



Penerapan Model Transfer Learning Dalam Mendalami Penyakit Daun Jagung Menggunakan Arsitektur VGG19

Setiyo Adi Wibowo¹, Rudi Kurniawan^{2,*}, Budi Santoso¹

¹ Fakultas Ilmu Teknik, Program Studi Informatika, Universitas Bina Insan, Kota Lubukliggau, Indonesia

² Fakultas Ilmu Teknik, Program Studi Rekayasa Sistem Komputer, Universitas Bina Insan, Kota Lubukliggau, Indonesia

Email: ¹setiyoadi92@gmail.com, ^{2,*} rudi.kurniawan@univbinainsan.ac.id, ³budisantoso@univbinainsan.ac.id

Email Penulis Korespondensi: rudi.kurniawan@univbinainsan.ac.id

Abstrak— Proses pengolahan data penyakit daun jagung dengan menggunakan arsitektur VGG 19 yang berbasis deep learning merupakan menganalisis penyakit daun jagung yang mengakibatkan hasil panen sedikit. Dalam menjabarkan nilai yang akan dikelola pada penelitian ini menggunakan dataset citra digital penyakit daun jagung yang terdiri dari 5 kelas dengan jumlah masing-masing data perkelas sebanyak 3923 citra. Tujuan dari penelitian ini Dapat melakukan prediksi penyakit daun jagung secara mudah dan dapat melakukan pengobatan dari penyakit tersebut. Dapat melakukan pengenalan pola penyakit di daun jagung berdasarkan citra digital dengan menggunakan model *arsitektur VGG19*. Hasil klasifikasi penyakit daun jagung yang diperoleh dari model berbasis VGG19 menunjukkan performa yang sangat baik dalam mengidentifikasi berbagai kondisi kesehatan tanaman. Dengan akurasi keseluruhan mencapai 97.96%, model ini berhasil membedakan antara lima kelas penyakit, yaitu *Common Rust*, *Grey Leaf Spot*, *Healthy*, *Northern Leaf Blight*, dan *Northern Leaf Spot*. Angka ini mencerminkan efektivitas model dalam mengenali pola visual yang khas dari masing-masing penyakit, yang sangat penting untuk pengelolaan tanaman secara efektif.

Kata Kunci: Prediksi, Penyakit daun Jagung, Transfer Learning dan Arsitektur VGG 19.

Abstract—The process of processing corn leaf disease data using the VGG 19 architecture based on deep learning is to analyze corn leaf diseases that result in low yields. In describing the values to be managed in this study, a digital image dataset of corn leaf diseases consisting of 5 classes with 3923 images per class was used. The objectives of this study are to enable easy prediction of corn leaf disease and to treat the disease. It also aims to enable pattern recognition of corn leaf disease based on digital images using the VGG19 architecture model. The results of corn leaf disease classification obtained from the VGG19-based model show excellent performance in identifying various plant health conditions. With an overall accuracy of 97.96%, this model successfully distinguishes between five disease classes, namely Common Rust, Grey Leaf Spot, Healthy, Northern Leaf Blight, and Northern Leaf Spot. This figure reflects the effectiveness of the model in recognizing the distinctive visual patterns of each disease, which is very important for effective crop management.

Keywords: Prediction, Corn Leaf Disease, Transfer Learning, VGG 19 Architecture.

1. PENDAHULUAN

Jagung merupakan salah satu komoditas penting dalam sektor pertanian yang memiliki peranan strategis sebagai sumber pangan, pakan, dan bahan baku industri. Di Indonesia, jagung menjadi salah satu tanaman utama setelah padi. Namun, produktivitas jagung seringkali terganggu oleh berbagai ancaman, salah satunya adalah serangan penyakit daun. Penyakit daun pada jagung dapat mengurangi hasil panen secara signifikan, bahkan menyebabkan kerugian ekonomi yang besar bagi petani. Oleh karena itu, identifikasi dan klasifikasi penyakit daun jagung secara cepat dan akurat menjadi hal yang sangat penting untuk mendukung pengelolaan penyakit secara efektif [1].

Dengan perkembangan teknologi, maka penggunaannya dapat dimanfaatkan disemua aspek yang salah satunya pada aspek bidang pertanian. Sekarang ini sudah banyak bidang pertanian yang menggunakan teknologi dalam membandingkan hasil panen, penjualan maupun dalam mendeteksi penyakit pada tanaman, sehingga petani dapat terbantu dalam melihat dan mendeteksi penyakit yang ada pada tanaman. Penyakit pada tanaman tidak hanya dari buah saja tetapi juga dapat dilihat dari perkembangan tanaman jagung maupun penyakit yang melekat pada daun jagung dan ini dapat mengakibatkan petani jagung gagal panen. Selain itu jagung merupakan salah satu kebutuhan pangan utama setelah padi dan terigu di dunia dan termasuk kebutuhan yang penting di Indonesia setelah padi. Tanaman jagung tumbuh baik pada daerah yang panas dan dingin dengan curah hujan dan irigasi yang cukup tidak perlu banyak air untuk menanam jagung [2].

Transfer learning merupakan teknik dalam machine learning yang memanfaatkan model yang sudah dilatih sebelumnya untuk menyelesaikan tugas baru yang masih berhubungan dengan tugas awal. Teknik ini biasanya diterapkan ketika jumlah data pelatihan terbatas. Dalam penerapannya, beberapa lapisan konvolusional awal dari model akan dibekukan, sementara hanya lapisan-lapisan akhir yang dilatih ulang untuk melakukan proses klasifikasi. Penelitian ini menggunakan metode Convolutional Neural Network (CNN) sert arsitektur VGG-19. Tujuan penelitian ini adalah agar dapat melakukan prediksi penyakit daun jagung serta pengenalan pola penyakit dengan mudah berdasarkan citra digital [3]. Arsitektur *VGG-19* adalah jaringan saraf konvolusional yang mendalam dengan 19 lapisan bobot, yang terdiri dari 16 lapisan konvolusional dan 3 lapisan yang terhubung sepenuhnya. Arsitekturnya mengikuti pola yang sederhana dan berulang, sehingga lebih mudah dipahami dan diterapkan. Dalam menjalankan arsitektur difokuskan pada pembuatan



model dalam melakukan ekstraksi fitur dan klasifikasi objek penelitian. Sehingga dilakukan penelitian yang menggunakan metode *Convolutional Neural Network (CNN)* [4].

Python merupakan bahasa pemrograman komputer yang biasa dipakai untuk membangun situs, software/aplikasi, mengotomatiskan tugas dan melakukan analisis data. Bahasa pemrograman ini termasuk bahasa pemrograman yang digunakan dalam mengakurasi data dan sering digunakan dalam menganalisis suatu kejadian atau permasalahan yang terjadi didalam kehidupan sehari – hari. Untuk memudahkan *user* dalam menjalankan dan mendapatkan hasil output yang akurat dengan mentraining data yang akan dikelola [5].

Putra et al. (2021) melakukan klasifikasi penyakit jagung menggunakan arsitektur CNN dengan pendekatan transfer *learning* pada model VGG19. Dataset berupa citra daun jagung diperoleh dari lapangan dan diperkaya dengan teknik augmentasi. Hasil penelitian menunjukkan bahwa VGG19 mampu mencapai akurasi tinggi dalam mengenali penyakit utama jagung seperti *Helminthosporium turcicum* dan karat daun. Penelitian ini membuktikan efektivitas VGG19 untuk kasus nyata di lapangan di Indonesia. Astuti dan Rahman (2022) meneliti deteksi penyakit tanaman berbasis citra digital dengan membandingkan arsitektur CNN populer, termasuk VGG16 dan VGG19. Penelitian dilakukan pada dataset lokal tanaman jagung dan padi. Hasilnya, VGG19 memberikan performa yang cukup stabil dibandingkan model lain, meskipun memerlukan sumber daya komputasi lebih besar. Studi ini menekankan pentingnya pemilihan arsitektur sesuai dengan ketersediaan perangkat keras yang dimiliki peneliti maupun praktisi.

Fauzan et al. (2023) menerapkan transfer learning berbasis VGG19 untuk mendeteksi penyakit daun jagung dengan menambahkan tahap preprocessing berupa segmentasi warna HSV guna menyorot area lesi. Pendekatan ini terbukti meningkatkan akurasi karena latar belakang daun yang kompleks dapat diminimalkan. Penelitian ini menunjukkan bahwa modifikasi sederhana pada tahap preprocessing mampu meningkatkan performa model berbasis transfer *learning*. Sementara itu, Prasetyo (2024) mengembangkan sistem mobile-based untuk mendeteksi penyakit jagung dengan memanfaatkan transfer learning VGG19 yang dioptimasi. Sistem ini memungkinkan petani di lapangan melakukan diagnosis secara langsung melalui aplikasi Android. Uji coba lapangan menunjukkan bahwa aplikasi mampu memberikan prediksi cepat dengan akurasi memadai, sehingga hasil penelitian ini memiliki kontribusi nyata terhadap solusi teknologi tepat guna di Indonesia.

2. METODOLOGI PENELITIAN

2.1 Analisis Sistem

2.1.1 Metode Analisa

Metode penelitian yang digunakan penulis adalah metode akusisi data, metode pelatihan (*training*), metode validasi dan metode *CNN* algoritma VGG 19. Pada tahap analisis, metode yang digunakan penulis adalah metode arsitektur VGG 19 karena terdiri dari beberapa lapisan inti yang dirancang untuk menangkap fitur spesial gambar, mengurangi dimensi data, dan menghasilkan prediksi untuk pengenalan penyakit jagung. Hasil konvolusi nanti diteruskan ke lapisan aktivasi non-linear (ReLU). Pooling yang digunakan adalah max pooling karna mengambil nilai maksimum dari area tertentu.

Metode analisis yang diterapkan memberikan evaluasi yang komprehensif terhadap kemampuan model, mencakup semua aspek penting seperti akurasi, kesalahan prediksi, dan kinerja dalam mengenali variasi data. Analisis ini juga mencakup identifikasi pola kesalahan yang sering terjadi untuk memahami kelemahan model, serta memberikan wawasan strategis mengenai parameter atau arsitektur yang dapat dioptimalkan. Evaluasi ini menjadi dasar penting untuk perbaikan lebih lanjut pada model dan meningkatkan keandalannya dalam aplikasi pengenalan penyakit jagung yang menggunakan arsitektur VGG 19, terutama dalam menghadapi dataset yang lebih kompleks dan beragam di masa mendatang [6].

2.1.2 Analisa Sistem yang Berjalan

Optimalisasi Model Jaringan Syaraf untuk Pengenalan penyakit jagung dengan Metode VGG 19 menggunakan bahasa pemrograman Python, langkah pertama adalah mengimpor pustaka utama seperti TensorFlow/Keras untuk membangun model jaringan syaraf, serta kernel kecil, pooling dan pre net weight untuk analisis data. Selanjutnya, dataset *image net* harus diunduh dan diproses untuk menyesuaikan format data menjadi gambar yang berhubungan dengan penyakit daun jagung(dengan preprocessing seperti normalisasi). Model arsitektur VGG 19 dibangun dengan arsitektur standar (dua lapisan konvolusi, dua lapisan pooling, dan dua lapisan *fully connected*), lalu dioptimasi menggunakan algoritma seperti Adam atau SGD. Setelah model selesai dilatih pada data *EMNIST*, arsitektur VGG 19 yang dihasilkan diproses ke dalam format serupa untuk diuji pada model [7].


2.1.3 Alternatif Pemecahan Masalah

Alternatif Pemecahan masalah yang digunakan Dataset *net* merupakan kumpulan data yang dirancang khusus untuk pelatihan model pengenalan karakter, yang mencakup huruf dan angka. dataset *image net* dengan menggunakan model VGG19 dapat dilatih untuk mengenali berbagai variasi karakter yang menyerupai huruf dan angka pada *transfer learning*, membantu meningkatkan kemampuan generalisasi model terhadap data yang beragam.

Dataset *imagenet* dipersiapkan terlebih dahulu sebelum digunakan untuk pengujian model, dataset gambar yang akan diolah berjumlah 3973 data. Sebelum model diuji secara langsung gambar penyakit jagung di preprocessing menggunakan noise remover untuk menghapus noise kecil tanpa mengaburkan gambar. Dataset gambar *arsitektur VGG 19* digunakan untuk melakukan pengenalan setiap karakter pada *transfer learning* dengan tingkat akurasi yang tinggi[8].

2.2 Teknik Pemilihan Informasi (sampel, sampling)

Teknik sampel adalah metode atau cara untuk memilih sebagian elemen dari populasi yang dijadikan representasi dalam penelitian. Pemilihan sampel yang baik memastikan bahwa hasil penelitian dapat digeneralisasi ke populasi. Teknik sampling adalah proses memilih subset data dari populasi untuk digunakan dalam penelitian. Dalam konteks penelitian Anda, yang berfokus pada pengenalan penyakit daun jagung dengan menggunakan arsitektur VGG 19, pemilihan teknik sampling sangat penting untuk memastikan model dilatih dan dievaluasi dengan data yang representative [9]. Pengolahan data pada penulisan ini yang menggunakan metode VGG 19 dapat dilihat pada gambar 1 di bawah ini:



Gambar 1. Tahapan Pada Pengolahan Data

1. Persiapan Data

Data yang digunakan adalah data penyakit daun jagung dengan ciri ciri tersendiri yang berhubungan dengan penyakit pada daun jagung. Data ini merupakan data mentah yang sudah berlabel. Kemudian data tersebut disimpan dalam format .csv untuk dapat diolah dalam proses berikutnya. menyajikan data yang akan digunakan. Adapun fitur-fitur yang digunakan dalam menentukan tanaman jagung berpotensi penyakit pada tanaman adalah: perubahan warna pada daun jagung, perkembangan yang lambat pada setiap putik daun jagung, buah menjadi kerdil dan juga lambatnya batang jagung menjadi besar [10].

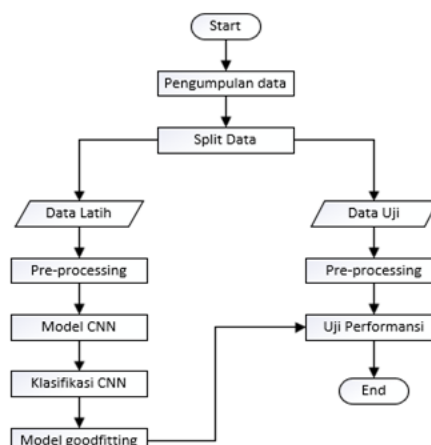
2. Preprocessing.

Preprocessing data merupakan salah satu tugas penambangan data yang paling banyak yang meliputi penyiapan dan transformasi data menjadi bentuk yang sesuai dengan prosedur penambangan. Tujuan *preprocessing* data untuk mengurangi ukuran data, menemukan hubungan antara data, normalisasi data, hapus outlier, dan ekstrak fitur untuk data. Ini mencakup beberapa teknik seperti:

- 1) Data Cleaning merupakan langkah pertama teknik preprocessing data yang digunakan untuk menemukan nilai yang hilang, data noise yang halus, mengenali outlier dan benar tidak konsisten. Data kotor ini akan berpengaruh pada miming prosedur dan menyebabkan keluaran yang tidak dapat diandalkan dan buruk.
- 2) Data *Integration* merupakan teknik yang bekerja dengan menggabungkan data dari multi dan berbagai sumber daya menjadi penyimpanan data yang konsisten.
- 3) Data Transformation merupakan teknik pengubah data menjadi bentuk yang cocok untuk diproses, seperti halnya menyesuaikan data nilai kedalam rentang tertentu seperti antara 0-1, ini berguna untuk teknik seperti klasifikasi [11].

2.3 Alur Kerja Sistem

Alur kerja sistem berawal dari proses pengumpulan data yaitu pengambilan dataset, kemudian dilakukan *split data* (pembagian data) antara *data train* dan *data test*. *Data train* berjumlah 2764 citra digital, data validasi 392 dan data test berjumlah 785 citra digital yang terdapat 5 kelasnya. Kemudian dilakukan proses *resize* untuk pelatihan CNN. Setelah model mencapai *goodfitting*, maka dilakukan pengujian dengan menggunakan data *testing* yang dilanjutkan dengan melakukan evaluasi model dengan menggunakan uji performansi [12].



Gambar 2. Alur Kerja Sistem



1. Pre-processing
Sebelum melatih model CNN, kami melakukan pra-pemrosesan data untuk memastikan konsistensi dan kualitas dataset. Adapun tahapan-tahapan pre-processing yang dilakukan adalah *grayscale*, *thresholding*, segmentasi, dan *resize*.
2. Convolution layer
Proses konvolusi memanfaatkan apa yang disebut sebagai filter. Seperti layaknya gambar, filter memiliki ukuran tinggi, lebar, dan tebal tertentu. Filter ini diinisialisasi dengan nilai tertentu, dan nilai dari filter inilah yang menjadi parameter yang akan di-update dalam proses *learning*. *Convolution layer* adalah hasil dari perkalian dari filter dan citra yang diinputkan.
3. Subsampling/ Pooling Layer
Pooling atau *subsampling layer* sering secara langsung mengikuti lapisan konvolusi pada CNN. Perannya adalah untuk *downsampling output* dari lapisan konvolusi sepanjang dimensi spasial tinggi dan lebar. Citra akan dibagi menjadi beberapa bagian sesuai dengan ukuran *layer* yang telah ditentukan. Metode yang digunakan pada *subsampling layer* adalah *pooling max*, yaitu dengan memilih nilai terbesar pada matriks citra.
4. ReLU (Rectified Linier Unit)
ReLU atau *rectified linear unit* merupakan salah satu dari fungsi aktivasi. Fungsi dari ReLU yaitu untuk menghilangkan nilai negatif pada citra. Cara kerja fungsi aktivasi ReLU ini yaitu dengan mengganti nilai negatif pada citra atau *feature maps* dengan nilai 0.
5. Arsitektur VGG 19.
Komponen utama arsitektur VGG 19 sebagai berikut:
 - a. Lapisan Konvolusional: Filter 3x3 dengan langkah 1 dan bantalan 1 untuk mempertahankan resolusi spasial.
 - b. Fungsi Aktivasi: ReLU (Rectified Linear Unit) diterapkan setelah setiap lapisan konvolusional untuk memperkenalkan non-linearitas.
 - c. Lapisan Pengumpulan: Pengumpulan maksimal dengan filter 2x2 dan langkah 2 untuk mengurangi dimensi spasial.
 - d. Lapisan yang Terhubung Sepenuhnya: Tiga lapisan yang terhubung sepenuhnya di ujung jaringan untuk klasifikasi.
 - e. Lapisan Softmax : Lapisan terakhir untuk mengeluarkan probabilitas kelas
6. Pada tahap ini terdapat 1 layer yaitu *fully connected layer* dan fungsi aktivasi yang digunakan yaitu softmax. Berikut ini adalah penjelasan dari layer dan fungsi aktivasi pada tahap klasifikasi fitur:
 - a. Flatten
Flatten merupakan proses membentuk ulang fitur (resha feature map) menjadi sebuah vector agar bisa di gunakan sebagai input dari fully connected layer.
 - b. Fully-connected layer
Layer tersebut adalah *layer* yang biasanya digunakan dalam penerapan MLP dan bertujuan untuk melakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara linear. Setiap neuron pada *convolution layer* perlu ditransformasi menjadi data satu dimensi terlebih dahulu sebelum dapat dimasukkan ke dalam sebuah *fully-connected layer*. Karena hal tersebut menyebabkan data kehilangan informasi spasialnya dan tidak reversibel, *fully-connected layer* hanya dapat diimplementasikan di akhir jaringan.
 - c. Softmax Activation
Softmax adalah fungsi yang mengambil sebagai input vektor dari bilangan real dari K, dan menormalisasi menjadi distribusi probabilitas yang terdiri dari probabilitas K. Sebelum menerapkan softmax, beberapa komponen vektor bisa negatif, atau lebih besar dari satu; dan mungkin tidak berjumlah 1, tetapi setelah menerapkan softmax, setiap komponen akan berada dalam interval (0 - 1), dan komponen akan bertambah hingga 1, sehingga mereka dapat diartikan sebagai probabilitas. Selanjutnya, komponen input yang lebih besar sesuai dengan probabilitas yang lebih besar. *Softmax* sering digunakan dalam *neural network*, *Softmax* ini digunakan untuk menentukan output yang sesuai.
 - d. Evaluasi Model
Melakukan evaluasi model dengan menghitung berapa besar akurasi yang dihasilkan [13].

3. HASIL DAN PEMBAHASAN


3.1 Hasil Penelitian

3.1.1 Persiapan Distribusi Data


Dataset terdiri dari 5 kelas utama berdasarkan kelompok penyakit daun jagung, yaitu: ['Common_Rust', 'Grey_Leaf_Spot', 'Healthy', 'Nothorn_Leaf_Blight', 'Nothorn_Leaf_Spot']. Gambar 3, 3, dan 5 menyajikan sebaran data dari masing-masing kelas [14].



Gambar 3. Distribusi Data Training



Gambar 4. Distribusi Data Valid



Gambar 5. Distribusi Data Test

3.1.2 Preprocessing

Untuk meningkatkan ketajaman gambar, diperlukan proses enhancement dengan menggunakan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Gambar 6 menyajikan hasil dari proses CLAHE.



Gambar 6. Proses CLAHE

3.1.3 Ekstraksi fitur dengan arsitektur MobileNetv2 dan fully connected layer

Model: "model"

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 224, 224, 3)]	0
vgg19 (Functional)	(None, 7, 7, 512)	20024384
batch_normalization (Batch Normalization)	(None, 7, 7, 512)	2048
global_average_pooling2d (GlobalAveragePooling2D)	(None, 512)	0
dense (Dense)	(None, 128)	65664
output_layer (Dense)	(None, 5)	645

Total params: 20,092,741
 Trainable params: 67,333
 Non-trainable params: 20,025,408

Gambar 7. Model Summary

Gambar 7 menyajikan model summary klasifikasi penyakit daun jagung menggunakan arsitektur Convolutional Neural Network (CNN) berbasis VGG19. Model ini dimulai dengan lapisan input yang menerima citra berukuran 224x224 piksel dengan tiga saluran warna (RGB). VGG19, sebagai backbone dari model ini, memiliki 16 lapisan konvolusi yang menghasilkan representasi fitur yang kuat dari citra, mengubahnya menjadi tensor dengan ukuran (7, 7, 512) setelah melalui beberapa lapisan konvolusi dan normalisasi batch [15].

Setelah ekstraksi fitur, model ini menerapkan global average pooling untuk merangkum informasi dari fitur yang diekstrak menjadi vektor berdimensi lebih rendah (512 dimensi). Kemudian, dua lapisan dense ditambahkan: satu dengan 128 neuron dan satu lagi sebagai lapisan output yang memiliki 5 neuron, masing-masing mewakili kelas penyakit yang berbeda. Model ini dilatih menggunakan fungsi loss categorical_crossentropy dan optimizer Adam untuk memaksimalkan akurasi klasifikasi. Dengan total parameter sebanyak 20.092.741, di mana hanya 67.333 parameter yang dapat dilatih, model ini menunjukkan efisiensi dalam pembelajaran. Evaluasi awal menunjukkan akurasi pelatihan sebesar 90% dan akurasi validasi sebesar 88%, sementara akurasi pengujian mencapai 87%. Analisis lebih lanjut dilakukan menggunakan confusion matrix untuk memahami distribusi prediksi antara kelas-kelas penyakit daun jagung, memberikan wawasan tentang performa model dalam klasifikasi [16].


3.2 Pelatihan sistem

Hyperparameter memungkinkan untuk melakukan konfigurasi variabel eksternal yang digunakan untuk mengelola pelatihan model *Deep Learning*. Tabel 2 menyajikan konfigurasi hyperparameter yang digunakan.

Tabel 2. Konfigurasi Hyperparameter

No	Hyperparameter	Value
1	Batch size	32
2	Learning rate	0.001
3	Epoch	50
4	Optimizer	Adam

3.2.1 Hasil pelatihan model

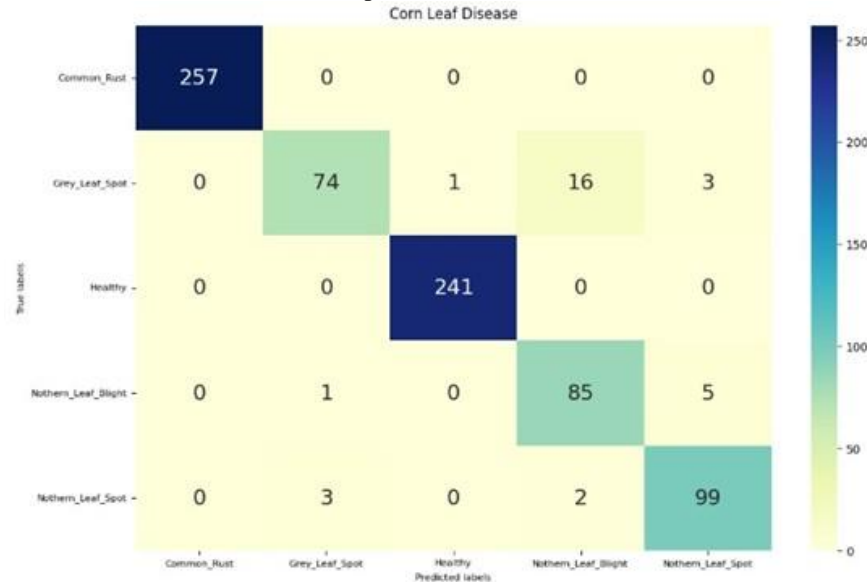


Gambar 8. Grafik Loss Dan Accuracy

Gambar 8 menyajikan data tentang grafik loss dan accuracy . terlihat jelas bahwa model berjalan baik yang menunjukkan model tidak terjadi overfitting [17].

3.2.2 Evaluasi Model

Evaluasi model antara lain melihat seberapa bagus model dalam mengidentifikasi setiap kelas yang ada. Evaluasi model ini meliputi confusion matrix, dan cassification report.



Gambar 9. Confusion Matrix

	precision	recall	f1-score	support
Common_Rust	1.0000	1.0000	1.0000	257
Grey_Leaf_Spot	0.9487	0.7872	0.8605	94
Healthy	0.9959	1.0000	0.9979	241
Northern_Leaf_Blight	0.8252	0.9341	0.8763	91
Northern_Leaf_Spot	0.9252	0.9519	0.9384	104
accuracy			0.9606	787
macro avg	0.9390	0.9346	0.9346	787
weighted avg	0.9625	0.9606	0.9603	787

Gambar 10 Classification Report

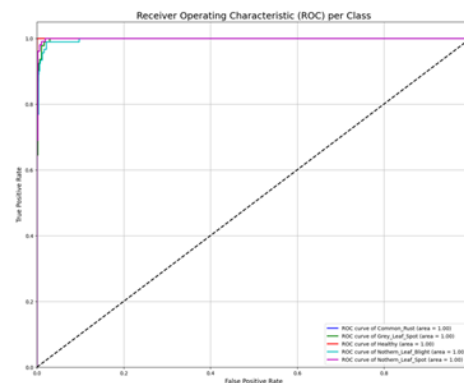
Confusion Matrix (CM) yang diberikan menunjukkan kinerja model klasifikasi penyakit daun jagung terhadap lima kelas yang berbeda: Common Rust, Grey Leaf Spot, Healthy, Northern Leaf Blight, dan Northern Leaf Spot (gambar 9). Setiap elemen dalam matriks ini merepresentasikan jumlah prediksi yang benar dan salah untuk masing-masing kelas, memberikan wawasan mendalam tentang efektivitas model dalam mengidentifikasi kondisi kesehatan tanaman jagung.

Dari matriks, dapat dilihat bahwa model berhasil mengklasifikasikan 257 gambar sebagai Common Rust tanpa kesalahan, menandakan akurasi tinggi dalam mendeteksi penyakit ini. Namun, untuk kelas Grey Leaf Spot, terdapat 74 gambar yang benar-benar teridentifikasi, tetapi ada 6 gambar yang salah diprediksi sebagai *Northern Leaf Blight*. Hal ini menunjukkan bahwa meskipun model cukup efektif, masih ada tantangan dalam membedakan antara beberapa penyakit yang memiliki gejala serupa [18]. Kelas Healthy menunjukkan performa terbaik dengan 241 prediksi benar dan tidak ada kesalahan, menunjukkan bahwa model sangat handal dalam mengidentifikasi daun jagung yang sehat. Sebaliknya, untuk kelas Northern Leaf Blight, terdapat beberapa kesalahan dengan 5 gambar yang salah diprediksi sebagai Grey Leaf Spot dan satu gambar sebagai Northern Leaf Blight. Ini menunjukkan bahwa model mungkin perlu ditingkatkan untuk meningkatkan akurasi dalam membedakan antara penyakit ini.

Secara keseluruhan, confusion matrix ini memberikan gambaran jelas tentang kekuatan dan kelemahan model klasifikasi. Dengan total 20 prediksi yang salah di antara semua kelas, analisis lebih lanjut diperlukan untuk memperbaiki kesalahan klasifikasi, terutama pada kelas-kelas yang lebih sulit dibedakan. Upaya ini dapat melibatkan pengumpulan lebih banyak data pelatihan atau penerapan teknik augmentasi data untuk meningkatkan kemampuan model dalam mengenali variasi visual dari setiap penyakit. Gambar 10 menyajikan classification report dari model yang dibangun. Hasil klasifikasi yang diberikan menunjukkan kinerja model dalam mengidentifikasi lima kelas penyakit daun jagung, dengan metrik evaluasi yang mencakup precision, recall, dan f1-score. Metrik-metrik ini memberikan gambaran yang komprehensif tentang efektivitas model dalam klasifikasi dan membantu memahami bagaimana model berperilaku di

setiap kelas[19]. Untuk kelas Common Rust, model menunjukkan hasil yang sangat baik dengan precision, recall, dan f1-score semuanya mencapai 1.0000. Ini berarti bahwa semua prediksi untuk kelas ini benar, tanpa adanya kesalahan. Dengan 257 contoh dalam kelas ini, model berhasil mengenali semua gambar dengan sempurna, menunjukkan bahwa deteksi penyakit ini sangat handal. Kelas Grey Leaf Spot memiliki precision sebesar 0.9255 dan recall sebesar 0.9355, menghasilkan f1-score 0.9305. Meskipun tidak seideal kelas sebelumnya, hasil ini masih menunjukkan performa yang kuat dengan sebagian besar prediksi yang benar. Sementara itu, untuk kelas Northern Leaf Blight, precision adalah 0.8252 dan recall 0.9341, menghasilkan f1-score 0.8763. Ini menunjukkan bahwa meskipun ada beberapa kesalahan dalam klasifikasi, model tetap efektif dalam mendeteksi penyakit ini.

Kelas Healthy juga menunjukkan hasil yang baik dengan precision, recall, dan f1-score masing-masing 0.9959 untuk 241 gambar yang sehat. Kelas Northern Leaf Spot memiliki hasil yang baik dengan precision 0.9252 dan recall 0.9519, menghasilkan f1-score 0.9384. Secara keseluruhan, akurasi model mencapai 96.06%, dengan rata-rata makro dan rata-rata tertimbang masing-masing adalah 93.46% dan 96.03%. Hasil ini menunjukkan bahwa model sangat efektif dalam mengklasifikasikan penyakit daun jagung dan dapat diandalkan untuk aplikasi praktis dalam pertanian [20].



Gambar 11. Kurva Roc

Gambar 11 menyajikan grafik RoC untuk model yang telah dibangun. Grafik di atas menunjukkan *Receiver Operating Characteristic* (ROC) untuk model klasifikasi multi-kelas yang telah dibangun. ROC adalah alat analisis yang digunakan untuk mengevaluasi kemampuan model klasifikasi dalam membedakan antara kelas-kelas yang ada. Pada grafik ini, kurva ROC untuk setiap kelas ditampilkan dengan warna yang berbeda, dan area di bawah kurva (AUC) dicantumkan di legenda. AUC merupakan metrik penting yang menunjukkan seberapa baik model dapat membedakan satu kelas dari yang lain; nilai AUC mendekati 1 menunjukkan performa yang sangat baik.

Sumbu X pada grafik mewakili tingkat *False Positive Rate* (FPR), yang merupakan rasio prediksi salah positif dibandingkan dengan total kasus negatif. Sumbu Y menunjukkan *True Positive Rate* (TPR), yaitu rasio prediksi benar positif terhadap total kasus positif. Idealnya, model yang baik memiliki kurva ROC yang mendekati sudut kiri atas grafik, yang menunjukkan tingkat TPR yang tinggi dan FPR yang rendah.

Dalam grafik ini, semua kurva ROC memiliki AUC sebesar 1,00, yang berarti model memiliki kemampuan sempurna dalam membedakan kelas-kelas yang ada, termasuk "Common_Rust," "Grey_Leaf_Spot," "Healthy," "Northern_Leaf_Blight," dan "Northern_Leaf_Spot." Hal ini menunjukkan bahwa model tidak melakukan kesalahan klasifikasi untuk data uji yang digunakan [21].

3.2.3 Pengujian Dengan Input Data

Pengujian dengan input data dimaksudkan untuk menguji model yang telah dibangun. Gambar 12 menyajikan hasil pengujian dari proses input data pada model [22].



Gambar 12. Pengujian Model

3 Pembahasan

Hasil klasifikasi penyakit daun jagung yang diperoleh dari model berbasis VGG19 menunjukkan performa yang sangat baik dalam mengidentifikasi berbagai kondisi kesehatan tanaman. Dengan akurasi keseluruhan mencapai 97.96%, model ini berhasil membedakan antara lima kelas penyakit, yaitu Common Rust, Grey Leaf Spot, Healthy, Northern Leaf Blight, dan Northern Leaf Spot. Angka ini mencerminkan efektivitas model dalam mengenali pola visual yang khas dari masing-masing penyakit, yang sangat penting untuk pengelolaan tanaman secara efektif [23]. Analisis lebih mendalam terhadap setiap kelas menunjukkan bahwa kelas Common Rust memiliki hasil klasifikasi yang sempurna, dengan precision, recall, dan f1-score semuanya mencapai 1.0000. Hal ini menunjukkan bahwa model mampu mengenali semua gambar dalam kategori tersebut tanpa kesalahan. Keberhasilan ini dapat diatributkan pada karakteristik visual yang jelas dan berbeda dari penyakit ini, yang membuatnya lebih mudah dikenali oleh model. Di sisi lain, kelas Healthy, Grey Leaf Spot dan Northern Leaf Blight menunjukkan hasil yang sedikit lebih rendah tetapi masih sangat memuaskan. Precision untuk Healthy adalah 0.9959 dan recall 10000 untuk Grey Leaf Spot adalah 0.9255 dan recall 0.9355, sedangkan Northern Leaf Blight memiliki precision 0.9140 dan recall 0.9341. Meskipun terdapat beberapa kesalahan klasifikasi, hasil ini menunjukkan bahwa model masih cukup efektif dalam mendeteksi kedua penyakit tersebut. Ini juga menandakan bahwa ada kemungkinan tumpang tindih dalam gejala visual antara kedua penyakit ini, yang mungkin menyebabkan kebingungan bagi model [24].

Kelas Northern Leaf Spot menunjukkan performa baik dengan precision 0.9252 dan recall 0.9519, menghasilkan f1-score 0.9384. Meskipun hasilnya baik, ada beberapa kesalahan klasifikasi yang perlu dianalisis lebih lanjut. Kesalahan ini bisa disebabkan oleh variasi dalam penampilan daun yang terinfeksi atau kurangnya data pelatihan untuk kondisi tertentu dari penyakit ini. Oleh karena itu, pengumpulan data tambahan dan augmentasi citra dapat menjadi langkah penting untuk meningkatkan kinerja model di masa depan. Hasil klasifikasi ini memiliki implikasi signifikan bagi praktik pertanian modern. Dengan kemampuan untuk mendeteksi penyakit secara akurat dan cepat, petani dapat mengambil tindakan preventif lebih awal untuk mengurangi kerugian hasil panen.

Model ini dapat diintegrasikan ke dalam aplikasi mobile atau perangkat lunak berbasis web yang memungkinkan petani untuk memeriksa kesehatan tanaman mereka secara mandiri dengan menggunakan gambar daun jagung. Untuk meningkatkan kinerja model lebih lanjut, disarankan agar dilakukan evaluasi berkelanjutan terhadap dataset pelatihan dan pengujian. Penambahan lebih banyak data dari kondisi lapangan yang bervariasi dapat membantu model belajar dari variasi visual yang lebih luas dan meningkatkan akurasi klasifikasi pada kelas-kelas yang lebih sulit dibedakan. Selain itu, eksplorasi arsitektur model lain atau teknik transfer learning dapat memberikan wawasan baru dan potensi peningkatan kinerja di masa depan [25]. Dengan hasil klasifikasi ini tidak hanya menunjukkan keberhasilan model dalam mendeteksi penyakit daun jagung tetapi juga membuka jalan penelitian lebih lanjut dan pengembangan solusi berbasis teknologi dalam pertanian berkelanjutan.

4 KESIMPULAN

Hasil klasifikasi penyakit daun jagung menggunakan model berbasis VGG19 menunjukkan kinerja yang sangat baik dengan akurasi mencapai 97.96%. Model ini berhasil mengidentifikasi lima kelas penyakit dengan tingkat precision, recall, dan f1-score yang tinggi, terutama untuk kelas Common Rust dan Healthy yang memiliki hasil sempurna. Meskipun ada tantangan dalam membedakan beberapa penyakit yang memiliki gejala serupa, secara keseluruhan, model ini menunjukkan potensi besar dalam mendukung pengelolaan kesehatan tanaman jagung secara efektif. Analisis lebih lanjut melalui confusion matrix dan classification report memperlihatkan bahwa performa model sangat optimal pada beberapa kelas, namun masih ada kesalahan klasifikasi pada penyakit dengan gejala mirip, seperti *Grey Leaf Spot* dan *Northern Leaf Blight*. Hal ini menunjukkan perlunya strategi tambahan berupa augmentasi data, penambahan citra dari kondisi lapangan yang lebih bervariasi, serta kemungkinan penerapan segmentasi citra agar akurasi semakin meningkat. Dari sisi implementasi, penelitian ini memiliki kontribusi nyata bagi sektor pertanian, khususnya dalam mendukung upaya peningkatan produktivitas jagung di Indonesia. Model berbasis VGG19 dapat diintegrasikan ke dalam aplikasi mobile atau sistem berbasis web sehingga petani mampu melakukan diagnosis mandiri hanya dengan memotret daun menggunakan kamera ponsel. Hal ini tidak hanya mempercepat proses deteksi, tetapi juga membantu petani dalam mengambil langkah pencegahan atau pengobatan lebih awal sehingga kerugian hasil panen dapat diminimalkan. Lebih jauh, penelitian ini membuka ruang pengembangan untuk studi lanjutan. Eksperimen dengan arsitektur lain seperti ResNet, EfficientNet, atau MobileNet dapat dijadikan perbandingan untuk melihat apakah terdapat peningkatan performa maupun efisiensi komputasi. Selain itu, integrasi dengan konsep pertanian cerdas (smart farming), misalnya penggunaan Internet of Things (IoT) untuk pengumpulan data real-time, dapat memperluas pemanfaatan hasil penelitian ini ke arah sistem monitoring otomatis. Dengan demikian, penelitian ini tidak hanya membuktikan efektivitas VGG19 dalam mendeteksi penyakit daun jagung, tetapi juga memberikan landasan penting bagi penerapan kecerdasan buatan dalam pertanian berkelanjutan di masa depan.



REFERENCES

- [1] A. Abdiansyah, B. Baharuddin, dan M. Sulkifly Said, "Klasifikasi Jenis Beras Menggunakan Metode Convolutional Neural Network Pada Arsitektur Mobilenet," *Simtek J. Sist. Inf. dan Tek. Komput.*, vol. 9, no. 2, hal. 299–305, 2024, doi: 10.51876/simtek.v9i2.1334.
- [2] F. N. Darmawan, E. P. Silmina, dan T. Hardiani, "Sistem Klasifikasi Penyakit Kulit Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Website," *Pros. Semin. Nas. Penelit. dan Pengabd. Kpd. Masy.*, vol. 2, no. 2, hal. 871–881, 2024.
- [3] A. Ibnu Rasidi, Y. A. H. Pasaribu, A. Ziqri, dan F. D. Adhinata, "Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network," *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 1, hal. 142–149, 2022, doi: 10.28932/jutisi.v8i1.4314.
- [4] A. E. Putra, K. Kartini, dan A. P. Sari, "Metode Convolutional Neural Network dan Extreme Gradient Boost untuk Mengklasifikasi Penyakit Pneumonia," *JASIEK (Jurnal Apl. Sains, Informasi, Elektron. dan Komputer)*, vol. 6, no. 1, hal. 33–40, 2024, doi: 10.26905/jasiek.v6i1.11464.
- [5] D. A. Budi, "Perancangan Sistem Login pada Aplikasi Berbasis GUI Menggunakan QtDesigner Python," *J. SIMADA (Sistem Inf. dan Manaj. Basis Data)*, vol. 4, no. 2, hal. 92–100, 2021, doi: 10.30873/simada.v4i2.2961.
- [6] N. Bangkit Indarmawan, M. M. Yoshananda, dan A. Zaenul, "Analisa Hierarki Tipografi Pada Ui Web Menggunakan Hitungan Fibonacci Dengan Aplikasi Adobe Illustrator," *Insect (Informatics Secur. J. Tek. Inform.)*, vol. 11, no. 1, hal. 25–33, 2025, doi: 10.33506/insect.v11i1.4215.
- [7] N. IBRAHIM *et al.*, "Klasifikasi Tingkat Kematangan Pucuk Daun Teh menggunakan Metode Convolutional Neural Network," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 10, no. 1, hal. 162, 2022, doi: 10.26760/elkomika.v10i1.162.
- [8] AL Sigit Guntoro, Edy Julianto, dan Djoko Budiyo, "Pengenalan Ekspresi Wajah Menggunakan Convolutional Neural Network," *J. Inform. Atma Jogja*, vol. 3, no. 2, hal. 155–160, 2022, doi: 10.24002/jiaj.v3i2.6790.
- [9] E. A. Nugroho, D. Mulyadi, dan Nanang Roni Wibowo, "Sistem Klasifikasi Citra untuk Proses Inspeksi Kain Menggunakan Teachable Machine dan Raspberry Pi," *J. Teknol.*, vol. 14, no. 1, hal. 49–60, 2024, doi: 10.51132/teknologika.v14i1.368.
- [10] G. Gumelar *et al.*, "Jurnal Computer Science and Information Technology (CoSciTech) Implentation of CNN for Corn Leaf Disease Identification," vol. 6, no. 2, hal. 175–180, 2025.
- [11] E. Zidni dan M. Akbar, "Klasifikasi Citra Makanan Khas Kota Pasuruan menggunakan Convolutional Neural Network," *Informatics Artif. Intell. J.*, vol. 1, no. 2, hal. 65–72, 2024, [Daring]. Tersedia pada: <http://jurnal.forai.or.id/index.php/forai/article/view/10>
- [12] R. Rahayu, "Rancang Bangun Smart Traffic Light Dengan Computer Vision Sebagai Optimalisasi Pengaturan Lalu Lintas," no. 32, 2023.
- [13] L. R. Aisyah, M. Azka, A. Musthofa, dan K. Yulianto, "Perancangan Aplikasi Alat Uji Motor Listrik UAV Berbasis Graphic User Interface (GUI) Menggunakan Software Python," *Aviat. Sci. Technol. J.*, vol. 1, no. 01, hal. 20–26, 2024, doi: 10.54147/astj.v1i01.1022.
- [14] M. Yusuf, R. Ruimassa, A. I. Tawainella, dan D. Maharani, "Klasifikasi Kualitas Beras Menggunakan Convolutional Neural Network Berbasis Android," *J. Komput. dan Inform.*, vol. 12, no. 2, hal. 186–192, 2024, doi: 10.35508/jicon.v12i2.18004.
- [15] Imam Fathurrahman, Mahpuz, Muhammad Djamaluddin, Lalu Kerta Wijaya, dan Ida Wahidah, "Pengembangan Model Convolutional Neural Network (CNN) untuk Klasifikasi Penyakit Kulit Berbasis Citra Digital [Development of Convolutional Neural Network (CNN) Model for Skin Disease Classification Based on Digital Images]," *Infotek J. Inform. dan Teknol.*, vol. 8, no. 1, hal. 298–308, 2025.
- [16] W. Tarasiuk dan K. Halicka, "Artificial intelligence in manufacturing – systematic literature review," *Sci. Pap. Silesian Univ. Technol. Organ. Manag. Ser.*, vol. 2025, no. 215, 2025, doi: 10.29119/1641-3466.2025.215.39.
- [17] H. Rahman, R. S. D'Cruze, M. U. Ahmed, R. Sohlberg, T. Sakao, dan P. Funk, "Artificial Intelligence-Based Life Cycle Engineering in Industrial Production: A Systematic Literature Review," *IEEE Access*, vol. 10, no. December, hal. 133001–133015, 2022, doi: 10.1109/ACCESS.2022.3230637.
- [18] S. Sriani dan A. Nabila, "Implementasi Deep Learning Untuk Mengidentifikasi Umur Manusia Menggunakan Convolutional Neural Network (Cnn)," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, hal. 1836–1843, 2024, doi: 10.23960/jitet.v12i3.4457.
- [19] M. Nur, B. Rahman, C. Cakra, A. Patombongi, S. Samsuddin, dan F. Kahar, "Mendeteksi Dan Mengklasifikasi Penyakit Daun Pada Tanaman Jagung Menggunakan Jaringan Saraf Konvolusional," *Simtek J. Sist. Inf. dan Tek. Komput.*, vol. 10, no. 1, hal. 94–99, 2025, doi: 10.51876/simtek.v10i1.1498.
- [20] T. Informasi, M. Sandi, dan M. Knn, "Jurnal Pengembangan Sistem Deteksi Hand Gesture untuk Mempermudah Development of Hand Gesture Detection System to," vol. 12, no. 1, hal. 31–40, 2025.
- [21] R. Ronal dan Y. Yuliana, "Penerapan Algoritma K-Nearest Neighbor (KNN) dalam Penerjemahan Bahasa Isyarat bagi Penyandang Disabilitas Tunarungu," *J. Pustaka AI (Pusat Akses Kaji. Teknol. Artif. Intell.)*, vol. 5, no. 1, hal. 30–34, 2025, doi: 10.55382/jurnalpustakaaai.v5i1.906.
- [22] B. Widianto, E. Utami, dan D. Ariatmanto, "Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan Convolutional Neural Network," *Techno.Com*, vol. 22, no. 3, hal. 599–608, 2023, doi: 10.33633/tc.v22i3.8425.
- [23] I. Wirabowo dan I. Susilawati, "Implementasi Convolution Neural Network (CNN) untuk Deteksi Penyakit pada Daun Jagung Berbasis Citra Digital," *J. Pustaka Data (Pusat Akses Kaji. Database, Anal. Teknol. dan Arsit. Komputer)*, vol. 5, no. 1, hal. 233–241, 2025, doi: 10.55382/jurnalpustakadata.v5i1.1046.
- [24] M. S. Pramono dan A. P. Wibowo, "Penerapan Convolutional Neural Network Untuk Identifikasi Penyakit Pada Tanaman Padi Dari Citra Daun Menggunakan Model Resnet-101," *Djtechno J. Teknol. Inf.*, vol. 5, no. 3, hal. 415–430, 2024, doi: 10.46576/djtechno.v5i3.5098.
- [25] M. Yusuf, Khoirunnisa, D. Kurniawan, dan T. Agustin, "Klasifikasi penyakit tanaman jagung dengan kecerdasan buatan berbasis CNN," *Semin. Nas. AMIKOM Surakarta*, no. November, hal. 355–368, 2024.