minarno, "Herbal Leaves Classification Based on Leaf Image Using CNN Architecture Model VGG16," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 7, no. 1, hal. 20–26, 2023, doi: 10.29207/resti.v7i1.4550.
- [24] M. O. Lawrence, "SqueezeNet Deep Learning Model for Magnetic Resonance Imaging Brain Tumor Detection," *Fac. Nat. Appl. Sci. J. ...*, vol. 6, no. 1, hal. 72–83, 2024, [Daring]. Tersedia pada: <https://fnasjournals.com/index.php/FNAS-JSI/article/view/559>
- [25] Y. Gulzar, "Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique," *Sustain.*, vol. 15, no. 3, hal. 2–14, 2023, doi: 10.3390/su15031906.
- [26] N. F. Hikmah, A. D. Hajjanto, A. F. A. Surbakti, N. A. Prakosa, T. Asmaria, dan T. A. Sardjono, "Brain tumor detection using a MobileNetV2-SSD model with modified feature pyramid network levels," *Int. J. Electr. Comput. Eng.*, vol. 14, no. 4, hal. 3995–4004, Agu 2024, doi: 10.11591/ijece.v14i4.pp3995-4004.
- [27] J. Kusuma, Rubianto, R. Rosnelly, Hartono, dan B. H. Hayadi, "Klasifikasi Penyakit Daun Pada Tanaman Jagung Menggunakan Algoritma Support Vector Machine, K-Nearest Neighbors dan Multilayer Perceptron," *J. Appl. Comput. Sci. Technol.*, vol. 4, no. 1, hal. 1–6, 2023, doi: 10.52158/jacost.v4i1.484.
- [28] A. Sharma, A. Zehra, A. Das, K. Rastogi, dan ..., "Brain Tumor Classification: A Comparison Study CNN, VGG 16 and ResNet50 Model," ... *Conf. Data ...*, 2023, [Daring]. Tersedia pada: <https://ieeexplore.ieee.org/abstract/document/10245710/>
- [29] S. Sharma dan K. Guleria, "A Deep Learning based model for the Detection of Pneumonia from Chest X-Ray Images using VGG-16 and Neural Networks," 2022. doi: 10.1016/j.procs.2023.01.018.
- [30] A. Achmadi, B. A. Umam, dan A. Anwari, "Identifikasi Penyakit Daun Tembakau Berbasis Pengolahan Citra dengan Metode Convolutional Neural Network ( CNN ) Dan Metode Transfer Learning," 2024.
- [31] G. Batchuluun, S. H. Nam, dan K. R. Park, "Deep Learning-Based Plant-Image Classification Using a Small Training Dataset," *Mathematics*, vol. 10, no. 17, hal. 1–26, 2022, doi: 10.3390/math10173091.
- [32] S. Saecedi, S. Rezayi, H. Keshavarz, dan S. R. Niakan Kalhori, "MRI-based brain tumor detection using convolutional deep learning methods and chosen machine learning techniques," *BMC Med. Inform. Decis. Mak.*, vol. 23, no. 1, hal. 16, Jan 2023, doi: 10.1186/s12911-023-02114-6.