

**TESIS**  
**IDENTIFIKASI PENYAKIT TANAMAN JAGUNG BERDASARKAN**  
**CITRA DAUN MENGGUNAKAN COVOLUTIONAL NEURAL**  
**NETWORK**



disusun oleh  
**DWI SEPTIYANI ARWIN**  
**24.51.1560**  
**Konsentrasi : Business Intelligence**

**FAKULTAS ILMU KOMPUTER**  
**UNIVERSITAS AMIKOM YOGYAKARTA**  
**YOGYAKARTA**  
**2026**

**TESIS**  
**IDENTIFIKASI PENYAKIT TANAMAN JAGUNG**  
**BERDASARKAN CITRA DAUN MENGGUNAKAN**  
**COVOLUTIONAL NEURAL NETWORK**

**IDENTIFICATION OF CORN DISEASES BASED ON LEAF**  
**IMAGES USING COVOLUTIONAL NEURAL**  
**NETWORK**

Diajukan untuk memenuhi salah satu syarat mencapai derajat Pascasarjana  
Program Studi Infomatika



disusun oleh

**DWI SEPTIYANI ARWIN**

**24.51.1560**

**Konsentrasi : Business Intelligence**

**FAKULTAS ILMU KOMPUTER**  
**UNIVERSITAS AMIKOM YOGYAKARTA**  
**YOGYAKARTA**

**2026**

## HALAMAN PERSETUJUAN

HALAMAN PERSETUJUAN

IDENTIFIKASI PENYAKIT PAKANAN JAGUNG BERBASISAN CITRA  
DAUN MENGGUNAKAN CONVOLUTIONAL NEURAL  
NETWORK

IDENTIFICATION OF CORN DISEASE BASED ON LEAF  
IMAGES USING CONVOLUTIONAL NEURAL  
NETWORK

yang disusun dan diajukan oleh

Dwi Septian Arwa

24.51.1341

sebagai syarat untuk Disetujui dan Disetujui Tesis  
pada tanggal 02 Februari 2026

Dosen Pembimbing

  
Prof. Dr. Eng. Istikom, S.Si, M.Eng.  
johk.1903@2037

## HALAMAN PENGESAHAN

IDENTIFIKASI PENYAKIT TANAMAN JAGUNG BERDASARKAN CITRA  
DAUN MENGGUNAKAN CONVOLUTIONAL NEURAL  
NETWORK

IDENTIFICATION OF CORN DISEASES BASED ON LEAF  
IMAGES USING CONVOLUTIONAL NEURAL  
NETWORK

yang disusun dan diajukan oleh

Dwi Septiyani Arwin

24.01.1960

Telah dipertahankan di depan Dewan Penguji  
pada tanggal 02 Februari 2026

Susunan Dewan Penguji

Nama Penguji

Emha Taufiq Luthfi, S.T., M.Kom., Ph.D  
NIK. 190302125

Dr. Kumara Ari Yuana, S.T., M.T.  
NIK. 190302575

Prof. Dr. Fona Utami, S.Si., M.Kom  
NIK. 190302037

Tanda Tangan

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer  
Tanggal 02 Februari 2026

DEKAN FAKULTAS ILMU KOMPUTER



Prof. Dr. Kusrini, M.Kom.  
NIK. 190302106

## HALAMAN PERNYATAAN KEASLIAN TESIS

### HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertanda tangan di bawah ini,

Nama mahasiswa : Dwi Sepriyani A  
NIM : 24.01.1568

Menyatakan bahwa Tesis dengan judul berikut:

**IDENTIFIKASI PENYAKIT TANAMAN JAGUNG BERDASARKAN CITRA  
DAUN MENGGUNAKAN COEVOLUTIONAL NEURAL  
NETWORK**

Dibawah Pembimbing : Prof. Dr. Ema Utami, S.Si, M.Kom

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PUNAH dipublikasikan untuk mendapatkan gelar akademik, baik di Universitas AMKOM Yogyakarta maupun di Perguruan Tinggi lainnya.
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Dosen Pembimbing.
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas diuraikan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan diterbitkan dalam Daftar Pustaka pada karya tulis ini.
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMKOM Yogyakarta.
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan penarikan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi.

Yogyakarta, 02 Februari 2026

Yang Menyatakan,



Dwi Sepriyani A

## KATA PENGANTAR

Dengan memanjatkan puji syukur kepada kehadiran Allah SWT atas limpahan rahmat dan hidayah-Nya sehingga mampu menyelesaikan tesis yang berjudul “Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan Convolutional Neural Network”. Dalam penyusunan dan penulisan tesis ini, tidak terlepas dari bantuan dan bimbingan serta dukungan dari beberapa pihak. Oleh karena itu dalam kesempatan ini, penulis dengan senang hati menyampaikan terima kasih yang sebesar-besarnya kepada:

1. Keluarga saya yang senantiasa memberikan semangat, dukungan moral maupun materi serta doa, motivasi dan kesabaran kepada saya.
2. Prof. Dr. M. Suyanto, MM. selaku Rektor Universitas AMIKOM Yogyakarta.
3. Prof. Dr. Ema Utami, S.Si., M.Kom., selaku pembimbing saya yang selalu memberikan arahan, saran, motivasi serta bimbingan positif dalam menyelesaikan tesis ini sehingga dapat terselesaikan dengan baik.
4. Keluarga besar MTI AMIKOM Angkatan 32, yang telah menjadi teman-teman saya semasa kuliah pascasarjana serta kenangan yang tidak dapat saya rasakan dikesempatan lain.

## DAFTAR ISI

HALAMAN JUDUL .....	i
HALAMAN PERSETUJUAN.....	i
HALAMAN PENGESAHAN.....	<b>Kesalahan! Bookmark tidak ditentukan.</b>
HALAMAN PERNYATAAN KEASLIAN TESIS .....	iii
KATA PENGANTAR .....	iv
DAFTAR ISI.....	v
DAFTAR GAMBAR .....	viii
DAFTAR LAMBANG DAN SINGKATAN .....	x
DAFTAR ISTILAH .....	xi
INTISARI .....	xiii
ABSTRACT .....	xiv
<b>BAB I PENDAHULUAN</b> .....	1
1.1. Latar Belakang .....	1
1.2. Rumusan Masalah .....	5
1.3. Batasan Masalah .....	6
1.4. Tujuan Penelitian .....	7
1.5. Manfaat Penelitian .....	7
<b>BAB II TINJAUAN PUSTAKA</b> .....	9
2.1. Tjauan Pustaka .....	9
2.2. Keaslian Penelitian .....	13
2.3. Landasan Teori .....	18
2.3.1. Penyakit tanaman jagung .....	18
2.3.2. Citra Daun .....	19
2.3.3. Convolutional Neural Network .....	20
2.3.4. ResNet.....	21
2.3.5. Klasifikasi .....	22
2.3.6. Confusion Matrix .....	22
<b>BAB III METODE PENELITIAN</b> .....	25
3.1. Jenis, Sifat, dan Pendekatan Penelitian.....	25
3.2. Metode Pengumpulan Data.....	25
3.3. Metode Analisis Data.....	26
3.4. Alur Penelitian .....	27
<b>BAB IV HASIL PENELITIAN DAN PEMBAHASAN</b> .....	30
4.1. Pengumpulan Data .....	30
4.2. <i>Preprocessing</i> Data.....	32

4.3. Pemodelan Model Convolutional Neural Network (CNN) dengan ResNet-50 .....	34
4.4. Penerapan Modul CBAM (Convolutional Block Attention Module).....	36
4.5. Split Data .....	38
4.6. Skenario Penelitian .....	40
4.7. Analisis Hasil Klasifikasi.....	41
4.7.1 Analisis Hasil Adam ResNet-50 Tanpa CBAM dan CLAHE .....	43
4.7.2 Analisis Hasil (SGD) ResNet-50 Tanpa CBAM dan CLAHE.....	53
4.7.3 Analisis Hasil Optimaizer Adam ResNet-50 + CBAM .....	62
4.7.4 Analisis Hasil (SGD) ResNet-50 + CBAM.....	71
4.7.5 Analisis Hasil Optimaizer Adam ResNet-50 + CLAHE.....	79
4.7.6 Analisis Hasil (SGD) ResNet-50 + CLAHE.....	85
4.7.7 Analisis Hasil Optimaizer Adam ResNet-50 + CBAM + CLAHE.....	90
4.7.8 Analisis Hasil (SGD) ResNet-50 + CBAM +CLAHE.....	95
4.8. Perbandingan Hasil Pengujian.....	100
4.8.1 Perbandingan Hasil Pengujian Sebelum dan Sesudah CLAHE.....	103
4.8.2 Perbandingan Hasil Pengujian Sebelum dan Sesudah CBAM .....	104
4.8.3 Perbandingan Hasil Pengujian Optimizer Adam dan SGD .....	104
4.8.4 Perbandingan Hasil Pengujian Seluruh Skenario .....	105
4.9. Analisis Kombinasi Model Terbaik.....	106
BAB V .....	107
PENUTUP.....	107
5.1. Kesimpulan .....	107
5.2. Saran .....	108
DAFTAR PUSTAKA .....	109

## DAFTAR TABEL

Tabel 2. 1 Matriks literatur review dan posisi penelitian.....	13
Tabel 2. 2. Tabel 4. 0.1 <i>Confusion Matrix</i> .....	22
Tabel 4.1 Jumlah Data Citra Daun.....	32
Tabel 4. 2 Pembagian Data .....	39
Tabel 4. 3 Skenario Penelitian .....	41
Tabel 4. 4 Perbandingan Hasil Pengujian .....	100
Tabel 4. 5 Perbandingan Performa ResNet-50 sebelum dan Sesudah CLAHE...103	
Tabel 4. 6 Perbandingan Performa ResNet-50 sebelum dan Sesudah CBAM ....104	
Tabel 4. 7 Perbandingan Performa Optimizer Adam dan SGD.....105	
Tabel 4. 8 Peningkatan Performa dari Baseline ke Model Terbaik Secara .....	105
Tabel 4. 9 Perbandingan Metode .....	106

## DAFTAR GAMBAR

Gambar 2. 1 Citra Daun Terinfeksi.....	18
Gambar 2. 2 Arsitektur Pada CNN .....	21
Gambar 3. 1 Alur Penelitian .....	27
Gambar 4.1 Contoh Citra Daun Jagung Sebelum <i>Preprocessing</i> .....	33
Gambar 4. 2Contoh Citra Daun setelah CLAHE.....	34
Gambar 4.3 Plot Akurasi dan Loss Optimizer Adam + Learning Rate $1e-3$ .....	44
Gambar 4. 4 Plot Confusion Metrix Optimizer Adam + Learning Rate $1e-3$ .....	45
Gambar 4.5 Plot Akurasi dan Loss Optimizer Adam + Learning Rate $1e-4$ .....	49
Gambar 4.6 Plot Confusion Metrix Optimizer Adam + Learning Rate $1e-4$ .....	50
Gambar 4.7 Plot Akurasi dan Loss Optimizer SGD + Learning Rate $1e-2$ .....	53
Gambar 4.8 Plot Confusion Metrix Optimizer SGD + Learning Rate $1e-2$ .....	54
Gambar 4.9 Plot Akurasi dan Loss Optimizer SGD + Learning Rate $1e-3$ .....	58
Gambar 4.10 Plot Confusion Metrix Optimizer SGD + Learning Rate $1e-3$ .....	59
Gambar 4. 11 Plot Akurasi dan Loss Optimizer Adam + Learning Rate $1e-3$ ....	62
Gambar 4.12 Plot Confusion Metrix Optimizer Adam + Learning Rate $1e-3$ .....	64
Gambar 4. 13 Plot Akurasi dan Loss Optimizer Adam + Learning Rate $1e-4$ ....	67
Gambar 4.14 Plot Confusion Metrix Optimizer Adam + Learning Rate $1e-4$ .....	68
Gambar 4.15 Plot Akurasi dan Loss Optimizer SGD + Learning Rate $1e-3$ .....	71
Gambar 4.16. Plot Confusion Metrix Optimizer SDG + Learning Rate $1e-3$ .....	72
Gambar 4.17 Plot Akurasi dan Loss Optimizer SGD + Learning Rate $1e-2$ .....	75
Gambar 4.18 Plot Confusion Metrix Optimizer SGD + Learning Rate $1e-2$ .....	77

Gambar 4.19 Plot Akurasi dan Loss Optimizer Adam + Learning Ratae $1e-3$ .....	80
Gambar 4.20 Plot Confusion Metrix Optimizer Adam + Learning Rate $1e-3$ .....	81
Gambar 4.21 Plot Akurasi dan Loss Optimizer Adam + Learning Ratae $1e-4$ .....	83
Gambar 4.22 Plot Confusion Metrix Optimizer Adam + Learning Rate $1e-4$ .....	84
Gambar 4.23 Plot Akurasi dan Loss Optimizer SGD + Learning Ratae $1e-2$ .....	85
Gambar 4.24 Plot Confusion Metrix Optimizer SGD + Learning Rate $1e-2$ .....	86
Gambar 4.25 Plot Akurasi dan Loss Optimizer SGD + Learning Ratae $1e-3$ .....	88
Gambar 4.26 Plot Confusion Metrix Optimizer SGD + Learning Rate $1e-3$ .....	89
Gambar 4.27 Plot Akurasi dan Loss Optimizer Adam + Learning Ratae $1e-3$ .....	90
Gambar 4.28 Plot Confusion Metrix Optimizer Adam + Learning Rate $1e-3$ .....	91
Gambar 4.29 Plot Akurasi dan Loss Optimizer Adam + Learning Ratae $1e-4$ .....	93
Gambar 4.30 Plot Confusion Metrix Optimizer Adam + Learning Rate $1e-4$ .....	94
Gambar 4.31 Plot Akurasi dan Loss Optimizer SGD + Learning Ratae $1e-2$ .....	95
Gambar 4.32 Plot Confusion Metrix Optimizer SGD + Learning Rate $1e-2$ .....	96
Gambar 4.33 Plot Akurasi dan Loss Optimizer SGD + Learning Ratae $1e-3$ .....	98
Gambar 4.34 Plot Confusion Metrix Optimizer SGD + Learning Rate $1e-3$ .....	99

## DAFTAR LAMBANG DAN SINGKATAN

<b>CNN</b>	<i>Convolutional Neural Network</i> — Arsitektur jaringan saraf tiruan yang digunakan untuk mengenali pola visual pada citra digital.
<b>CBAM</b>	<i>Convolutional Block Attention Module</i> — Modul perhatian tambahan yang membantu model fokus pada area penting citra secara kanal dan spasial.
<b>CLAHE</b>	<i>Contrast Limited Adaptive Histogram Equalization</i> — Teknik peningkatan kontras adaptif yang digunakan pada tahap pra-pemrosesan citra.
<b>ReLU</b>	<i>Rectified Linear Unit</i> — Fungsi aktivasi yang digunakan untuk menambahkan non-linearitas pada jaringan saraf tiruan.
<b>SGD</b>	<i>Stochastic Gradient Descent</i> — Metode optimasi yang memperbarui bobot jaringan menggunakan sebagian kecil data ( <i>mini-batch</i> ).
<b>Adam</b>	<i>Adaptive Moment Estimation</i> — Algoritma optimasi yang menggabungkan keunggulan <i>Momentum</i> dan <i>RMSProp</i> untuk pembaruan bobot yang efisien.
<b>GAP</b>	<i>Global Average Pooling</i> — Lapisan pada CNN yang mereduksi dimensi fitur dengan menghitung rata-rata seluruh area peta fitur.
<b>TP</b>	<i>True Positive</i> — Jumlah data yang benar terklasifikasi ke dalam kelas positif.
<b>TN</b>	<i>True Negative</i> — Jumlah data yang benar terklasifikasi ke dalam kelas negatif.
<b>FP</b>	<i>False Positive</i> — Jumlah data yang salah diklasifikasikan sebagai kelas positif.
<b>FN</b>	<i>False Negative</i> — Jumlah data yang salah diklasifikasikan sebagai kelas negatif.
<b>LR</b>	<i>Learning Rate</i> — Parameter yang mengatur kecepatan pembaruan bobot selama proses pelatihan model.
<b>ACC</b>	<i>Accuracy</i> — Persentase prediksi model yang benar terhadap keseluruhan data uji.
<b>P</b>	<i>Precision</i> — Rasio antara <i>True Positive</i> dan jumlah total prediksi positif.
<b>R</b>	<i>Recall</i> — Rasio antara <i>True Positive</i> dan jumlah total data aktual positif.
<b>F1</b>	<i>F1-Score</i> — Nilai rata-rata harmonis antara <i>Precision</i> dan <i>Recall</i> .
<b>RGB</b>	<i>Red, Green, Blue</i> — Model warna yang digunakan untuk merepresentasikan citra digital.
<b>DSS</b>	<i>Decision Support System</i> — Sistem pendukung keputusan yang dapat diintegrasikan dengan hasil model klasifikasi untuk rekomendasi tindakan pertanian.
<b>DL</b>	<i>Deep Learning</i> — Bidang kecerdasan buatan yang menggunakan jaringan saraf berlapis-lapis untuk mengenali pola kompleks.

## DAFTAR ISTILAH

<b>Citra</b>	Representasi visual dari objek dalam bentuk gambar digital yang digunakan sebagai data masukan dalam pengolahan citra.
<b>CNN (Convolutional Neural Network)</b>	Arsitektur jaringan saraf tiruan yang dirancang untuk mengenali pola visual pada gambar dengan menggunakan lapisan konvolusi.
<b>ResNet-50</b>	Salah satu arsitektur CNN yang memiliki 50 lapisan dan menggunakan konsep <i>residual learning</i> untuk mengatasi penurunan akurasi pada jaringan yang sangat dalam.
<b>CBAM (Convolutional Block Attention Module)</b>	Modul tambahan pada CNN yang berfungsi untuk meningkatkan fokus model terhadap area penting pada citra melalui mekanisme <i>attention</i> pada aspek kanal dan spasial.
<b>CLAHE (Contrast Limited Adaptive Histogram Equalization)</b>	Teknik peningkatan kualitas citra yang bertujuan untuk memperbaiki kontras secara adaptif agar detail pada area gelap maupun terang lebih terlihat jelas.
<b>Optimizer</b>	Algoritma yang digunakan untuk memperbarui bobot dalam proses pelatihan jaringan saraf agar model mencapai nilai kesalahan minimum.
<b>Adam (Adaptive Moment Estimation)</b>	Jenis <i>optimizer</i> yang menggabungkan keunggulan dari metode <i>Momentum</i> dan <i>RMSProp</i> untuk mempercepat konvergensi pelatihan model.
<b>SGD (Stochastic Gradient Descent)</b>	Metode optimasi yang memperbarui bobot jaringan berdasarkan gradien dari sebagian kecil data ( <i>mini-batch</i> ) pada setiap iterasi pelatihan.
<b>Accuracy</b>	Ukuran performa model yang menunjukkan persentase jumlah prediksi benar terhadap total keseluruhan data uji.
<b>Precision</b>	Ukuran ketepatan prediksi model yang menunjukkan seberapa banyak hasil prediksi positif yang benar dari seluruh prediksi positif yang dihasilkan model.
<b>Recall</b>	Ukuran kemampuan model untuk menemukan semua data positif yang sebenarnya ada dalam dataset.

<b>F1-Score</b>	Nilai rata-rata harmonis antara <i>precision</i> dan <i>recall</i> yang memberikan ukuran keseimbangan performa model.
<b>Confusion Matrix</b>	Tabel yang menunjukkan perbandingan antara hasil prediksi model dengan label sebenarnya, digunakan untuk mengevaluasi kinerja klasifikasi.
<b>Dataset</b>	Kumpulan data, dalam penelitian ini berupa citra daun jagung, yang digunakan untuk pelatihan, validasi, dan pengujian model.
<b>Blight</b>	Jenis penyakit pada daun jagung yang ditandai dengan munculnya bercak cokelat atau kehitaman yang menyebar cepat.
<b>Common Rust</b>	Penyakit daun jagung yang disebabkan oleh jamur <i>Puccinia sorghi</i> , ditandai dengan bintik-bintik berwarna oranye hingga merah kecokelatan.
<b>Gray Leaf Spot</b>	Penyakit pada daun jagung yang disebabkan oleh jamur <i>Cercospora zea-maydis</i> , ditandai dengan bercak keabu-abuan memanjang.
<b>Healthy</b>	Kelas dalam dataset yang mewakili kondisi daun jagung sehat tanpa infeksi penyakit.
<b>Deep Learning</b>	Cabang dari <i>machine learning</i> yang menggunakan jaringan saraf dengan banyak lapisan untuk mengekstraksi fitur kompleks dari data.
<b>Epoch</b>	Satu siklus penuh dari seluruh data pelatihan yang digunakan dalam proses pembelajaran model <i>neural network</i> .

## INTISARI

Penelitian ini berjudul “*Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan Convolutional Neural Network (CNN)*” yang bertujuan untuk mengembangkan model klasifikasi otomatis dalam mendeteksi penyakit pada daun jagung guna membantu petani melakukan diagnosis dini secara cepat dan akurat. Data penelitian diperoleh dari dataset publik *Corn or Maize Leaf Disease Dataset* yang berjumlah 4.188 citra dan terbagi ke dalam empat kelas, yaitu *Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*. Proses pra-pemrosesan citra dilakukan menggunakan metode *Contrast Limited Adaptive Histogram Equalization (CLAHE)* untuk meningkatkan kontras dan memperjelas detail tekstur daun sebelum dilakukan pelatihan model. Arsitektur yang digunakan adalah *ResNet-50* dengan penambahan modul *Convolutional Block Attention Module (CBAM)* serta perbandingan beberapa *optimizer* seperti Adam dan SGD dengan variasi *learning rate* untuk memperoleh konfigurasi terbaik. Hasil penelitian menunjukkan bahwa kombinasi *ResNet-50 + CBAM* dengan *optimizer SGD* dan *learning rate* 0.01 menghasilkan kinerja terbaik dengan nilai akurasi sebesar 96,03%, *precision* 96,03%, dan *recall* 96,03%, yang menunjukkan keseimbangan performa dalam mengenali serta mengklasifikasikan penyakit pada daun jagung. Penggunaan metode CLAHE terbukti mampu meningkatkan kualitas citra dan membantu model dalam mengekstraksi fitur penting secara lebih efektif. Dengan demikian, pendekatan *ResNet-50 + CBAM* dan teknik pra-pemrosesan CLAHE dinilai efektif dalam mengidentifikasi penyakit daun jagung secara akurat serta berpotensi dikembangkan lebih lanjut untuk sistem deteksi penyakit tanaman berbasis citra digital.

**Kata kunci:** Convolutional Neural Network, ResNet-50, CBAM, CLAHE, Penyakit Daun Jagung

## ABSTRACT

*This study, entitled "Identification of Corn Leaf Diseases Based on Leaf Images Using Convolutional Neural Network (CNN)", aims to develop an automatic classification model to detect corn leaf diseases and assist farmers in conducting early and accurate diagnosis. The research data were obtained from the public dataset Corn or Maize Leaf Disease Dataset, consisting of 4,188 images categorized into four classes: Blight, Common Rust, Gray Leaf Spot, and Healthy. Image preprocessing was carried out using the Contrast Limited Adaptive Histogram Equalization (CLAHE) method to enhance contrast and highlight texture details before the training stage. The architecture employed was ResNet-50 integrated with the Convolutional Block Attention Module (CBAM), and several optimizers such as Adam and SGD with various learning rates were compared to determine the best configuration. The experimental results showed that the combination of ResNet-50 + CBAM using the Adam optimizer with a learning rate of 0.001 achieved the best performance, yielding an accuracy of 96.10%, a precision of 95.67%, and a recall of 95.87%, indicating balanced performance in recognizing and classifying corn leaf diseases. The use of CLAHE significantly improved image quality and helped the model extract essential features more effectively. Therefore, the ResNet-50 + CBAM approach combined with CLAHE preprocessing proved to be effective in accurately identifying corn leaf diseases and has potential for further development into a digital image-based plant disease detection system..*

**Keyword:** Convolutional Neural Network, ResNet-50, CBAM, CLAHE, Corn Leaf

## **B A B I**

### **PENDAHULUAN**

#### **1.1. Latar Belakang**

Jagung merupakan salah satu tanaman serealia dan bahan pangan yang penting karena mengandung sumber karbohidrat. Ini adalah tanaman pangan terbesar ketiga di dunia setelah beras dan gandum. Di Indonesia, jagung merupakan salah satu tanaman pangan terbesar kedua setelah padi. Tanaman ini memiliki daya hasil yang tinggi dan kegunaan yang luas. Tanaman ini memiliki peran strategis dalam perekonomian nasional dan memiliki fungsi multiguna, seperti pakan ternak. Dengan kata lain, jagung juga dapat digunakan sebagai bahan baku industri. Dengan kemajuan teknologi, berbagai sektor bisnis merasakan manfaatnya, termasuk industri pertanian [1]. Saat ini, penerapan teknologi dalam pertanian sudah menjadi hal yang lazim dan tak terelakkan. Oleh karena itu, pemanfaatan teknologi dalam pertanian diyakini mampu membawa dampak positif bagi para petani. Salah satu contohnya adalah penggunaan teknologi pengolahan citra digital, yang dapat mendeteksi penyakit pada tanaman sehingga membantu dalam upaya pencegahan penyebarannya[2].

Jagung adalah salah satu tanaman pangan utama di dunia, bersama dengan gandum dan padi. Di Indonesia, jagung menjadi sumber makanan pokok kedua setelah padi dan sering dikonsumsi sebagai sumber karbohidrat [3]. Menurut data dari Food and Agriculture Organization (FAO), produksi jagung menunjukkan tren peningkatan dari tahun 2010 hingga 2018, mencapai 30,25 juta ton pada 2018. Namun, pada

2019 produksi mengalami penurunan sebesar 25% menjadi 22,59 juta ton, dan kembali turun 0,38% pada 2020 menjadi 22,5 juta ton [4]. Salah satu faktor yang menghambat peningkatan produksi jagung adalah serangan organisme pengganggu tanaman. Salah satu kendala dalam meningkatkan produksi jagung adalah adanya berbagai hambatan, termasuk serangan organisme pengganggu tanaman [5]. Berbagai upaya terus dilakukan untuk mencegah dan mengatasi organisme pengganggu tanaman (OPT), termasuk hama dan penyakit pada jagung. Namun, faktor lingkungan seperti cuaca, suhu, dan kelembaban turut berperan dalam mempercepat perkembangan penyakit pada tanaman jagung.

Permasalahan tersebut menjadi tantangan bagi pengembang teknologi informasi untuk menciptakan sistem yang mampu mengatasinya. Diharapkan teknologi informasi dapat menghasilkan sistem yang dapat mengenali penyakit pada tanaman. Dalam teknik pengolahan citra, terdapat metode yang memungkinkan deteksi penyakit pada daun tanaman, sehingga dapat membedakan antara daun yang sehat dan yang terinfeksi. Salah satu metode yang digunakan untuk mengidentifikasi penyakit pada tanaman jagung adalah Convolutional Neural Network (CNN) [6].

Convolutional Neural Network (CNN) adalah salah satu algoritma dalam Deep Learning yang dirancang khusus untuk mengolah dan mengenali informasi dari gambar. CNN mampu menerima input berupa gambar dan secara otomatis mengidentifikasi aspek atau objek yang terdapat di dalamnya. Melalui proses pembelajaran, algoritma ini memungkinkan mesin mengenali pola-pola kompleks serta membedakan satu gambar dengan gambar lainnya. Keunggulan utama CNN terletak pada kemampuannya dalam meniru sistem pengenalan citra di korteks

visual manusia, sehingga sangat efektif dalam mengolah informasi visual. Dengan kemampuannya yang unggul dalam pengenalan citra, CNN menjadi dasar utama dalam berbagai aplikasi, seperti deteksi objek, klasifikasi gambar, dan pemrosesan citra secara umum [7] .

Beberapa penelitian terkait klasifikasi menggunakan CNN telah dilakukan, termasuk studi mengenai penyakit pada tanaman jagung. Data utama diperoleh dari Github, kemudian dikumpulkan dan diklasifikasikan secara manual. Pemrosesan serta analisis data dilakukan dengan menerapkan model dasar CNN serta transfer learning menggunakan VGG16. Hasil implementasi menunjukkan kinerja yang sangat baik, dengan akurasi pelatihan mencapai 98% dan validasi sebesar 97%. Grafik akurasi dan loss memberikan gambaran visual keberhasilan model dalam mendeteksi penyakit. Berdasarkan hasil tersebut, dapat disimpulkan bahwa jaringan saraf konvolusional mampu mengidentifikasi penyakit pada jagung dengan akurasi lebih dari 90% dan dapat diuji dengan berbagai kumpulan data lainnya [8] .

Berbeda dengan penelitian [9] , Penelitian ini melakukan klasifikasi citra penyakit daun jagung dengan membandingkan empat model kernel pada Convolutional Neural Network, yaitu  $3 \times 2$ ,  $3 \times 3$ ,  $3 \times 4$ , dan  $4 \times 4$ , serta enam metode optimasi, yakni RMSProp, AdaGrad, SGD, Adam, Adamax, dan Adadelta. Hasil penelitian menunjukkan bahwa metode optimasi Adam dengan kernel  $3 \times 3$  memberikan tingkat akurasi tertinggi, yaitu 84% pada data uji dan 89% pada data latih.

penelitian dari [10]. Penelitian ini berfokus pada klasifikasi penyakit daun jagung dengan memanfaatkan arsitektur EfficientNet. Tujuan utama dari penelitian ini adalah mengidentifikasi penyakit pada daun jagung menggunakan metode

convolutional neural network (CNN) dengan berbagai varian arsitektur, yaitu EfficientNetB1, EfficientNetB2, dan EfficientNetB3. Dataset yang digunakan terdiri dari 4.118 citra berukuran 260 x 260 piksel, yang dibagi menjadi 80% untuk data pelatihan, serta masing-masing 10% untuk data uji dan validasi. Hasil evaluasi menunjukkan bahwa arsitektur EfficientNet mampu mencapai tingkat akurasi yang tinggi, yaitu 97,77%.

Dalam penelitian [11] dataset yang digunakan diambil dari situs Kaggle dengan judul *Corn or Maize Leaf Disease Dataset*. Dataset ini memiliki 4 klasifikasi, yaitu: Blight, Common Rust, Grey Leaf Spot, dan Healthy. Penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) dengan dua model yang berbeda, yaitu model EfficientNet-B0 dan ResNet-50. Arsitektur yang digunakan meliputi *dense layer*, *dropout layer*, dan *GlobalAveragePooling layer*, dengan rasio pembagian dataset sebesar 70% sebagai data pelatihan dan 30% sebagai data validasi. Setelah dilakukan pengujian pada dua skenario model yang diusulkan, hasil akurasi yang diperoleh pada skenario model pertama yaitu EfficientNet-B0 adalah sebesar 94%, sedangkan untuk skenario model kedua yaitu ResNet-50 memperoleh akurasi sebesar 93%. Meskipun begitu, dari grafik *confusion matrix* penelitian ini masih mengalami *overfitting* karena jumlah salah satu kelas dataset yang digunakan tidak seimbang, dan masih terdapat banyak kesalahan pengenalan dalam kelas *Gray leaf spot* yang sering tertukan dengan kelas *blight*.

Penelitian sebelumnya menghasilkan akurasi yang cukup baik namun belum mampu menunjukkan bagian mana dari citra daun jagung yang paling berpengaruh terhadap keputusan klasifikasi. Variasi bentuk, warna, dan pencahayaan pada citra

daun sering menyebabkan model salah fokus, misalnya mengenali bagian daun yang sehat atau latar belakang, bukan area yang terinfeksi. Akibatnya, ciri penting seperti bercak kecil, perubahan warna, atau pola tepi daun yang menunjukkan gejala penyakit bisa terabaikan.

Untuk mengatasi hal tersebut, penelitian ini akan mengklasifikasikan penyakit pada daun jagung berdasarkan citra daun menggunakan Convolutional Neural Network dengan model ResNet-50. Penelitian ini menambahkan modul perhatian seperti Convolutional Block Attention Module (CBAM) serta Optimizer Adam dan Stochastic Gradient Descent (SGD) dan preprocessing CLAHE agar model dapat menyoroti area penting pada citra dan mengabaikan bagian yang tidak relevan [12]. Dengan pendekatan ini, model diharapkan memiliki kemampuan yang lebih baik dalam mengenali pola penyakit pada daun tanaman secara akurat dan konsisten dibandingkan arsitektur CNN. Dataset yang digunakan berasal dari situs Kaggle dengan judul Corn or Maize Leaf Disease Dataset. Dataset tersebut terdiri dari 4188 gambar yang terbagi dalam empat kategori, yaitu blight sebanyak 1146 gambar, common rust sebanyak 1306 gambar, gray leaf spot sebanyak 574 gambar, dan healthy sebanyak 1162 gambar.

## 1.2. Rumusan Masalah

Berdasarkan latar belakang yang di angkat, maka dibuat rumusan-rumusan masalah yang akan diselesaikan dalam penelitian, antara lain:

- a. Bagaimana performa yang dihasilkan oleh model Convolutional Neural Network (CNN) dengan Arsitektur ResNet-50 dalam mengklasifikasi

penyakit pada tanaman jagung berdasarkan akurasi, presisi, recall dan F1-Score?

- b. Bagaimana pengaruh Convolutional Block Attention Module Convolutional Block Attention Module (CBAM) pada ResNet-50 menggunakan Optimizer Adam dan SGD dan penerapan preprocessing CLAHE untuk klasifikasi penyakit pada tanaman jagung melalui citra daun?

### 1.3. Batasan Masalah

Mengacu pada luasnya cakupan permasalahan yang diangkat, diperlukan batasan dalam penelitian agar fokus penelitian menjadi lebih terarah dan tidak melenceng dari tujuan utama. Berikut adalah batasan masalah yang diterapkan dalam penelitian ini:

- a. Penelitian ini hanya menggunakan dataset yang diunduh dari Kaggle.
- b. Penelitian ini akan mengidentifikasi penyakit pada tanaman jagung berdasarkan citra daun.
- c. Data citra daun dikategorikan ke dalam 4 kelas yaitu: *Blight*, *Comon Rust*, *Grey Leaf Spot*, dan *Healthy*.
- d. Evaluasi performa model klasifikasi menggunakan confusion matrix.
- e. Penelitian ini hanya menggunakan model ResNet-50 dengan penambahan modul Convolutional Block Attention Module (CBAM) ) serta menggunakan Optimizer Adam dan Stochastic Gradient Descent (SGD).
- f. Penelitian ini hanya menerapkan CLAHE sebagai preprocessing

- g. Fokus penelitian hanya pada mengidentifikasi penyakit pada tanaman jagung berdasarkan citra daun menggunakan model *Convolutional neural network* dengan arsitektur ResNet-50.

#### 1.4. Tujuan Penelitian

Berdasarkan rumusan masalah tujuan dari penelitian ini adalah :


- a. Untuk mengetahui Bagaimana performa yang dihasilkan oleh model Convolutional Neural Network (CNN) dengan Arsitektur ResNet-50 dalam mengklasifikasi penyakit pada tanaman jagung berdasarkan akurasi, presisi, recall dan F1-Score?
- b. Untuk mengetahui Seberapa besar pengaruh Convolutional Block Attention Module Convolutional Block Attention Module (CBAM) pada ResNet-50 menggunakan Optimizer Adam dan SGD dan penerapan preprocessing CLAHE untuk klasifikasi penyakit pada tanaman jagung melalui citra daun?

#### 1.5. Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut:

- a. Model yang dirancang dapat membantu mempercepat proses identifikasi penyakit pada tanaman jagung, sehingga diharapkan mampu mendukung solusi yang lebih efektif di masa depan.
- b. Penelitian ini berkontribusi dalam penerapan metode Convolutional Neural Network (CNN) menggunakan model ekstraksi fitur ResNet-50 untuk klasifikasi penyakit tanaman.

- c. Hasil penelitian ini dapat menjadi referensi bagi studi selanjutnya dalam pengembangan sistem identifikasi penyakit tanaman berbasis citra daun.
- d. Sebagai syarat kelulusan Magister Teknik Informatika Universitas Amikom Yogyakarta.



## **BAB II** **TINJAUAN PUSTAKA**

### **2.1. Tinjauan Pustaka**

Keberhasilan penelitian dalam mengidentifikasi penyakit pada tanaman jagung berbasis citra daun memerlukan tinjauan pustaka yang bersifat ilmiah dan relevan. Kajian ini berperan sebagai referensi utama dalam pengembangan penelitian yang akan dilakukan.

Penelitian (Ahadian et al., 2023) berfokus pada pemanfaatan Convolutional Neural Network (CNN) untuk mengklasifikasikan penyakit pada tanaman jagung. Terdapat dua dataset yang menjadi dasar penelitian ini. Dataset pertama terdiri dari 4144 gambar yang terbagi ke dalam 4 kelas, sementara dataset kedua mencakup 5155 gambar yang terbagi ke dalam 7 hingga 8 kelas. Dalam proses eksperimen, tiga arsitektur model yang berbeda—ResNet-18, VGG16, dan EfficientNet—diuji secara menyeluruh. Selain itu, berbagai jenis optimizer juga dieksplorasi, dengan hasil yang menunjukkan bahwa kedua dataset mencapai akurasi tertinggi saat menggunakan optimizer SGD (Stochastic Gradient Descent). Pada dataset pertama, hasil optimal diperoleh dengan arsitektur VGG16, dengan penerapan frozen layer pada tahap klasifikasi, dan menghasilkan akurasi yang mengesankan sebesar 97,146%. Sementara itu, pada dataset kedua, hasil terbaik dicapai dengan menggunakan arsitektur EfficientNet tanpa frozen layer, serta penerapan weighted loss untuk mengatasi ketidakseimbangan kelas, yang menghasilkan akurasi sebesar 94,798%.


Penelitian dari (Ilham Rahmana Syihad et al., 2023) Penelitian ini bertujuan untuk meningkatkan ketepatan dalam mengidentifikasi penyakit pada tanaman pisang. Model ResNet-50 mampu mencapai tingkat akurasi sebesar 94%, dengan nilai precision 88%, recall 91%, dan F1-score 89%. Di sisi lain, model VGG-19 juga menunjukkan kinerja yang baik dengan akurasi mencapai 91%, melampaui hasil dari penelitian-penelitian sebelumnya dan menegaskan bahwa kedua model ini efektif dalam mendeteksi penyakit pada tanaman pisang melalui analisis citra daun.

Penelitian selanjutnya dari (Syarief & Setiawan, 2020) Penelitian ini membahas tentang proses klasifikasi gambar daun jagung yang terkena penyakit. Data yang digunakan terdiri dari 200 gambar yang terbagi ke dalam empat kategori, yaitu: daun sehat, cercospora, common rust, dan northern leaf blight. Proses penelitian dilakukan melalui dua tahapan utama, yaitu ekstraksi fitur dan klasifikasi. Ekstraksi fitur dilakukan secara otomatis dengan memanfaatkan metode Convolutional Neural Network (CNN). Dalam penelitian ini, tujuh arsitektur CNN yang diuji meliputi: AlexNet, VGG16, VGG19, GoogleNet, Inception-V3, ResNet-50, dan ResNet-101. Selanjutnya, proses klasifikasi dilakukan menggunakan algoritma machine learning, yaitu k-Nearest Neighbor (k-NN), Decision Tree, dan Support Vector Machine (SVM). Dari hasil pengujian, kombinasi paling optimal diperoleh pada penggunaan model AlexNet dengan algoritma Support Vector Machine, yang menghasilkan akurasi sebesar 93,5%, sensitivitas 95,08%, dan spesifisitas 93%.

Penelitian yang dilakukan (Kaushik et al., 2024) memanfaatkan model deep convolutional neural network (CNN) untuk mendeteksi penyakit pada daun tanaman melalui citra daun. CNN telah menunjukkan hasil yang menjanjikan dalam tugas-tugas visi komputer (machine vision). Model-model CNN yang digunakan dalam penelitian ini mencapai tingkat akurasi antara 90,25% hingga 95,56% dalam mengklasifikasikan penyakit, melampaui metode tradisional yang bergantung pada fitur buatan secara manual. Arsitektur CNN utama yang dieksplorasi meliputi VGG16, ResNet50, dan AlexNet, dengan beberapa optimasi seperti penyesuaian batch size, penerapan dropout, serta variasi jumlah epoch pelatihan.

Penelitian dari (Haque et al., 2022) Dalam penelitian ini, diusulkan pendekatan deep learning untuk identifikasi penyakit tanaman jagung berdasarkan citra di lapangan. Gambar-gambar diambil dari lahan percobaan milik ICAR-IIMR di Ludhiana, India, dengan menargetkan tiga jenis penyakit utama, yaitu Maydis Leaf Blight, Turcicum Leaf Blight, dan Banded Leaf and Sheath Blight. Pengambilan gambar dilakukan secara non-destruktif dengan latar belakang yang bervariasi menggunakan kamera digital dan ponsel pintar. Untuk mengatasi masalah ketidakseimbangan kelas pada data, gambar buatan dihasilkan menggunakan metode peningkatan rotasi dan peningkatan kecerahan. Dalam studi ini, tiga arsitektur berbeda yang berbasis pada kerangka jaringan Inception-v3 dilatih menggunakan gambar penyakit jagung yang telah dikumpulkan dengan pendekatan pelatihan dasar (baseline training). Model dengan performa terbaik mencapai akurasi klasifikasi keseluruhan sebesar 95,99% dan rata-rata recall sebesar 95,96% pada dataset pengujian terpisah.

Berbeda dengan penelitian (Adhinata et al., 2021) menggunakan metode Convolutional Neural Network dengan memanfaatkan model DenseNet-201. Dataset yang digunakan terdiri dari 4188 gambar yang diklasifikasikan ke dalam empat kategori, yaitu blight sebanyak 1146 gambar, common rust sebanyak 1306 gambar, gray leaf spot sebanyak 574 gambar, dan healthy sebanyak 1162 gambar. Dari penelitian ini, diperoleh akurasi terbaik sebesar 93%.



## 2.2.Keaslian Penelitian

Tabel 2. 1 Matriks literatur review dan posisi penelitian

### IDENTIFIKASI PENYAKIT TANAMAN JAGUNG BERDASARKAN CITRA DAUN MENGGUNAKAN COVOLUTIONAL NEURAL NETWORK

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	<i>Corn Disease Classification Using Convolutional Neural Network with Weighted Loss</i>	Krisnanda Ahadian, Novanto Yudsitira, Bayu Rahayudi, Jurnal SSRN (2023)	Penelitian ini melakukan eksperimen dengan tiga arsitektur model yang berbeda yaitu ResNet-18, VGG16, dan EfficientNet untuk mengklasifikasikan penyakit pada tanaman jagung menggunakan dataset yang terdiri dari 4144 gambar yang terbagi menjadi 4 kelas dan Dataset kedua 5155 gambar yang terbagi ke dalam 7 hingga 8 kelas.	dari penelitian yang dilakukan dengan dataset pertama, performa terbaik dicapai menggunakan arsitektur VGG16 dengan penerapan frozen layer pada tahap klasifikasi, yang menghasilkan akurasi tinggi sebesar 97,146%. Sedangkan pada dataset kedua, akurasi terbaik sebesar 94,798% diperoleh melalui arsitektur EfficientNet tanpa frozen layer, serta dengan penerapan metode weighted loss untuk mengatasi masalah ketidakseimbangan antar kelas.	Dataset kedua yang digunakan dalam penelitian ini mengalami permasalahan ketidakseimbangan distribusi kelas, di mana beberapa kelas memiliki jumlah data yang jauh lebih banyak dibandingkan kelas lainnya.	Penelitian yang akan kami lakukan adalah klasifikasi penyakit pada tanaman jagung melalui citra daun menggunakan model CNN dengan arsitektur EfficientNet-B0 menambahkan teknik <i>Class Weighting</i> untuk menyeimbangkan data agar terhindar dari overfitting.

2	CNN Method to Identify the Banana Plant Diseases based on Banana Leaf Images by Giving Models of ResNet50 and VGG-19	Ilham Rahmana S. Muhammad Rizal, Zamah Sari, Yufis Azhar. Jurnal Resti (2023)	Tujuan dari penelitian ini mencakup pengolahan dataset, pengembangan arsitektur model, evaluasi, dan pelaporan hasil, dengan fokus utama pada peningkatan akurasi identifikasi penyakit tanaman pisang menggunakan Model ResNet-50 dan model VGG 16.	Dari Penelitian yang telah dilakukan Model ResNet50 menunjukkan performa yang mengesankan dengan akurasi sebesar 94%, presisi 88%, recall 91%, dan skor F1 sebesar 89%. Sementara itu, model VGG-19 juga menunjukkan kinerja yang baik dengan akurasi mencapai 91%, melampaui hasil penelitian sebelumnya dan menegaskan efektivitas kedua model dalam mengidentifikasi penyakit tanaman pisang melalui citra daun.	Penelitian ini menggunakan data uji luar dimana data ini kurang representatif. Serta dataset dari kaggle belum tentu seimbang sehingga bisa menimbulkan overfitting.	Penelitian yang akan kami lakukan adalah kalsifikasi penyakit pada tanaman jagung melalui citra daun menggunakan model CNN dengan arsitektur EfficientNet-B0 menambahkan teknik <i>Class Weighting</i> untuk menyeimbangkan data agar terhindar dari overfitting.
---	--	---	--	---	--	---

3	Convolutional Neural Network for Maize leaf Disease Image Classification	Mohammad Syarif, Wahyudi Setiawan, Jurnal Telkomnika (2020)	<p>Penelitian ini membahas klasifikasi citra daun jagung yang terkena penyakit menggunakan 200 gambar dalam empat kategori: sehat, cercospora, common rust, dan northern leaf blight. Prosesnya terdiri dari dua tahap, yaitu ekstraksi fitur secara otomatis menggunakan Convolutional Neural Network (CNN) dan klasifikasi.</p>	<p>Dalam penelitian ini, tujuh arsitektur CNN yang diuji meliputi: AlexNet, VGG16, VGG19, GoogleNet, Inception-V3, ResNet-50, dan ResNet-101. Selanjutnya, proses klasifikasi dilakukan menggunakan algoritma machine learning, yaitu k-Nearest Neighbor (k-NN), Decision Tree, dan Support Vector Machine (SVM). Dari hasil pengujian, kombinasi paling optimal diperoleh pada penggunaan model AlexNet dengan algoritma Support Vector Machine, yang menghasilkan akurasi sebesar 93,5%, sensitivitas 95,08%, dan spesifisitas 93%.</p>	<p>Penelitian ini hanya menggunakan metrik akurasi untuk penilaian kinerja model sehingga pada klasifikasi yang tidak seimbang akurasi dapat menyesatkan.</p>	<p>Penelitian yang akan kami lakukan akan menggunakan confusion matrix untuk penilaian kinerja model.</p>
---	--	---	---	---	---	---


4	Identification of Corn Leaf Disease Using Deep Learning	Rekha Kaushik, Suryansh Yagnik, Aman Verma, Nitin Yadav, IEEE (2024)	memanfaatkan model <i>deep convolutional neural network</i> (CNN) untuk mendeteksi penyakit pada daun tanaman melalui citra daun. CNN telah menunjukkan hasil yang menjanjikan dalam tugas-tugas visi komputer ( <i>machine vision</i> ).	Model-model CNN yang digunakan dalam penelitian ini mencapai tingkat akurasi antara 90,25% hingga 95,56% dalam mengklasifikasikan penyakit, melampaui metode tradisional yang bergantung pada fitur buatan secara manual. Arsitektur CNN utama yang dieksplorasi meliputi VGG16, ResNet50, dan AlexNet, dengan beberapa optimasi seperti penyesuaian <i>batch size</i> , penerapan <i>dropout</i> , serta variasi jumlah <i>epoch</i> pelatihan.	Penelitian ini menggunakan data uji luar dimana data ini kurang representatif. Serta dataset dari kaggle belum tentu seimbang sehingga bisa menimbulkan overfitting	Penelitian yang akan kami lakukan adalah kalsifikasi penyakit pada tanaman jagung melalui citra daun menggunakan model CNN dengan arsitektur EfficientNet-B0 menambahkan teknik <i>Class Weighting</i> untuk menyeimbangkan data agar terhindar dari overfitting.
5	Deep learning-based approach for identification of diseases of maize crop	Md. Ashraf Haque, Sudeep Marwaha, Chandan Kumar Deb, Sapna Nigam, Alka Arora, (2022), Scientific Reports	Penelitian ini bertujuan untuk mengidentifikasi penyakit pada tanaman jagung dengan mengkomparasi model dengan kerangka arsitektur <i>Inception-v3</i> pada metode <i>convolutional neural network</i>	Dari penelitian yang telah dilakukan, pada model pertama <i>Inception v3</i> <i>fully connected layer</i> menghasilkan tingkat akurasi sebesar 95.42%, pada model kedua <i>Inception-v3</i> <i>global average pooling layer</i> mendapatkan akurasi sebesar 95.71%, dan pada model yang ketiga <i>Inception-v3</i> <i>global average pooling layer</i> with <i>fully</i>	Penelitian ini tidak mencoba mengkomparasi arsitektur cnn guna mengetahui performa yang terbaik, dan pada tahap <i>preprocessing</i> bisa lebih ditingkatkan.	Penelitian yang akan kami lakukan adalah kalsifikasi penyakit pada tanaman jagung melalui citra daun menggunakan model CNN dengan arsitektur EfficientNet-B0 menambahkan teknik <i>Class Weighting</i> untuk menyeimbangkan data agar terhindar dari overfitting

				<i>connected layer</i> menghasilkan akurasi 95.38%.		
6	Corn Disease Classification Using Transfer Learning and Convolutional Neural Network	Faisal Dharma Adhinata, Gita Fadila Fitriana, Aditya Wijayanto, Muhammad Pajar Kharisma Putra (2021) Jurnal Informatika	Penelitian ini menggunakan teknik transfer learning sebagai ekstraksi fitur yang dikombinasikan dengan Convolutional Neural Network (CNN) sebagai klasifikasi penyakit pada tanaman jagung. Kami menganalisis kombinasi antara DenseNet201 dengan lapisan Flatten dan Global Average Pooling.	Hasil eksperimen menunjukkan bahwa kombinasi DenseNet201 dengan lapisan Global Average Pooling menghasilkan akurasi yang lebih baik dibandingkan dengan DenseNet201 yang menggunakan lapisan Flatten. Akurasi yang diperoleh sebesar 93%, yang membuktikan bahwa sistem yang diusulkan lebih akurat dibandingkan penelitian sebelumnya.	Penelitian ini memiliki dataset yang tidak seimbang sehingga nilai recall yang dihasilkan belum optimal.	Penelitian yang akan kami lakukan adalah klasifikasi penyakit pada tanaman jagung melalui citra daun menggunakan model CNN dengan arsitektur EfficientNet-B0 menambahkan teknik <i>Class Weighting</i> untuk menyeimbangkan data agar terhindar dari overfitting.

## 2.3. Landasan Teori

### 2.3.1. Penyakit tanaman jagung

Penyakit yang menyerang tanaman jagung menjadi ancaman besar bagi sektor pertanian, karena dapat menyebabkan penurunan produktivitas dan kerugian ekonomi bagi petani. Penyakit ini dapat muncul akibat berbagai faktor, seperti infeksi jamur, bakteri, virus, serta kondisi lingkungan yang kurang mendukung pertumbuhan tanaman secara optimal [13]. Dengan perkembangan media pertanian modern, termasuk internet dan media sosial, informasi mengenai penyakit tanaman jagung dapat tersebar dengan cepat. Namun, tidak semua informasi yang beredar dapat dipercaya, karena masih banyak kesalahan informasi atau mitos yang dapat menyesatkan petani dalam mengambil langkah pengendalian. Penyebaran informasi yang keliru tentang penyakit tanaman jagung berpotensi menimbulkan dampak negatif, seperti penggunaan pestisida yang tidak sesuai, penerapan teknik pertanian yang kurang efektif, hingga meningkatnya risiko penularan penyakit ke area pertanian lainnya. Selain itu, informasi yang salah dapat membuat petani mengabaikan metode pengendalian yang lebih tepat, sehingga memperburuk kondisi tanaman dan hasil panen. Citra daun jagung yang terinfeksi penyakit dapat dilihat pada Gambar 2.1.



Gambar 2. 1 Citra Daun Terinfeksi

Untuk mengatasi permasalahan ini, diperlukan pendekatan menyeluruh yang melibatkan berbagai pihak. Meningkatkan literasi petani dalam mengenali dan mengendalikan penyakit tanaman jagung berdasarkan kajian ilmiah, memperkuat sistem verifikasi informasi oleh lembaga pertanian dan akademisi, serta menerapkan kebijakan yang mendukung penyebaran informasi yang akurat menjadi langkah-langkah penting yang harus dilakukan. Dengan strategi yang tepat, petani dapat lebih siap dalam menghadapi ancaman penyakit tanaman jagung dan menjaga keberlanjutan produksi pertanian mereka.

### **2.3.2. Citra Daun**


Citra daun memiliki peran krusial dalam berbagai aspek pertanian dan penelitian ilmiah, terutama dalam menilai kondisi kesehatan tanaman. Melalui analisis citra daun, gejala penyakit, kekurangan nutrisi, serta dampak lingkungan terhadap pertumbuhan tanaman dapat diidentifikasi dengan lebih efektif. Seiring dengan perkembangan teknologi digital dan kecerdasan buatan, pemrosesan citra kini memungkinkan deteksi yang lebih cepat dan akurat dibandingkan metode observasi manual [14].

Namun, informasi yang tidak akurat terkait analisis citra daun dapat berdampak negatif. Kesalahan dalam menafsirkan citra dapat mengarah pada diagnosis yang keliru, penggunaan pupuk atau pestisida yang tidak tepat, serta keputusan pengelolaan pertanian yang kurang optimal [15]. Selain itu, mitos atau informasi yang tidak berdasarkan penelitian ilmiah dapat membuat petani dan peneliti mengabaikan metode yang lebih valid dan efektif, sehingga menghambat perkembangan teknologi dalam deteksi penyakit tanaman. Untuk mengatasi tantangan ini, diperlukan pendekatan yang menyeluruh. Meningkatkan literasi digital serta pemahaman mengenai analisis citra daun di kalangan

petani dan peneliti, membangun sistem verifikasi informasi oleh institusi akademik dan pertanian, serta mendorong penerapan teknologi kecerdasan buatan dalam deteksi penyakit tanaman merupakan langkah-langkah penting yang harus dilakukan. Dengan strategi yang tepat, analisis citra daun dapat menjadi solusi andal dalam mendukung pertanian presisi dan berkelanjutan.

### **2.3.3. Convolutional Neural Network**

Convolutional Neural Network (CNN) merupakan pengembangan dari Multilayer Perceptron (MLP) yang dirancang untuk menangani data dalam skala besar dan diimplementasikan dalam pemrosesan citra tiga dimensi. CNN berfungsi sebagai metode pemrosesan gambar yang digunakan untuk mengenali objek atau mendeteksi keberadaan suatu benda dalam citra [16]. Teknik ini banyak diterapkan dalam klasifikasi dan pengenalan gambar yang telah diberi label dengan pendekatan supervised learning. Dalam supervised learning, terdapat data pelatihan dan variabel target, di mana tujuan utama metode ini adalah mengelompokkan suatu data ke dalam kategori yang telah ditentukan sebelumnya. Arsitektur CNN memiliki kemampuan untuk menangkap informasi kontekstual yang terdapat dalam data, seperti hubungan antara piksel yang berdekatan dalam sebuah citra. Hal ini memungkinkan model CNN untuk secara otomatis mengekstraksi fitur dari gambar tanpa memerlukan intervensi manual. Adapun arsitektur umum yang sering dijumpai pada CNN dapat dilihat pada Gambar 2.2.



Gambar 2. 2 Arsitektur Pada CNN

#### 2.3.4. ResNet

ResNet (Residual Network) merupakan salah satu arsitektur deep learning yang diperkenalkan oleh Kaiming He bersama timnya pada tahun 2015. Arsitektur ini dirancang untuk mengatasi masalah degradasi, yaitu penurunan akurasi yang sering muncul ketika jaringan neural memiliki lapisan yang sangat dalam. ResNet mengusung konsep residual learning, di mana jaringan tidak belajar langsung terhadap fungsi target, melainkan terhadap selisih (residual) antara input dan output [11]. Untuk mendukung konsep ini, ResNet menggunakan shortcut connections atau skip connections yang memungkinkan data dari satu layer diteruskan langsung ke layer yang lebih dalam tanpa melalui semua layer di antaranya. Strategi ini terbukti mampu menjaga kinerja model, bahkan saat jumlah layer bertambah banyak. ResNet memodelkan transformasi sebagai:

$$H(x) = F(x) + x \quad (1)$$

Dimana:

$H(x)$  : Output yang diinginkan

$F(x)$  : Fungsi residual

$X$  : Input asli yang dilewatkan langsung melalui *shortcut connection*

Dengan ini, jaringan hanya perlu mempelajari  $F(x) = H(x) - x$ , yang secara empiris lebih mudah dibandingkan langsung mempelajari  $H(x)$ .

### 2.3.5. Klasifikasi

Klasifikasi adalah proses yang bertujuan untuk menentukan fungsi suatu model agar dapat mengenali kelas atau label data, sehingga mampu memprediksi kelas yang sebelumnya tidak diketahui [17]. Teknik ini banyak diterapkan dalam berbagai bidang, seperti deteksi penggunaan masker, penentuan tingkat kematangan buah, identifikasi penyakit, dan lain sebagainya. Dalam klasifikasi, terdapat dua tahap utama, yaitu training dan testing. Pada tahap training, model dibangun menggunakan data sampel yang telah memiliki label agar dapat mempelajari pola yang ada. Sementara itu, tahap testing dilakukan dengan menguji model yang telah dibangun untuk mengklasifikasikan data baru serta mengukur tingkat keakuratannya.

### 2.3.6. Confusion Matrix

Metode *confusion matrix* merupakan metode pengujian untuk mengetahui kinerja pada suatu model pada metode klasifikasi. Metode ini berupa matriks yang berisikan label hasil prediksi dari metode klasifikasi dan label data sesungguhnya [18]. Saat mengukur kinerja dengan *confusion matrix*, terdapat 4 (empat) *term* yang mewakili hasil proses klasifikasi. Keempat suku tersebut adalah *true positive (TP)*, *true negative (TN)*, *false positive (FP)*, dan *false negative (FN)*. Pada Tabel 1 merupakan tabel dari *Confusion Matrix*.

Tabel 2. 2.Tabel 4. 0.1 *Confusion Matrix*

	<b>Positive</b>	<b>Negative</b>
<b>Positive</b>	<i>TP (True Positive)</i>	<i>FP (False Positive)</i>
<b>Negative</b>	<i>TN (True Negative)</i>	<i>FN (False Negative)</i>

Keterangan:

- a. *True Positive* (TP) merupakan data yang diprediksikan dengan tepat sebagai keluaran positif atau benar.
- b. *True Negative* (TN) merupakan data yang diprediksikan tepat sebagai keluaran negatif atau salah.
- c. *False Positive* (FP) merupakan data prediksi yang kurang tepat apabila keluaran positif atau benar.
- d. *False Negative* (FN) merupakan data yang diprediksikan kurang tepat apabila keluaran negatif atau salah.

Dalam mengukur kinerja sebuah model klasifikasi, ada beberapa model kinerja pada *confusion matrix* yang biasanya digunakan diantaranya akurasi, *recall*, dan presisi [19].

- a. Akurasi

Akurasi merupakan gambaran seberapa akurat model dalam mengklasifikasi data dengan sesuai dan tepat. Persamaan nilai akurasi

sebagai berikut:

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

b. Presisi

Presisi merupakan gambaran dari tingkat keakuratan dari data yang diminat dengan hasil prediksi yang diberikan oleh model. Persamaan nilai presisi sebagai berikut:

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

c. Recall

Recall merupakan gambaran perhitungan kebenaran negatif dibandingkan keseluruhan data negatif. Persamaan nilai recall sebagai berikut:

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

## BAB III METODE PENELITIAN

### 3.1. Jenis, Sifat, dan Pendekatan Penelitian

Jenis penelitian yang digunakan pada penelitian ini bersifat eksperimental, di mana dilakukan beberapa skenario percobaan guna menghasilkan akurasi yang tinggi. Eksperimen yang dilakukan adalah penerapan metode klasifikasi dalam mendeteksi penyakit daun tanaman jagung dengan menggunakan ekstraksi fitur *ResNet-50* dan model *Convolutional Neural Network (CNN)*. Dari penerapan model ini, akan dilakukan pengujian untuk mengetahui performa *Convolutional Neural Network (CNN)* dengan *Convolutional Block Attention Module (CBAM)* serta penambahan fitur preprocessing *CLAHE* dalam mengidentifikasi penyakit daun pada tanaman jagung secara akurat dan efisien dengan penambahan modul Penelitian ini bersifat deskriptif, karena bertujuan untuk membandingkan tingkat akurasi, presisi, dan recall dalam identifikasi penyakit daun pada tanaman jagung menggunakan metode *Convolutional Neural Network (CNN)*. Pendekatan yang digunakan adalah kuantitatif, yakni suatu proses pengumpulan data dalam bentuk angka yang kemudian dianalisis untuk memperoleh temuan setelah proses pengujian dilakukan.

### 3.2. Metode Pengumpulan Data

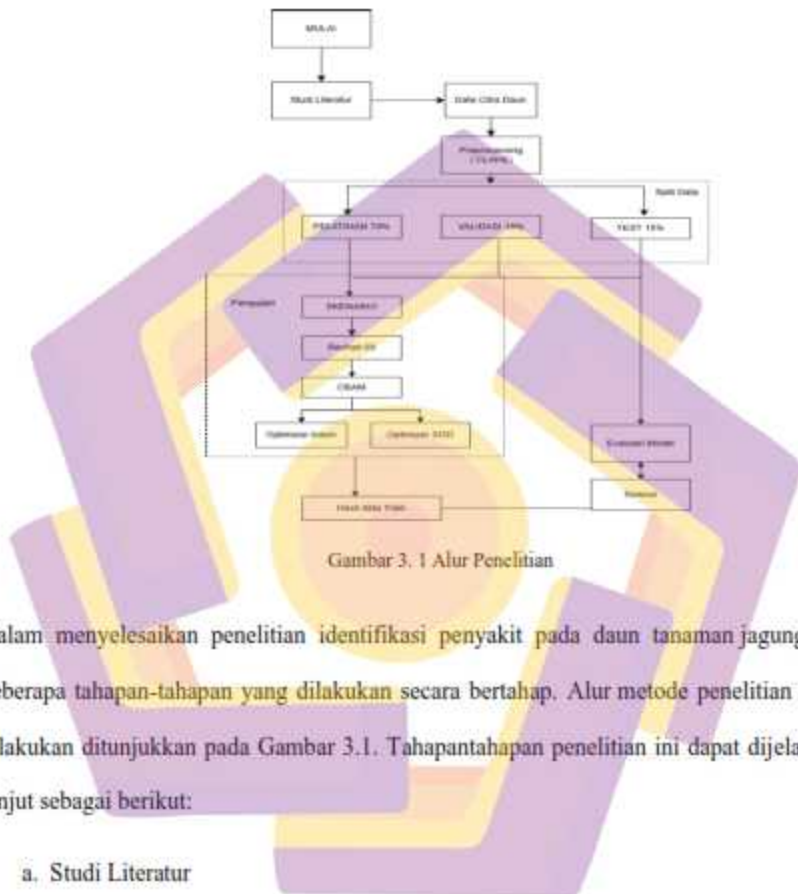
Penelitian ini menggunakan data dari layanan penyedia data publik yang dapat diakses oleh siapa saja untuk keperluan penelitian. Sumber data yang digunakan berasal dari situs [www.kaggle.com](http://www.kaggle.com), tepatnya dataset berjudul *Corn or Maize Leaf Disease Dataset* yang dikontribusikan oleh Smaranjit Ghose. Dataset ini terdiri dari gambar atau citra digital daun

jagung dan telah digunakan dalam beberapa penelitian sebelumnya, seperti yang dilakukan oleh [20] dalam penelitian berjudul *Leaf Image Identification: CNN with EfficientNet-B0 and ResNet-50 Used to Classified Corn Disease* serta oleh [21] dalam penelitian *Identifying Types of Corn Leaf Diseases with Deep Learning*. Data yang digunakan dalam penelitian ini diklasifikasikan ke dalam dua kategori, yaitu satu kelas untuk daun sehat dan satu lainnya untuk daun yang terinfeksi penyakit.

### 3.3. Metode Analisis Data

Metode analisis data merupakan tahapan pengolahan data untuk mendapatkan hasil yang paling optimal dari permasalahan yang telah dirumuskan. Metode analisis yang digunakan pada penelitian ini berupa analisis kuantitatif menggunakan *Convolutional Neural Network (CNN)*. Citra daun jagung yang telah diperoleh dari proses pengumpulan data akan di klasifikasikan menjadi dua kelas yaitu daun sehat dan daun yang terinfeksi penyakit. Dalam penelitian ini menerapkan tiga skenario ekstraksi fitur menggunakan ResNet-50.

### 3.4. Alur Penelitian



Dalam menyelesaikan penelitian identifikasi penyakit pada daun tanaman jagung, terdapat beberapa tahapan-tahapan yang dilakukan secara bertahap. Alur metode penelitian yang akan dilakukan ditunjukkan pada Gambar 3.1. Tahapantahapan penelitian ini dapat dijelaskan lebih lanjut sebagai berikut:

#### a. Studi Literatur

Tahap studi literatur dilakukan dengan mengumpulkan dan menganalisis berbagai referensi ilmiah yang relevan, baik dari jurnal, buku, maupun penelitian terdahulu. Kajian ini difokuskan pada teori-teori mengenai pengolahan citra digital, jaringan konvolusional (CNN), arsitektur ResNet-50, serta penerapan modul perhatian seperti CBAM (Convolutional Block Attention Module). Selain itu, literatur mengenai teknik

peningkatan kualitas citra seperti CLAHE juga dipelajari untuk mendukung pemilihan metode yang tepat.

b. Data Citra Daun

Data yang digunakan dalam penelitian ini berupa citra daun jagung yang dikumpulkan dari dataset publik atau hasil dokumentasi langsung. Setiap citra mewakili salah satu dari empat kelas, yaitu tiga jenis penyakit daun jagung dan satu kelas daun sehat. Dataset ini berfungsi sebagai bahan utama dalam proses pelatihan dan pengujian model klasifikasi berbasis deep learning.

c. Preprocessing (CLAHE)

Tahap pra-pemrosesan dilakukan menggunakan teknik Contrast Limited Adaptive Histogram Equalization (CLAHE) untuk meningkatkan kontras dan memperjelas detail pada citra daun. Proses ini bertujuan agar model dapat mengenali pola dan tekstur pada daun dengan lebih akurat, terutama pada bagian yang memiliki pencahayaan tidak merata. Hasil dari tahap ini berupa citra yang lebih optimal untuk digunakan dalam pelatihan model.

d. Split Data

Setelah proses pra-pemrosesan, data citra dibagi menjadi tiga subset dengan proporsi 70% untuk data pelatihan, 15% untuk data validasi, dan 15% untuk data pengujian. Pembagian ini bertujuan agar model dapat belajar secara efektif dari data pelatihan, dievaluasi kinerjanya selama proses validasi, serta diuji kemampuannya pada data baru yang belum pernah dilihat. Proses pembagian ini penting untuk memastikan model memiliki kemampuan generalisasi yang baik.

e. Pengujian (Skenario)

Tahap pengujian dilakukan dengan menerapkan dua skenario untuk menganalisis pengaruh penggunaan modul CBAM (Convolutional Block Attention Module) terhadap performa model ResNet-50 dalam proses klasifikasi citra. Pada skenario pertama, model ResNet-50 dimodifikasi dengan menambahkan modul CBAM dan menggunakan optimizer Adam dengan pengaturan learning rate tertentu untuk mempercepat proses konvergensi dan meningkatkan stabilitas pembelajaran. Sedangkan pada skenario kedua, digunakan arsitektur dan modul yang sama, namun optimizer diganti menjadi Stochastic Gradient Descent (SGD), yang diharapkan dapat memberikan pembaruan parameter yang lebih halus dan meningkatkan kemampuan model dalam memfokuskan perhatian pada fitur-fitur penting dari citra. Hasil dari kedua skenario ini kemudian dibandingkan untuk menilai seberapa besar pengaruh kombinasi ResNet-50 dengan CBAM dan jenis optimizer terhadap kinerja model dalam melakukan klasifikasi citra secara akurat.

f. Hasil Data Train

Setelah proses pelatihan selesai, hasil dari setiap skenario dianalisis meliputi nilai akurasi, loss, waktu pelatihan, dan grafik konvergensi. Tahap ini bertujuan untuk mengevaluasi sejauh mana model mampu mempelajari pola dari data latih dan bagaimana tingkat kestabilan performanya selama proses pelatihan berlangsung.

g. Evaluasi Model

Evaluasi model dilakukan menggunakan metrik performa seperti akurasi, presisi, recall, F1-score, dan confusion matrix. Evaluasi ini bertujuan untuk mengukur kemampuan model dalam mengklasifikasikan citra daun secara tepat pada masing-masing kelas. Hasil evaluasi kemudian digunakan untuk menentukan model terbaik di antara dua skenario yang telah diuji.

## BAB IV HASIL PENELITIAN DAN PEMBAHASAN

### 4.1. Pengumpulan Data

Pada penelitian ini digunakan data sekunder yang diperoleh dari situs penyedia dataset publik yang dapat diakses secara bebas oleh siapa pun. Data yang dimanfaatkan berupa citra daun. Pembagian data yang digunakan dalam penelitian ini, yang terdiri dari tiga subset, yaitu data training, validation, dan testing. Dari total 4.188 data, sebanyak 2.932 data atau 70% digunakan untuk proses training, yaitu tahap pelatihan model agar mampu mengenali pola pada data. Selanjutnya, 628 data atau 15% dialokasikan untuk validation, yang berfungsi untuk menguji performa model selama proses pelatihan dan mencegah overfitting. Sisanya, 628 data atau 15% digunakan untuk testing, yaitu tahap evaluasi akhir guna menilai kemampuan model dalam melakukan prediksi terhadap data baru yang belum pernah dilihat sebelumnya. Pembagian ini dilakukan agar model yang dihasilkan memiliki kinerja yang optimal dan generalisasi yang baik. Jagung yang mengandung berbagai kondisi penyakit, bersumber dari situs Kaggle dengan judul Corn or Maize Leaf Disease Dataset yang dikontribusikan oleh Smaranjit Ghose pada tahun 2019 melalui tautan <https://www.kaggle.com/datasets/smaranjitghose/corn-or-maize-leaf-disease-dataset>. Proses pengumpulan data pada Corn or Maize Leaf Disease Dataset dilakukan dalam kondisi lapangan secara alami, di mana daun jagung difoto langsung di lingkungan pertanian tanpa pengaturan studio. Gambar-gambar diambil dalam berbagai kondisi cahaya, sebagian menggunakan pencahayaan matahari penuh yang menghasilkan bayangan dan pantulan cahaya kuat, sementara sebagian lainnya difoto pada kondisi teduh atau mendung sehingga warna daun tampak lebih

lembut. Posisi daun dalam dataset juga bervariasi; ada yang difoto langsung dari atas, ada yang dipegang oleh tangan, dan ada pula yang diletakkan pada permukaan datar. Variasi sudut pengambilan gambar cenderung kecil, tetapi tetap menunjukkan bahwa pengambilan data tidak dilakukan secara terstandar. Dari kualitas dan karakter resolusi gambar, besar kemungkinan perangkat yang digunakan adalah kamera smartphone kelas menengah, yang umum digunakan dalam pengumpulan dataset visual pertanian di lapangan.

Namun, proses pengumpulan data seperti ini berpotensi menghasilkan berbagai bentuk bias. Bias lingkungan dapat muncul karena dataset kemungkinan besar dikumpulkan di negara tertentu dengan kondisi iklim, pencahayaan, dan varietas jagung yang berbeda dari kondisi Indonesia. Hal ini dapat menyebabkan model bekerja baik pada data asli tetapi kurang akurat ketika digunakan dalam konteks lokal. Selain itu, bias kamera juga mungkin terjadi karena keseragaman jenis perangkat yang digunakan, sehingga model lebih sensitif terhadap kualitas kamera tertentu. Variasi posisi dan latar belakang daun juga dapat memberikan bias tambahan, terutama jika kelas penyakit tertentu lebih sering muncul pada latar belakang tertentu. Terakhir, dataset mungkin hanya mencakup jenis-jenis penyakit tertentu yang umum di lokasi pengumpulan, sehingga tidak sepenuhnya mewakili penyakit jagung yang dominan di wilayah lain. Semua bentuk bias ini perlu diperhatikan dan diatasi melalui augmentasi data, penambahan data lokal, atau teknik adaptasi domain agar model dapat bekerja secara lebih general dan akurat.

Tabel 4.1 Jumlah Data Citra Daun

Kelas	Jumlah
<i>Blight</i>	1146
<i>Common Rust</i>	1306
<i>Grey Leaf Spot</i>	574
<i>Healthy</i>	1162
<b>Jumlah</b>	<b>4188</b>

Dataset ini juga telah digunakan dalam beberapa penelitian terdahulu, antara lain oleh Singh et al. (2019) serta Geetharamani & J. (2019). Jumlah total citra yang digunakan dalam penelitian ini sebanyak 4.188 gambar, yang dikategorikan ke dalam empat kelas, terdiri atas satu kelas daun sehat dan tiga kelas daun yang terinfeksi penyakit, yaitu blight, common rust, dan grey leaf spot. Rincian jumlah citra pada masing-masing kelas disajikan pada Tabel 4.1.

#### 4.2. Preprocessing Data

Pada tahap preprocessing, penelitian ini menggunakan metode Contrast Limited Adaptive Histogram Equalization (CLAHE) untuk meningkatkan kualitas visual citra daun sebelum dilakukan proses pelatihan model. Teknik preprocessing CLAHE (Contrast Limited Adaptive Histogram Equalization) memiliki pengaruh yang cukup penting ketika diterapkan pada dataset daun jagung seperti *Corn or Maize Leaf Disease Dataset*, terutama karena dataset tersebut dikumpulkan dalam


kondisi lapangan yang tidak terstandar. Pada dataset yang diambil dengan pencahayaan alami, perbedaan intensitas cahaya sering menyebabkan sebagian gambar tampak terlalu gelap, terlalu terang, atau memiliki kontras yang tidak konsisten. Ketidakkonsistenan ini dapat membuat fitur penyakit seperti bercak, perubahan warna, atau pola nekrosis menjadi kurang jelas. Dengan penggunaan CLAHE, distribusi pencahayaan pada citra menjadi lebih merata karena teknik ini meningkatkan kontras pada area lokal, bukan pada keseluruhan gambar. Hal ini memungkinkan detail-detail kecil pada permukaan daun tampil lebih jelas sehingga membantu model mendeteksi pola visual penyakit secara lebih akurat. Pada Gambar 4.1 dapat dilihat citra daun jagung yang belum melalui tahap *preprocessing*



Gambar 4.1 Contoh Citra Daun Jagung Sebelum *Preprocessing*

Berdasarkan Gambar 4.1 langkah yang digunakan untuk *preprocessing* pada citra daun adalah CLAHE. penerapan CLAHE dilakukan dengan menggunakan library OpenCV pada citra berformat RGB, di mana setiap channel warna (Red, Green, Blue) diproses secara terpisah kemudian digabungkan kembali menjadi citra hasil peningkatan kontras. Tahapan ini bertujuan agar fitur-fitur penting pada permukaan daun, seperti pola tekstur dan bercak penyakit, menjadi lebih jelas dan mudah dikenali oleh model ResNet-50 maupun ResNet-50 yang dimodifikasi dengan CBAM. Dengan demikian, CLAHE berperan penting dalam membantu model mengenali karakteristik penyakit secara lebih akurat dan meningkatkan performa

klasifikasi secara keseluruhan. Proses transformasi pada citra daun menggunakan CLAHE dapat dilihat pada Gambar 4.2



Gambar 4. 2 Contoh Citra Daun setelah CLAHE

#### 4.3. Pemodelan Model Convolutional Neural Network (CNN) dengan ResNet-50

Pada penelitian ini, model Convolutional Neural Network (CNN) yang digunakan memanfaatkan arsitektur ResNet-50 sebagai backbone utama untuk proses ekstraksi fitur. ResNet-50 dipilih karena merupakan salah satu arsitektur deep convolutional neural network dengan struktur residual yang terbukti mampu mengatasi permasalahan vanishing gradient pada jaringan yang sangat dalam. Melalui penggunaan residual blocks, model dapat mempertahankan aliran gradien secara stabil selama proses pelatihan, sehingga memungkinkan pembelajaran representasi fitur yang lebih kompleks dan mendalam. Dalam notebook tersebut, ResNet-50 diinisialisasi dengan bobot pra-latih (pretrained) pada dataset ImageNet agar model memiliki kemampuan awal dalam mengenali pola-pola visual dasar sebelum dilakukan penyesuaian lebih lanjut terhadap domain citra penyakit daun jagung. Lapisan klasifikasi bawaan ResNet-50 kemudian dihilangkan dan digantikan dengan lapisan baru yang disesuaikan dengan jumlah kelas penyakit, sehingga pendekatan transfer learning dapat dilakukan secara efektif. proses pemodelan juga dilakukan dengan menggunakan arsitektur ResNet-50 sebagai transfer learning backbone dalam proses klasifikasi citra. Model ResNet-50 dipilih

karena memiliki kedalaman jaringan yang cukup besar dan telah terbukti menghasilkan representasi fitur yang kuat pada berbagai permasalahan klasifikasi citra. ResNet-50 cocok untuk penelitian ini karena kemampuannya menghasilkan representasi fitur yang tetap kuat bahkan pada citra yang tidak terstandar, seperti foto yang diambil dari kamera smartphone dengan pencahayaan natural yang bervariasi. Arsitektur ini secara alami lebih mampu menghadapi noise, variasi background, serta perbedaan orientasi daun, yang merupakan karakter umum dataset lapangan. Ketika dipadukan dengan modul CBAM, kemampuan model dalam memperhatikan bagian penting pada daun menjadi semakin baik sehingga performa klasifikasinya meningkat, khususnya untuk membedakan penyakit dengan pola visual mirip. Secara keseluruhan, karakteristik teknis ResNet-50, kemampuannya dalam feature representation, serta kecocokannya dengan kondisi dataset membuat arsitektur ini sangat layak digunakan dan mampu memberikan hasil yang lebih stabil serta akurat dibandingkan arsitektur yang lebih dangkal atau kurang matang.

Arsitektur ResNet-50 yang digunakan pada penelitian ini memanfaatkan bobot awal dari dataset ImageNet sebagai pengetahuan awal (pre-trained weights). Bagian fully connected layer pada model asli dihilangkan dengan mengatur parameter `include_top=False`, sehingga model dapat disesuaikan dengan jumlah kelas pada dataset yang digunakan. Setelah lapisan utama ResNet-50, ditambahkan blok CBAM (Convolutional Block Attention Module) yang berfungsi sebagai mekanisme perhatian (attention mechanism) untuk meningkatkan fokus model terhadap area penting pada citra. CBAM mengkombinasikan channel attention dan spatial attention, sehingga model mampu memperkuat fitur yang relevan dan

menekan fitur yang kurang signifikan. Selanjutnya, diterapkan Global Average Pooling (GAP) untuk mereduksi dimensi fitur tanpa kehilangan informasi penting yang telah diekstraksi oleh jaringan konvolusional.

Lapisan selanjutnya terdiri dari beberapa lapisan Dense dan Dropout yang berfungsi untuk meningkatkan kemampuan generalisasi model serta mengurangi risiko overfitting. Lapisan Batch Normalization juga ditambahkan di antara lapisan Dense untuk menstabilkan distribusi data selama proses pelatihan dan mempercepat konvergensi model. Lapisan akhir menggunakan fungsi aktivasi Softmax, yang menghasilkan probabilitas untuk setiap kelas berdasarkan jumlah total kelas yang digunakan dalam penelitian, yaitu empat kelas penyakit daun jagung.

Sebelum proses pelatihan, dilakukan tahap fine-tuning dengan membekukan sebagian besar lapisan awal ResNet-50 dan hanya melatih lapisan terakhir agar model dapat menyesuaikan bobotnya terhadap karakteristik data baru tanpa kehilangan pengetahuan umum yang telah dipelajari dari ImageNet. Model kemudian dikompilasi menggunakan optimizer Adam dengan learning rate kecil ( $1e-4$ ) dan loss function sparse categorical cross-entropy, serta metrik evaluasi accuracy. Selain itu, digunakan callback EarlyStopping untuk menghentikan pelatihan secara otomatis apabila validation loss tidak menunjukkan peningkatan setelah beberapa epoch, guna mencegah overfitting dan menjaga performa model tetap optimal.

#### **4.4. Penerapan Modul CBAM (Convolutional Block Attention Module)**

Penerapan Convolutional Block Attention Module (CBAM) pada penelitian ini bertujuan untuk meningkatkan kemampuan model ResNet-50 dalam mengekstraksi

fitur penting dari citra penyakit daun jagung. CBAM merupakan mekanisme attention ringan dan modular yang dapat dengan mudah diintegrasikan ke dalam arsitektur convolutional neural network (CNN) tanpa menambah beban komputasi yang signifikan. Secara umum, CBAM bekerja dengan menambahkan dua tahap perhatian, yaitu Channel Attention dan Spatial Attention, untuk memperkuat representasi fitur pada dua dimensi yang berbeda. Tahap pertama adalah Channel Attention Module, yang berfungsi untuk mengidentifikasi saluran (channel) fitur mana yang paling berkontribusi terhadap hasil klasifikasi. Modul ini menerima tensor fitur keluaran dari ResNet-50, kemudian melakukan operasi Global Average Pooling dan Global Max Pooling secara paralel untuk mengekstraksi konteks global dari tiap saluran. Kedua hasil pooling tersebut kemudian dilewatkan melalui shared multi-layer perceptron (MLP), dan hasilnya digabungkan menggunakan fungsi aktivasi sigmoid untuk menghasilkan channel attention map. Peta ini kemudian dikalikan secara elemen demi elemen dengan fitur masukan, sehingga saluran fitur yang lebih penting akan diberi bobot lebih besar. Tahap berikutnya adalah Spatial Attention Module, yang berfokus pada penentuan lokasi spasial (spatial location) dari fitur penting pada citra. Modul ini mengambil keluaran dari tahap channel attention dan melakukan average pooling serta max pooling di sepanjang dimensi saluran untuk menghasilkan dua peta fitur dua dimensi. Kedua peta ini kemudian digabungkan dan dilewatkan melalui convolution layer dengan kernel berukuran  $7 \times 7$  untuk menangkap informasi spasial dari area yang luas. Hasil akhirnya adalah spatial attention map yang juga dikalikan dengan fitur masukan, memungkinkan model untuk memusatkan perhatian pada area citra yang paling relevan, seperti bagian daun yang menunjukkan gejala penyakit.

Integrasi CBAM ke dalam ResNet-50 dilakukan dengan menempatkan blok ini setelah keluaran fitur utama dari backbone, sebelum proses Global Average Pooling. Dengan posisi tersebut, CBAM berperan menyaring dan menonjolkan fitur penting yang dihasilkan oleh lapisan konvolusional terdalam ResNet-50 sebelum fitur tersebut diringkas dan diteruskan ke lapisan fully connected. Pendekatan ini terbukti efektif dalam meningkatkan kemampuan model untuk membedakan pola-pola visual yang halus antar kelas penyakit, sehingga menghasilkan performa klasifikasi yang lebih baik dibandingkan model baseline tanpa mekanisme perhatian.

#### 4.5. Split Data

Pada tahap pemrosesan data, dataset dibagi menjadi tiga bagian menggunakan metode `train_test_split`, yaitu 70% data untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian. Selama proses pelatihan, diterapkan teknik augmentasi citra menggunakan `ImageDataGenerator` untuk meningkatkan keragaman data dan mencegah overfitting, dengan transformasi berupa rotasi hingga  $25^\circ$ , pergeseran horizontal dan vertikal sebesar 10%, shear sebesar 0.1, zoom hingga 0.2, serta pembalikan horizontal, sedangkan data validasi dan pengujian tidak diberikan augmentasi.

Tabel 4. 2 Pembagian Data

<b>Kelas</b>	<b>Jumlah</b>	<b>Presentase</b>
<i>Training</i>	2.932	70%
<i>Validation</i>	628	15%
<i>Testing</i>	628	15%
<b>Jumlah</b>	<b>4.188</b>	<b>100%</b>

Tabel 4.2 menunjukkan pembagian data yang digunakan dalam penelitian ini, yang terdiri dari tiga subset, yaitu data *training*, *validation*, dan *testing*. Dari total 4.188 data, sebanyak 2.932 data atau 70% digunakan untuk proses *training*, yaitu tahap pelatihan model agar mampu mengenali pola pada data. Selanjutnya, 628 data atau 15% dialokasikan untuk *validation*, yang berfungsi untuk menguji performa model selama proses pelatihan dan mencegah *overfitting*. Sisanya, 628 data atau 15% digunakan untuk *testing*, yaitu tahap evaluasi akhir guna menilai kemampuan model dalam melakukan prediksi terhadap data baru yang belum pernah dilihat sebelumnya. Pembagian ini dilakukan agar model yang dihasilkan memiliki kinerja yang optimal dan generalisasi yang baik. Pada kasus ini, *EarlyStopping* diatur dengan *patience=5*, artinya jika selama 5 epoch berturut-turut nilai *val\_loss* tidak membaik, pelatihan akan berhenti. Selain itu, opsi *restore\_best\_weights=True* memastikan bahwa setelah pelatihan dihentikan, model tidak menggunakan bobot dari epoch terakhir, tetapi dikembalikan ke bobot terbaik yang pernah dicapai selama pelatihan. Dengan demikian, *early stopping* berfungsi sebagai mekanisme perlindungan terhadap *overfitting* sekaligus menghemat waktu dan sumber daya

komputasi, sehingga model yang dihasilkan lebih optimal dan stabil pada data yang belum pernah dilihat sebelumnya.

#### 4.6. Skenario Penelitian

Rancangan skenario eksperimen yang terdiri dari 19 konfigurasi (S1–S19) untuk mengevaluasi kinerja model berbasis ResNet dengan berbagai variasi metode pra-proses dan arsitektur tambahan. Variasi utama yang diuji meliputi penggunaan CBAM (Convolutional Block Attention Module), teknik peningkatan kontras CLAHE (Contrast Limited Adaptive Histogram Equalization), serta kondisi tanpa CBAM dan/atau CLAHE. Kombinasi ini dirancang untuk menganalisis pengaruh masing-masing komponen dan integrasinya terhadap performa model, baik secara individual maupun gabungan, sehingga memungkinkan evaluasi yang komprehensif terhadap kontribusi setiap pendekatan dalam proses pembelajaran fitur.

Pada Tabel 4.3 juga memperlihatkan perbedaan parameter pelatihan berupa jenis optimizer (Adam dan SGD) serta nilai learning rate (0.01, 0.001, dan 0.0001). Pengaturan ini bertujuan untuk mengkaji stabilitas dan efektivitas proses optimasi pada setiap skenario eksperimen. Dengan memadukan variasi arsitektur, teknik pra-proses, dan parameter pelatihan, rancangan eksperimen ini memberikan kerangka evaluasi yang sistematis untuk menentukan konfigurasi optimal yang menghasilkan kinerja terbaik, sekaligus mendukung analisis perbandingan yang objektif dan terstruktur dalam penelitian.

Tabel 4. 3 Skenario Penelitian

No	Metode	Optimizer	Learning Rate
S1	ResNet-50 Tanpa CBAM dan CLAHE	Adam	0.001
S2	ResNet-50 Tanpa CBAM dan CLAHE	Adam	0.0001
S3	ResNet-50 Tanpa CBAM dan CLAHE	SGD	0.01
S4	ResNet-50 Tanpa CBAM dan CLAHE	SGD	0.001
S5	ResNet + CBAM	Adam	0.001
S6	ResNet + CBAM	Adam	0.0001
S7	ResNet + CBAM	SGD	0.01
S8	ResNet + CBAM	SGD	0.001
S9	ResNet + CLAHE	Adam	0.001
S10	ResNet + CLAHE	Adam	0.0001
S11	ResNet + CLAHE	SGD	0.01
S12	ResNet + CLAHE	SGD	0.001
S13	ResNet + CBAM + CLAHE	Adam	0.001
S14	ResNet + CBAM + CLAHE	Adam	0.0001
S15	ResNet + CBAM + CLAHE	SGD	0.01
S16	ResNet + CBAM + CLAHE	SGD	0.001

#### 4.7. Analisis Hasil Klasifikasi

Pada penelitian ini, proses identifikasi penyakit daun jagung dilakukan dengan penggunaan modul CBAM (Convolutional Block Attention Module) terhadap performa model ResNet-50 dalam proses klasifikasi citra. Pada skenario pertama, model ResNet-50 dimodifikasi dengan menambahkan modul CBAM dan menggunakan optimizer Adam dengan pengaturan learning rate tertentu untuk

mempercepat proses konvergensi dan meningkatkan stabilitas pembelajaran. Sedangkan pada skenario kedua, digunakan arsitektur dan modul yang sama, namun optimizer diganti menjadi Stochastic Gradient Descent (SGD). Selain itu penelitian ini juga menerapkan CLAHE pada tahap preprocessing untuk meningkatkan kualitas ciri yang ditangkap model. Analisis dilakukan pada citra daun jagung yang termasuk ke dalam empat kelas, yaitu Blight, Common Rust, Gray Leaf Spot, dan Healthy, dengan tujuan untuk mengevaluasi kinerja model dalam mengklasifikasikan jenis penyakit secara akurat. Penilaian hasil klasifikasi dilakukan dengan mengukur tingkat kemampuan model dalam mendeteksi dan membedakan setiap kelas berdasarkan confusion matrix serta metrik evaluasi yang meliputi accuracy, precision, recall, dan F1-Score. Setiap metrik memberikan gambaran menyeluruh mengenai kemampuan model, baik dari segi ketepatan prediksi total maupun konsistensi model dalam mengenali setiap kelas.

Confusion matrix dimanfaatkan untuk melihat pola prediksi model secara lebih rinci, terutama untuk mengetahui jumlah citra yang diklasifikasikan dengan benar (True Positive / True Negative) serta kesalahan klasifikasi (False Positive / False Negative) pada masing-masing kelas. Pada konteks klasifikasi penyakit daun jagung, True Positive (TP) menunjukkan jumlah citra daun yang terdeteksi dengan benar sesuai label penyakitnya. False Positive (FP) menggambarkan kondisi di mana model memprediksi suatu citra sebagai salah satu kelas penyakit, padahal label aslinya berbeda. Sedangkan False Negative (FN) menunjukkan kegagalan model dalam mengenali citra yang seharusnya termasuk dalam kelas tertentu. True Negative (TN) menunjukkan citra yang diprediksi benar sebagai kelas lain yang sesuai. Penggunaan metrik tersebut memberikan dasar untuk memahami kelebihan

dan keterbatasan model dalam mengenali gejala penyakit daun jagung. Misalnya, nilai precision menunjukkan seberapa akurat model dalam memberikan prediksi benar pada suatu kelas, sedangkan recall menggambarkan kemampuan model dalam menangkap seluruh data yang benar-benar termasuk kelas tersebut. Sementara itu, F1-Score menjadi ukuran keseimbangan kinerja antara precision dan recall.


Hasil analisis ini selanjutnya digunakan untuk membandingkan dua skenario pelatihan model, yaitu penggunaan modul CBAM (Convolutional Block Attention Module) terhadap performa model ResNet-50 dalam proses klasifikasi citra dengan optimizer Adam dan SGD serta pengaturan Learning Rate, sehingga dapat diperoleh pemahaman mengenai sejauh mana penambahan modul perhatian (attention mechanism) dan penerapan CLAHE pada citra dapat meningkatkan performa klasifikasi secara signifikan. Temuan tersebut menjadi dasar dalam menentukan model terbaik yang mampu mendeteksi penyakit daun jagung secara optimal, konsisten, dan akurat.

#### **4.7.1 Analisis Hasil Optimizer Adam ResNet-50 Tanpa CBAM dan CLAHE**

##### **a. Learning Rate $1e-3$**

Pada Gambar 4.3 menunjukkan perkembangan akurasi pelatihan (training) dan akurasi validasi (validation) terhadap jumlah epoch. Secara umum, akurasi pelatihan mengalami peningkatan yang signifikan pada epoch awal, dari sekitar 0,78 hingga mendekati 0,95, kemudian meningkat secara lebih stabil hingga mencapai nilai di atas 0,96 pada epoch akhir. Pola serupa juga terlihat pada akurasi validasi yang sejak awal berada pada nilai relatif tinggi (sekitar 0,91) dan cenderung meningkat seiring bertambahnya epoch, meskipun dengan beberapa fluktuasi kecil.

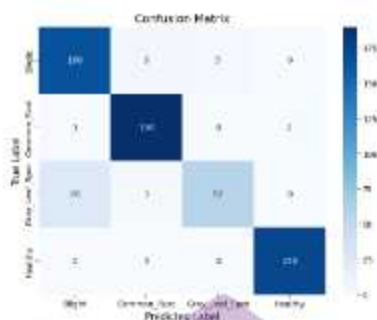
Kedekatan nilai akurasi antara data pelatihan dan data validasi menunjukkan bahwa model mampu melakukan generalisasi dengan baik dan tidak mengalami overfitting yang signifikan, karena tidak terdapat kesenjangan besar antara kedua kurva.



Gambar 4.3 Plot Akurasi dan Loss Optimizer Adam + Learning Rate  $1e-3$

Selanjutnya memperlihatkan perubahan nilai loss pada data pelatihan dan validasi selama proses pelatihan. Loss pelatihan menurun secara konsisten dari nilai awal yang cukup tinggi hingga mencapai nilai rendah pada epoch akhir, yang mengindikasikan bahwa model semakin optimal dalam meminimalkan kesalahan prediksi terhadap data latih. Sementara itu, loss validasi juga menunjukkan tren penurunan meskipun terdapat fluktuasi pada beberapa epoch, yang masih berada dalam batas wajar. Secara keseluruhan, penurunan loss pada kedua kurva, disertai dengan peningkatan akurasi, mengindikasikan bahwa proses pelatihan berjalan secara konvergen dan model memiliki performa yang stabil serta cukup baik dalam mempelajari pola data tanpa indikasi overfitting atau underfitting yang kuat.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4. 4 Plot Confusion Matrix Optimizer Adam + Learning Rate 1e-3

Pada Gambar 4.4 confusion matrix tersebut menggambarkan kinerja model klasifikasi empat kelas, yaitu Blight, Common\_Rust, Gray\_Leaf\_Spot, dan Healthy, dengan membandingkan label aktual dan label prediksi. Nilai diagonal utama menunjukkan jumlah prediksi yang benar untuk masing-masing kelas. Kelas Blight terklasifikasi dengan baik sebanyak 166 data, meskipun masih terdapat kesalahan prediksi ke kelas Common\_Rust (6 data) dan Gray\_Leaf\_Spot (5 data). Kelas Common\_Rust menunjukkan performa yang sangat baik dengan 190 data terklasifikasi benar, hanya sedikit kesalahan ke kelas Blight dan Healthy. Sementara itu, kelas Healthy berhasil diprediksi secara sempurna dengan seluruh 173 data berada pada diagonal utama, menunjukkan bahwa model sangat mampu mengenali pola kelas ini.

Namun demikian, kelas Gray\_Leaf\_Spot menunjukkan tingkat kesalahan klasifikasi yang relatif lebih tinggi dibandingkan kelas lainnya. Dari total data kelas ini, hanya 57 yang terklasifikasi dengan benar, sedangkan sebagian besar kesalahan terjadi karena data Gray\_Leaf\_Spot diprediksi sebagai Blight (26 data) dan Common\_Rust (3 data). Pola ini mengindikasikan adanya kemiripan karakteristik visual atau fitur antara kelas Gray\_Leaf\_Spot dengan dua kelas penyakit lainnya,

sehingga model mengalami kesulitan dalam membedakannya secara konsisten. Secara keseluruhan, confusion matrix ini menunjukkan bahwa model memiliki performa yang sangat baik pada kelas Healthy dan Common\_Rust, cukup baik pada kelas Blight, namun masih memerlukan peningkatan pada kemampuan diskriminasi terhadap kelas Gray\_Leaf\_Spot.

Selanjutnya dilakukan perhitungan manual akurasi, presisi, raacall, dan F1-score untuk mengetahui performa model secara keseluruhan.

#### 1. Akurasi

Menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan keseluruhan data uji. Nilai akurasi dihitung dengan menjumlahkan seluruh true positive dari setiap kelas, kemudian dibagi dengan total seluruh data pada confusion matrix.

$$Accuracy = \frac{166 + 190 + 57 + 173}{629} = \frac{586}{629} = 0.9316$$

#### 2. Presisi

Rasio antara jumlah true positive dengan jumlah true positive ditambahkan false positive. Precision menunjukkan seberapa tepat model dalam mengklasifikasikan suatu kelas dibandingkan dengan prediksi yang dibuat.

Nilai ini diambil untuk setiap kelas pada confusion matrix.

$$a) \text{ Blight} = \frac{166}{166+27} = 0.8601$$

$$b) \text{ Common\_Rust} = \frac{190}{190+9} = 0.9548$$

$$c) \text{ Grey Leaf Spot} = \frac{57}{57+5} = 0.9194$$

$$d) \text{ Healthy} = \frac{173}{173+2} = 0.9886$$

### 3. Recall

Recall adalah perbandingan antara jumlah true positive dengan jumlah true positive ditambahkan false negative. Recall mengukur kemampuan model dalam mengenali seluruh data aktual dari suatu kelas. Nilai recall juga dihitung untuk setiap kelas dari confusion matrix.

$$a) \text{Blight} = \frac{166}{166+11} = 0.9379$$

$$b) \text{Common\_Rust} = \frac{190}{190+3} = 0.9845$$

$$c) \text{Grey Leaf Spot} = \frac{57}{57+29} = 0.6628$$

$$d) \text{Healthy} = \frac{173}{173+0} = 1.000$$

### 4. F1-Score

Rata-rata harmonis dari precision dan recall. Nilai ini digunakan untuk menyeimbangkan antara ketepatan prediksi (precision) dan kelengkapan prediksi (recall), sehingga lebih objektif dalam menilai performa model, terutama pada data yang tidak seimbang.

Kelas Blight:

$$a) \text{PrecisionBlight} = \frac{166}{166+27} = 0.8601$$

$$b) \text{RecallBlight} = \frac{166}{166+11} = 0.9379$$

$$c) \text{F1Blight} = 2 \times \frac{0.8601}{0.8601} = 2 \times 0.4486 = 0.8972$$

Kelas Common Rust:

$$a) \text{PrecisionCR} = \frac{190}{190+9} = 0.9548$$

$$b) \text{RecallCR} = \frac{190}{190+3} = 0.9845$$

$$c) \text{F1CR} = 2 \times \frac{0.9399}{1.9393} = 0.9649$$

Kelas Grey Leaf Spot:

$$a) \text{ Precision}_{GLS} = \frac{57}{57+5} = 0.9194$$

$$b) \text{ Recall}_{GLS} = \frac{57}{57+29} = 0.6628$$

$$c) \text{ F1}_{GLS} = 2 \times \frac{0.6094}{1.5822} = 2 \times 0.3855 = 0.7710$$

Kelas Healthy:


$$a) \text{ Precision}_{HL} = \frac{173}{173+2} = 0.9886$$

$$b) \text{ Recall}_{HL} = \frac{173}{173+0} = 1.000$$

$$c) \text{ F1}_{HL} = 2 \times \frac{0.9886}{0.9886} = 0.9943$$

#### b. Learning Rate $1e-4$

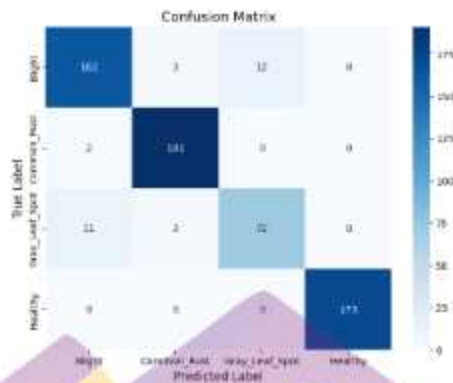
Pada Gambar 4.5 menampilkan kurva akurasi dan loss pada data pelatihan (train) dan validasi (validation) selama proses pelatihan model dalam beberapa epoch. Pada grafik akurasi (kiri), terlihat bahwa akurasi data pelatihan meningkat secara tajam pada epoch awal, kemudian berlanjut dengan kenaikan yang lebih gradual hingga mencapai nilai sekitar 0,95. Akurasi validasi sejak awal sudah berada pada nilai yang relatif tinggi dan cenderung stabil di kisaran 0,95–0,96 dengan fluktuasi kecil. Kedekatan antara kurva akurasi pelatihan dan validasi menunjukkan bahwa model mampu melakukan generalisasi dengan baik terhadap data yang tidak dilatih, serta tidak menunjukkan indikasi overfitting yang signifikan.



Gambar 4.5 Plot Akurasi dan Loss Optimizer Adam + Learning Rate  $1e-4$

Sementara itu, grafik loss (kanan) memperlihatkan penurunan loss yang konsisten baik pada data pelatihan maupun data validasi. Loss pelatihan turun drastis pada epoch awal, kemudian menurun secara bertahap hingga mendekati nilai minimum pada epoch akhir. Pola yang serupa juga terlihat pada loss validasi, meskipun dengan sedikit fluktuasi pada beberapa epoch, yang masih berada dalam batas wajar. Penurunan loss yang sejalan dengan peningkatan akurasi pada kedua dataset mengindikasikan bahwa proses optimasi berjalan secara konvergen dan stabil, serta model berhasil mempelajari representasi data secara efektif tanpa mengalami underfitting maupun overfitting yang kuat.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.6 Plot Confusion Matrix Optimizer Adam + Learning Rate 1e-4

Pada Gambar 4.6 memperlihatkan performa model klasifikasi dalam membedakan empat kelas penyakit daun jagung, yaitu Blight, Common Rust, Gray Leaf Spot, serta kelas Healthy. Diagonal utama matriks menunjukkan jumlah prediksi yang tepat untuk setiap kelas. Terlihat bahwa model memiliki tingkat akurasi tinggi pada kelas Common Rust (191 benar) dan Healthy (173 benar), yang menandakan bahwa fitur visual pada kedua kelas ini dapat dikenali dengan baik oleh model. Demikian pula pada kelas Blight, model berhasil mengklasifikasikan 162 citra dengan benar, meskipun masih terdapat sejumlah kecil kesalahan prediksi ke kelas lain.

Namun, kesalahan klasifikasi (off-diagonal) juga terlihat, terutama pada kelas Gray Leaf Spot, dengan 11 citra salah diklasifikasikan sebagai Blight dan 3 citra menjadi Common Rust. Hal ini menunjukkan adanya tumpang tindih fitur antar kelas penyakit yang memiliki pola visual serupa. Sementara itu, kelas Healthy tidak mengalami salah klasifikasi sama sekali, menunjukkan tingkat separabilitas fitur yang sangat baik untuk kelas tersebut. Secara keseluruhan, confusion matrix ini menegaskan bahwa model bekerja cukup efektif, namun masih terdapat ruang

peningkatan terutama pada pemisahan karakteristik antara penyakit daun yang memiliki kemiripan morfologis.

1. Selanjutnya dilakukan perhitungan manual akurasi, presisi, raacall, dan F1-score untuk mengetahui performa model secara keseluruhan. Akurasi Menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan keseluruhan data uji. Nilai akurasi dihitung dengan menjumlahkan seluruh true positive dari setiap kelas, kemudian dibagi dengan total seluruh data pada confusion matrix.

$$Accuracy = \frac{162 + 191 + 72 + 173}{629} = \frac{598}{629} = 0.951$$

2. Presisi

Rasio antara jumlah true positive dengan jumlah true positive ditambahkan false positive. Precision menunjukkan seberapa tepat model dalam mengklasifikasikan suatu kelas dibandingkan dengan prediksi yang dibuat. Nilai ini diambil untuk setiap kelas pada confusion matrix.

$$a) \text{ Blight} = \frac{162}{162+13} = 0.926$$

$$b) \text{ Common Rust} = \frac{191}{191+6} = 0.969$$

$$c) \text{ Grey Leaf Spot} = \frac{72}{72+14} = 0.857$$

$$d) \text{ Healthy} = \frac{173}{173+0} = 1.000$$

3. Recall

Recall adalah perbandingan antara jumlah true positive dengan jumlah true positive ditambahkan false negative. Recall mengukur kemampuan model dalam mengenali seluruh data aktual dari suatu kelas. Nilai recall juga dihitung untuk setiap kelas dari confusion matrix.

- a)  $Blight = \frac{162}{162+13} = 0.915$
- b)  $Common\_Rust = \frac{191}{191+2} = 0.990$
- c)  $Grey\ Leaf\ Spot = \frac{72}{72+14} = 0.837$
- d)  $Healthy = \frac{173}{173+0} = 1.000$

#### 4. F1-Score

Rata-rata harmonis dari precision dan recall. Nilai ini digunakan untuk menyeimbangkan antara ketepatan prediksi (precision) dan kelengkapan prediksi (recall), sehingga lebih objektif dalam menilai performa model, terutama pada data yang tidak seimbang.

Kelas Blight:

- a)  $PrecisionBlight = \frac{162}{162+13} = 0.9257$
- b)  $RecallBlight = \frac{162}{162+15} = 0.9153$
- c)  $F1Blight = 2 \times 0.8467 = 0.9201$

Kelas Common Rust:

- a)  $PrecisionCR = \frac{191}{191+6} = 0.9690$
- b)  $RecallCR = \frac{191}{191+2} = 0.9904$
- c)  $F1CR = 2 \times 0.9597 = 0.9795$

Kelas Grey Leaf Spot:

- a)  $PrecisionGLS = \frac{72}{72+12} = 0.8571$
- b)  $RecallGLS = \frac{72}{72+14} = 0.8372$
- c)  $F1GLS = 2 \times 0.7178 = 0.8471$

Kelas Healthy:

$$a) \text{ PrecisionHL} = \frac{173}{173+0} = 1.000$$


$$b) \text{ RecallHL} = \frac{173}{173+0} = 1.000$$

$$c) \text{ F1HL} = 2 \times \frac{1.000}{1.000} = 1.000$$

#### 4.7.2 Analisis Hasil Stochastic Gradient Descent (SGD) ResNet-50 Tanpa CBAM dan CLAHE

##### a. Learning Rate 1e-2

Pada Gambar 4.7 terlihat tren peningkatan performa model selama proses pelatihan. Kurva akurasi data latih meningkat secara konsisten dari sekitar 0,82 pada epoch awal menuju kisaran 0,93 pada epoch akhir. Sementara itu, akurasi data validasi menunjukkan nilai yang lebih tinggi dibandingkan akurasi data latih, stabil pada kisaran 0,93–0,95. Pola ini menunjukkan bahwa model berhasil mempelajari pola penting dari data, tanpa mengalami penurunan performa pada validasi. Stabilitas akurasi validasi juga mengindikasikan bahwa generalisasi model terhadap data yang belum pernah dilihat berada dalam kategori baik.

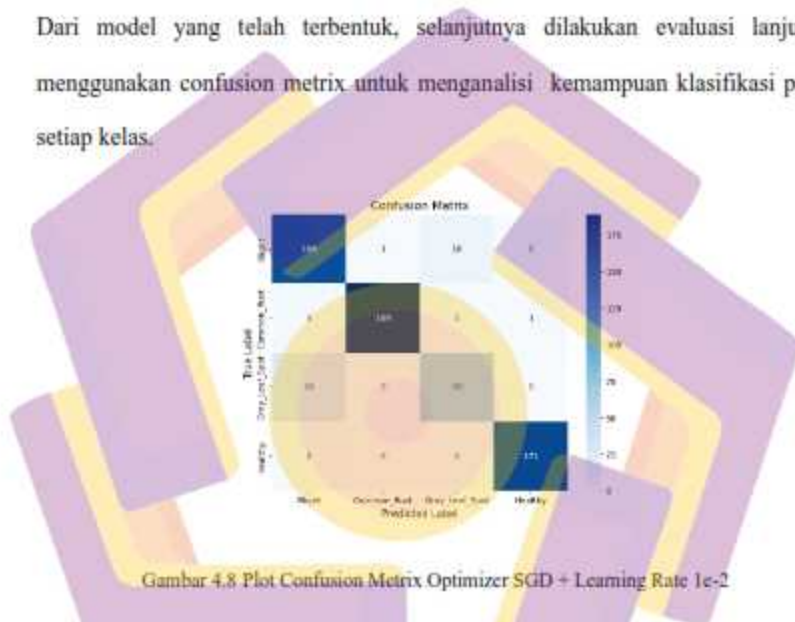


Gambar 4.7 Plot Akurasi dan Loss Optimizer SGD + Learning Rate 1e-2

Sedangkan pada grafik **loss**, terlihat penurunan signifikan pada epoch awal, terutama pada kurva data latih yang turun tajam dari sekitar 0,46 menjadi sekitar 0,20 setelah beberapa epoch. Loss validasi juga menunjukkan tren yang relatif stabil pada rentang 0,15–0,20 dengan sedikit fluktuasi. Pola penurunan loss yang paralel

antara data latih dan validasi menandakan bahwa model tidak mengalami overfitting secara berarti, karena loss validasi tidak naik meskipun model semakin dilatih. Secara keseluruhan, kedua grafik ini menggambarkan bahwa model konvergen dengan baik dan memiliki kemampuan generalisasi yang solid terhadap data klasifikasi penyakit daun jagung.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.8 Plot Confusion Matrix Optimizer SGD + Learning Rate  $1e-2$

Pada Gambar 4.8 menunjukkan performa model dalam mengklasifikasikan empat kelas penyakit daun jagung, yaitu Blight, Common Rust, Gray Leaf Spot, dan Healthy. Secara umum, model mampu mengidentifikasi setiap kelas dengan tingkat akurasi yang tinggi, terlihat pada nilai diagonal utama yang mewakili prediksi benar: 166 citra Blight, 189 citra Common Rust, 60 citra Gray Leaf Spot, dan 171 citra pada kelas Healthy. Hal ini mengindikasikan bahwa karakteristik visual untuk masing-masing kelas telah berhasil dipelajari dengan baik oleh model, terutama untuk kelas Common Rust dan Healthy yang hampir tidak memiliki salah

klasifikasi, membuktikan tingkat separabilitas fitur yang tinggi pada kedua kategori tersebut.

Namun demikian, model masih memperlihatkan sejumlah kesalahan klasifikasi yang perlu dicermati lebih lanjut. Kelas Gray Leaf Spot mengalami mis-klasifikasi yang relatif lebih tinggi, dengan 26 citra salah dikenali sebagai Blight, mengindikasikan adanya kemiripan pola visual antara bercak daun Gray Leaf Spot dan area bercak nekrotik pada Blight. Selain itu, beberapa sampel Blight diklasifikasikan menjadi Gray Leaf Spot (10 citra), dan sedikit jumlah pada kelas Healthy dan Common Rust juga menunjukkan tumpang tindih fitur meskipun dalam jumlah kecil. Secara keseluruhan, confusion matrix ini menunjukkan bahwa model bekerja efektif, namun peningkatan dapat dilakukan dengan perbaikan representasi fitur pada kelas yang memiliki kemiripan gejala visual.

Selanjutnya dilakukan perhitungan manual akurasi, presisi, recall, dan F1-score untuk mengetahui performa model secara keseluruhan.

1. Selanjutnya dilakukan perhitungan manual akurasi, presisi, recall, dan F1-score untuk mengetahui performa model secara keseluruhan. Akurasi Menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan keseluruhan data uji. Nilai akurasi dihitung dengan menjumlahkan seluruh true positive dari setiap kelas, kemudian dibagi dengan total seluruh data pada confusion matrix.

$$Accuracy = \frac{166 + 189 + 60 + 171}{629} = \frac{586}{629} = 0.9316$$

2. Presisi

Rasio antara jumlah true positive dengan jumlah true positive ditambahkan false positive. Precision menunjukkan seberapa tepat model dalam mengklasifikasikan suatu kelas dibandingkan dengan prediksi yang dibuat. Nilai ini diambil untuk setiap kelas pada confusion matrix.

$$a) \textit{Blight} = \frac{166}{166+31} = 0.8426$$

$$b) \textit{Common\_Rust} = \frac{189}{189+1} = 0.9947$$

$$c) \textit{Grey\_Leaf\_Spot} = \frac{60}{60+10} = 0.857$$

$$d) \textit{Healthy} = \frac{171}{171+1} = 0.9942$$

### 3. Recall

Recall adalah perbandingan antara jumlah true positive dengan jumlah true positive ditambahkan false negative. Recall mengukur kemampuan model dalam mengenali seluruh data aktual dari suatu kelas. Nilai recall juga dihitung untuk setiap kelas dari confusion matrix.

$$a) \textit{Blight} = \frac{166}{166+11} = 0.9384$$

$$b) \textit{Common\_Rust} = \frac{189}{189+1} = 0.9793$$

$$c) \textit{Grey\_Leaf\_Spot} = \frac{60}{60+26} = 0.6977$$

$$d) \textit{Healthy} = \frac{171}{171+0} = 1.000$$

### 4. F1-Score

Rata-rata harmonis dari precision dan recall. Nilai ini digunakan untuk menyeimbangkan antara ketepatan prediksi (precision) dan kelengkapan prediksi (recall), sehingga lebih objektif dalam menilai performa model, terutama pada data yang tidak seimbang.

Kelas Blight:

$$a) \text{ PrecisionBlight} = \frac{166}{166+29} = 0.8513$$

$$b) \text{ RecallBlight} = \frac{166}{166+11} = 0.9379$$

$$c) \text{ F1Blight} = 2 \times 0.4464 = 0.8928$$

Kelas Common Rust:

$$a) \text{ PrecisionCR} = \frac{189}{189+1} = 0.9947$$

$$b) \text{ RecallCR} = \frac{189}{189+4} = 0.9792$$

$$c) \text{ F1CR} = 2 \times 0.4936 = 0.9872$$

Kelas Grey Leaf Spot:

$$a) \text{ PrecisionGLS} = \frac{60}{60+10} = 0.8571$$

$$b) \text{ RecallGLS} = \frac{60}{60+26} = 0.6977$$

$$c) \text{ F1GLS} = 2 \times 0.3851 = 0.7702$$

Kelas Healthy:

$$a) \text{ PrecisionHL} = \frac{171}{171+0} = 1.000$$

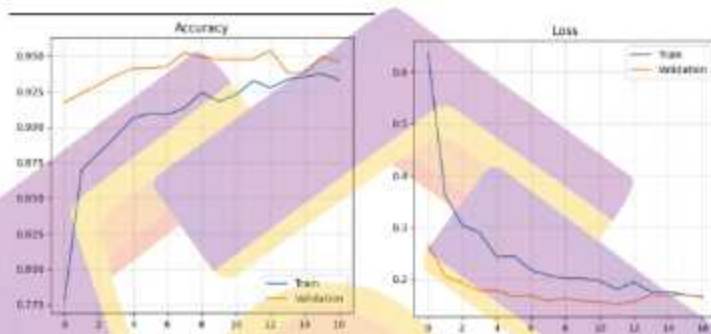
$$b) \text{ RecallHL} = \frac{171}{171+2} = 0.9884$$

$$c) \text{ F1HL} = 2 \times 0.4971 = 0.9942$$

b. Learning Rate 1e-3

Pada Gambar 4.9 menampilkan kurva akurasi pelatihan (*training accuracy*) dan akurasi validasi (*validation accuracy*) terhadap jumlah epoch. Terlihat bahwa akurasi pelatihan meningkat secara signifikan pada epoch awal, dari sekitar 77% hingga melampaui 90%, kemudian mengalami kenaikan yang lebih stabil hingga mencapai kisaran 93–94% pada epoch akhir. Pola serupa juga ditunjukkan oleh


akurasi validasi yang sejak awal sudah relatif tinggi (sekitar 91–92%) dan terus meningkat hingga mencapai puncak mendekati 95%. Perbedaan antara akurasi pelatihan dan validasi relatif kecil di hampir seluruh epoch, yang mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik serta tidak menunjukkan gejala *overfitting* yang signifikan.



Gambar 4.9 Plot Akurasi dan Loss Optimizer SGD + Learning Rate  $1e-3$

Gambar kedua menunjukkan kurva loss pelatihan dan loss validasi selama proses pelatihan. Nilai training loss menurun tajam pada beberapa epoch awal, kemudian berangsur menurun secara lebih landai hingga mendekati nilai konvergen di akhir pelatihan. Sementara itu, validation loss juga mengalami penurunan yang konsisten dan cenderung stabil pada nilai yang sedikit lebih rendah dibandingkan training loss. Kondisi ini mencerminkan proses optimasi yang berjalan efektif, di mana model mampu meminimalkan kesalahan baik pada data pelatihan maupun data validasi. Secara keseluruhan, tren penurunan loss yang sejalan dengan peningkatan akurasi menunjukkan bahwa model telah mencapai konvergensi yang baik dan performanya stabil.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.10 Plot Confusion Matrix Optimizer SGD + Learning Rate  $1e-3$

Pada Gambar 4.10 menampilkan confusion matrix yang menggambarkan kinerja model klasifikasi dalam membedakan empat kelas, yaitu Blight, Common\_Rust, Gray\_Leaf\_Spot, dan Healthy. Nilai pada diagonal utama menunjukkan jumlah prediksi yang benar untuk setiap kelas. Terlihat bahwa model mampu mengklasifikasikan data dengan sangat baik pada kelas Common\_Rust (190 data benar) dan Healthy (172 data benar), serta cukup tinggi pada kelas Blight (168 data benar). Hal ini mengindikasikan bahwa model memiliki kemampuan diskriminasi yang kuat terhadap karakteristik visual dari masing-masing kelas tersebut, khususnya untuk penyakit Common\_Rust dan kondisi daun Healthy.

Namun demikian, masih terdapat beberapa kesalahan klasifikasi yang terlihat pada nilai di luar diagonal. Kesalahan paling menonjol terjadi pada kelas Gray\_Leaf\_Spot, di mana sebagian data salah diprediksi sebagai Blight (24 sampel). Hal ini menunjukkan adanya kemiripan fitur antara kedua kelas tersebut

yang berpotensi menyebabkan ambiguitas bagi model. Meskipun demikian, jumlah kesalahan secara keseluruhan relatif kecil dibandingkan prediksi yang benar, sehingga dapat disimpulkan bahwa model memiliki tingkat akurasi dan keandalan yang tinggi. Pola ini memperkuat hasil evaluasi sebelumnya bahwa model tidak hanya baik dalam pelatihan, tetapi juga konsisten dalam melakukan klasifikasi pada data uji.

Selanjutnya dilakukan perhitungan manual akurasi, presisi, raacall, dan F1-score untuk mengetahui performa model secara keseluruhan.

1. Selanjutnya dilakukan perhitungan manual akurasi, presisi, raacall, dan F1-score untuk mengetahui performa model secara keseluruhan. Akurasi Menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan keseluruhan data uji. Nilai akurasi dihitung dengan menjumlahkan seluruh true positive dari setiap kelas, kemudian dibagi dengan total seluruh data pada confusion matrix.

$$Accuracy = \frac{168 + 190 + 60 + 172}{629} = \frac{590}{629} = 0.9379$$

2. Presisi

Rasio antara jumlah true positive dengan jumlah true positive ditambahkan false positive. Precision menunjukkan seberapa tepat model dalam mengklasifikasikan suatu kelas dibandingkan dengan prediksi yang dibuat. Nilai ini diambil untuk setiap kelas pada confusion matrix.

$$a) \text{ Blight} = \frac{168}{168+26} = 0.866$$

$$b) \text{ Common\_Rust} = \frac{190}{190+4} = 0.979$$

$$c) \text{ Grey Leaf Spot} = \frac{60}{60+8} = 0.882$$

$$d) \text{ Healthy} = \frac{172}{172+1} = 0.994$$

### 3. Recall

Recall adalah perbandingan antara jumlah true positive dengan jumlah true positive ditambahkan false negative. Recall mengukur kemampuan model dalam mengenali seluruh data aktual dari suatu kelas. Nilai recall juga dihitung untuk setiap kelas dari confusion matrix.

$$a) \text{ Blight} = \frac{169}{169+26} = 0.866$$

$$b) \text{ Common\_Rust} = \frac{190}{190+3} = 0.984$$

$$c) \text{ Grey Leaf Spot} = \frac{60}{60+26} = 0.698$$

$$d) \text{ Healthy} = \frac{172}{172+1} = 0.994$$

### 4. F1-Score

Rata-rata harmonis dari precision dan recall. Nilai ini digunakan untuk menyeimbangkan antara ketepatan prediksi (precision) dan kelengkapan prediksi (recall), sehingga lebih objektif dalam menilai performa model, terutama pada data yang tidak seimbang.

Kelas Blight:

$$a) \text{ PrecisionBlight} = \frac{169}{169+26} = 0.8660$$

$$b) \text{ RecallBlight} = \frac{169}{169+9} = 0.9492$$

$$c) \text{ F1Blight} = 2 \times 0.4105 = 0.9050$$

Kelas Common Rust:

$$a) \text{ PrecisionCR} = \frac{190}{190+4} = 0.9794$$

$$b) \text{ RecallCR} = \frac{190}{190+3} = 0.9845$$

$$c) F1CR = 2 \times 0.4910 = 0.9820$$

Kelas Grey Leaf Spot:

$$a) Precision_{GLS} = \frac{60}{60+8} = 0.8824$$

$$b) Recall_{GLS} = \frac{60}{60+26} = 0.6977$$

$$c) F1_{GLS} = 2 \times 0.3897 = 0.7794$$

Kelas Healthy:

$$a) Precision_{HL} = \frac{172}{172+1} = 0.9942$$


$$b) Recall_{HL} = \frac{172}{172+1} = 0.9942$$

$$c) F1_{HL} = 2 \times 0.4971 = 0.9942$$

#### 4.7.3 Analisis Hasil Optimizer Adam ResNet-50 + CBAM

##### a. Learning Rate 1e-3

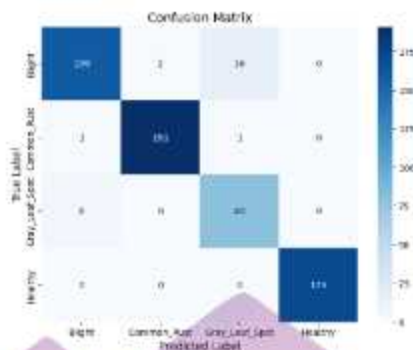
Skenario Pertama pada penelitian ini menerapkan model ResNet-50 dimodifikasi dengan menambahkan modul CBAM dan menggunakan optimizer Adam dengan Learning Rate 0,001 dengan pengaturan learning rate tertentu untuk mempercepat proses konvergensi dan meningkatkan stabilitas pembelajaran



Gambar 4.11 Plot Akurasi dan Loss Optimizer Adam + Learning Rate 1e-3

Pada Gambar 4.11 menunjukkan grafik pertama (Loss Over Epochs), terlihat bahwa nilai *train loss* (garis merah) dan *validation loss* (garis hijau) sama-sama menurun seiring bertambahnya jumlah *epoch*. Hal ini menunjukkan bahwa model semakin mampu meminimalkan kesalahan dalam memprediksi data, baik pada data pelatihan maupun data validasi. Pada awal pelatihan, nilai *loss* cukup tinggi, namun secara bertahap menurun dengan cepat hingga stabil di nilai rendah sekitar *epoch* ke-20 hingga akhir. Perbedaan kecil antara *train loss* dan *validation loss* di akhir pelatihan menandakan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting* yang signifikan. Sementara itu, grafik kedua (Accuracy Over Epochs) menggambarkan peningkatan akurasi model selama pelatihan. Garis biru menunjukkan *train accuracy*, sedangkan garis oranye menunjukkan *validation accuracy*. Keduanya meningkat secara konsisten hingga mencapai kisaran di atas 95%, yang menandakan bahwa model berhasil mempelajari pola data dengan baik. Meski terdapat sedikit fluktuasi pada *validation accuracy*, terutama setelah *epoch* ke-20, tren keseluruhan menunjukkan kestabilan dan performa tinggi. Perbedaan yang tidak terlalu besar antara akurasi pelatihan dan validasi juga memperkuat indikasi bahwa model tidak mengalami *overfitting* dan memiliki performa yang seimbang antara data pelatihan dan data validasi.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.12 Plot Confusion Matrix Optimizer Adam + Learning Rate 1e-3

Pada Gambar 4.12 menunjukkan confusion matrix yang menggambarkan performa model dalam mengklasifikasikan empat kategori daun jagung, yaitu *Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*. Matriks ini memperlihatkan perbandingan antara label sebenarnya (*true label*) dan label hasil prediksi model (*predicted label*). Dari hasil yang ditunjukkan, model memiliki performa klasifikasi yang sangat baik secara keseluruhan. Terlihat bahwa sebagian besar data berada pada diagonal utama (dari kiri atas ke kanan bawah), yang menandakan banyak prediksi benar. Misalnya, dari total sampel kelas *Common Rust*, sebanyak 191 gambar diklasifikasikan dengan benar, hanya satu yang salah. Kelas *Healthy* juga diprediksi sempurna dengan 173 prediksi benar dan tanpa kesalahan. Untuk kelas *Blight*, terdapat 159 prediksi benar, namun masih ada 16 kasus yang keliru diklasifikasikan sebagai *Gray Leaf Spot* dan 2 kasus yang salah sebagai *Common Rust*. Sementara itu, kelas *Gray Leaf Spot* memiliki 80 prediksi benar, namun terdapat 6 kasus yang salah diprediksi sebagai *Blight*. Secara keseluruhan, confusion matrix ini menunjukkan bahwa model memiliki tingkat akurasi tinggi dengan kesalahan klasifikasi yang relatif kecil. Kesalahan yang muncul umumnya terjadi

antara kelas penyakit daun yang memiliki kemiripan visual, seperti antara *Blight* dan *Gray Leaf Spot*, yang sering kali sulit dibedakan bahkan secara manual.

Selanjutnya dilakukan perhitungan manual akurasi, presisi, recall, dan F1-score untuk mengetahui performa model secara keseluruhan.

### 1. Akurasi

Menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan keseluruhan data uji. Nilai akurasi dihitung dengan menjumlahkan seluruh true positive dari setiap kelas, kemudian dibagi dengan total seluruh data pada confusion matrix.

$$Accuracy = \frac{159 + 191 + 80 + 173}{629} = \frac{603}{629} = 0.9587 \approx 95.87\%$$

### 2. Presisi

Rasio antara jumlah true positive dengan jumlah true positive ditambahkan false positive. Precision menunjukkan seberapa tepat model dalam mengklasifikasikan suatu kelas dibandingkan dengan prediksi yang dibuat. Nilai ini diambil untuk setiap kelas pada confusion matrix.

$$a) \text{ Blight} = \frac{159}{159+7} = 0.9578$$

$$b) \text{ Common Rust} = \frac{191}{191+2} = 0.9896$$

$$c) \text{ Grey Leaf Spot} = \frac{80}{80+17} = 0.8247$$

$$d) \text{ Healthy} = \frac{173}{173+0} = 1.0000$$

### 3. Recall

Recall adalah perbandingan antara jumlah true positive dengan jumlah true positive ditambahkan false negative. Recall mengukur kemampuan model

dalam mengenali seluruh data aktual dari suatu kelas. Nilai recall juga dihitung untuk setiap kelas dari confusion matrix.

$$a) \text{Blight} = \frac{159}{159+18} = 0.8983$$

$$b) \text{Common\_Rust} = \frac{191}{191+2} = 0.9896$$

$$c) \text{Grey Leaf Spot} = \frac{80}{80+6} = 0.9302$$

$$d) \text{Healthy} = \frac{173}{173+0} = 1.000$$

#### 4. F1-Score

Rata-rata harmonis dari precision dan recall. Nilai ini digunakan untuk menyeimbangkan antara ketepatan prediksi (precision) dan kelengkapan prediksi (recall), sehingga lebih objektif dalam menilai performa model, terutama pada data yang tidak seimbang.

Kelas Blight:

$$a) \text{PrecisionBlight} = \frac{159}{159+7} = 0.9578$$

$$b) \text{RecallBlight} = \frac{159}{159+18} = 0.8983$$

$$c) \text{F1Blight} = 2 \times \frac{0.8601}{1.8561} = 2 \times 0.4637 = 0.9274 \approx 0.927$$

Kelas Common Rust:

$$d) \text{PrecisionCR} = \frac{191}{191+2} = 0.9896$$

$$e) \text{RecallCR} = \frac{191}{191+2} = 0.9896$$

$$f) \text{F1CR} = 2 \times \frac{0.9793}{1.9792} = 0.9896$$

Kelas Grey Leaf Spot:

$$d) \text{PrecisionGLS} = \frac{80}{80+17} = 0.8247$$

$$e) \text{ Recall}_{GLS} = \frac{80}{80+6} = 0.9302$$

$$f) \text{ F1}_{GLS} = 2 \times \frac{0.7671}{1.7549} = 2 \times 0.4372 = 0.8744$$

Kelas Healthy:


$$d) \text{ Precission}_{HL} = \frac{173}{173+0} = 1.000$$

$$e) \text{ Recall}_{HL} = \frac{173}{173+0} = 1.000$$

$$f) \text{ F1}_{HL} = 2 \times \frac{1.0 \times 1.0}{1.0+1.0} = 2 \times \frac{1.0}{2.0} = 1.000$$

#### b. Learning Rate 1e-4

Skenario Pertama pada penelitian ini menerapkan model ResNet-50 dimodifikasi dengan menambahkan modul CBAM dan menggunakan optimizer Adam dengan Learning Rate 0,0001 dengan pengaturan learning rate tertentu untuk mempercepat proses konvergensi dan meningkatkan stabilitas pembelajaran




Gambar 4. 13 Plot Akurasi dan Loss Optimizer Adam + Learning Rate 1e-4

Pada Gambar 4.13 menunjukkan grafik akurasi dan loss selama proses pelatihan model menggunakan arsitektur ResNet-50 dengan penambahan modul CBAM serta optimizer Adam. Pada grafik akurasi, terlihat bahwa nilai train accuracy dan validation accuracy sama-sama meningkat tajam pada awal epoch, kemudian stabil

setelah sekitar epoch ke-10. Nilai akurasi pelatihan mencapai hampir 0,99, sedangkan akurasi validasi stabil di kisaran 0,95 hingga 0,97, yang menunjukkan bahwa model mampu mempelajari pola data dengan baik serta memiliki kemampuan generalisasi yang cukup tinggi tanpa menunjukkan tanda overfitting yang signifikan.

Sementara itu, grafik loss memperlihatkan bahwa nilai train loss dan validation loss sama-sama mengalami penurunan seiring bertambahnya epoch. Nilai loss awal yang tinggi (sekitar 2,0) menurun secara konsisten hingga mencapai di bawah 0,8 pada data validasi, menandakan bahwa kesalahan prediksi model semakin kecil. Meskipun terdapat sedikit fluktuasi pada validation loss di beberapa titik, tren keseluruhan menunjukkan bahwa proses pelatihan berlangsung stabil dan model berhasil mencapai konvergensi dengan baik. Secara keseluruhan, kedua grafik ini menggambarkan bahwa penggunaan optimizer Adam mampu menghasilkan proses pembelajaran yang efektif, stabil, dan akurat.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas



Gambar 4.14 Plot Confusion Matrix Optimizer Adam + Learning Rate 1e-4

Pada Gambar 4.14 menunjukkan hasil evaluasi kinerja model klasifikasi penyakit daun jagung yang terdiri dari empat kelas, yaitu Blight, Common Rust, Gray Leaf Spot, dan Healthy. Berdasarkan matriks tersebut, dapat dilihat bahwa model memiliki tingkat ketepatan prediksi yang tinggi pada hampir semua kelas. Kelas Blight berhasil dikenali dengan sangat baik, dengan 167 citra terklasifikasi benar dan hanya sedikit kesalahan pada kelas *Common Rust* dan *Gray Leaf Spot*. Kelas *Common Rust* menunjukkan performa terbaik dengan 189 prediksi benar dan hanya 4 kesalahan klasifikasi ke kelas *Blight*. Untuk kelas *Gray Leaf Spot*, model mampu mengklasifikasikan 73 citra dengan benar, meskipun masih terdapat beberapa kesalahan ke kelas *Blight* dan *Common Rust*. Sementara itu, kelas *Healthy* hampir sempurna dengan 172 prediksi benar dan hanya satu kesalahan klasifikasi. Secara keseluruhan, hasil confusion matrix ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan mampu membedakan antar kelas penyakit daun jagung dengan akurasi yang tinggi.

Selanjutnya dilakukan perhitungan manual akurasi, presisi, recall, dan F1-score untuk mengetahui performa model secara keseluruhan.

#### 1. Akurasi

Menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan keseluruhan data uji. Nilai akurasi dihitung dengan menjumlahkan seluruh true positive dari setiap kelas, kemudian dibagi dengan total seluruh data pada confusion matrix.

$$Accuracy = \frac{167 + 189 + 73 + 172}{629} = \frac{601}{629} = 0.955 \approx 95.5\%$$

#### 2. Presisi

Rasio antara jumlah true positive dengan jumlah true positive ditambahkan false positive. Precision menunjukkan seberapa tepat model dalam mengklasifikasikan suatu kelas dibandingkan dengan prediksi yang dibuat. Nilai ini diambil untuk setiap kelas pada confusion matrix.

$$a) \text{ Blight} = \frac{167}{167+16} = 0.912$$

$$b) \text{ Common\_Rust} = \frac{189}{189+3} = 0.984$$

$$c) \text{ Grey Leaf Spot} = \frac{73}{73+9} = 0.890$$

$$d) \text{ Healthy} = \frac{172}{172+0} = 1.0000$$

### 3. Recall

Recall adalah perbandingan antara jumlah true positive dengan jumlah true positive ditambahkan false negative. Recall mengukur kemampuan model dalam mengenali seluruh data aktual dari suatu kelas. Nilai recall juga dihitung untuk setiap kelas dari confusion matrix.

$$a) \text{ Blight} = \frac{167}{167+10} = 0.944$$

$$b) \text{ Common\_Rust} = \frac{189}{189+4} = 0.979$$

$$c) \text{ Grey Leaf Spot} = \frac{73}{73+13} = 0.848$$

$$d) \text{ Healthy} = \frac{172}{172+1} = 1.000$$

### 4. F1-Score

Rata-rata harmonis dari precision dan recall. Nilai ini digunakan untuk menyeimbangkan antara ketepatan prediksi (precision) dan kelengkapan prediksi (recall), sehingga lebih objektif dalam menilai performa model, terutama pada data yang tidak seimbang.

Kelas Blight:

$$F1_{Blight} = \frac{2 \times (0.912 \times 0.944)}{0.984 + 0.944} = 0.928$$

Kelas Common Rust:

$$F1_{CR} = \frac{2 \times (0.984 \times 0.979)}{0.984 + 0.979} = 0.981$$

Kelas Grey Leaf Spot:

$$F1_{GLS} = \frac{2 \times (0.890 \times 0.848)}{0.890 + 0.848} = 0.868$$


Kelas Healthy:

$$F1_{Hl} = \frac{2 \times (1.000 \times 0.994)}{1.000 + 0.994} = 0.997$$

#### 4.7.4 Analisis Hasil Stochastic Gradient Descent (SGD) ResNet-50 + CBAM

##### a. Learning Rate $1e-3$

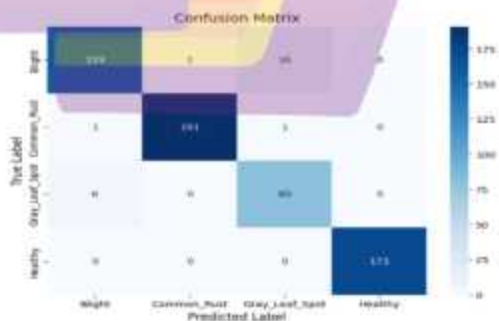
Skenario kedua pada penelitian ini menerapkan model ResNet-50 dimodifikasi dengan menambahkan modul CBAM dan menggunakan optimizer Stochastic Gradient Descent (SGD) dengan pengaturan learning rate 0.001 tertentu untuk mempercepat proses konvergensi dan meningkatkan stabilitas pembelajaran.



Gambar 4.15 Plot Akurasi dan Loss Optimizer SGD + Learning Rate  $1e-3$

Pada Gambar 4.15 menunjukkan hasil pelatihan model berupa grafik akurasi dan loss terhadap jumlah epoch. Pada grafik akurasi, terlihat bahwa nilai akurasi pelatihan (train accuracy) meningkat tajam sejak awal hingga mencapai sekitar 0,98, sedangkan akurasi validasi (validation accuracy) juga mengalami peningkatan signifikan dan stabil di kisaran 0,95. Pola ini menunjukkan bahwa model mampu mempelajari pola data dengan baik serta memiliki kemampuan generalisasi yang cukup baik karena perbedaan antara akurasi pelatihan dan validasi tidak terlalu besar. Sementara itu, pada grafik loss terlihat bahwa train loss menurun drastis dari sekitar 1,5 hingga di bawah 0,1, dan validation loss juga menurun hingga sekitar 0,2 meskipun mengalami sedikit fluktuasi pada beberapa epoch. Secara keseluruhan, kedua grafik ini memperlihatkan bahwa proses pelatihan model berlangsung efektif, model mencapai konvergensi dengan stabil, serta mampu menjaga keseimbangan antara penurunan kesalahan prediksi pada data latih dan kinerja pada data validasi.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.16. Plot Confusion Matrix Optimizer SGD + Learning Rate 1e-3

Pada Gambar 4.16 menunjukkan confusion matrix hasil evaluasi model klasifikasi penyakit daun jagung menggunakan empat kelas, yaitu *Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*. Berdasarkan matriks tersebut, model menunjukkan performa yang sangat baik dengan sebagian besar data berhasil diklasifikasikan dengan benar. Kelas *Blight* memiliki 159 prediksi benar dari total sampelnya, dengan sedikit kesalahan klasifikasi ke kelas *Common Rust* (2 sampel) dan *Gray Leaf Spot* (16 sampel). Kelas *Common Rust* menunjukkan akurasi yang sangat tinggi dengan 191 prediksi benar dan hanya satu kesalahan untuk masing-masing kelas lain. Sementara itu, kelas *Gray Leaf Spot* terdeteksi dengan 80 prediksi benar, namun masih terdapat kesalahan kecil terhadap kelas *Blight* sebanyak 6 sampel. Adapun kelas *Healthy* menunjukkan performa sempurna dengan seluruh 173 sampel diklasifikasikan dengan benar tanpa kesalahan. Secara keseluruhan, hasil confusion matrix ini memperlihatkan bahwa model memiliki tingkat akurasi dan kemampuan generalisasi yang sangat baik dalam mengenali setiap kategori citra daun jagung.

Selanjutnya dilakukan perhitungan manual akurasi, presisi, recall, dan F1-score untuk mengetahui performa model secara keseluruhan.

#### 1. Akurasi

Menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan keseluruhan data uji. Nilai akurasi dihitung dengan menjumlahkan seluruh true positive dari setiap kelas, kemudian dibagi dengan total seluruh data pada confusion matrix.

$$Accuracy = \frac{159 + 191 + 80 + 173}{629} = \frac{603}{629} = 0.959 \approx 95.9\%$$

## 2. Presisi

Rasio antara jumlah true positive dengan jumlah true positive ditambahkan false positive. Precision menunjukkan seberapa tepat model dalam mengklasifikasikan suatu kelas dibandingkan dengan prediksi yang dibuat. Nilai ini diambil untuk setiap kelas pada confusion matrix.

$$a) \text{ Blight} = \frac{159}{159+7} = 0.957$$

$$b) \text{ Common\_Rust} = \frac{191}{191+2} = 0.990$$

$$c) \text{ Grey Leaf Spot} = \frac{80}{80+17} = 0.825$$

$$d) \text{ Healthy} = \frac{173}{173+0} = 1.000$$

## 3. Recall

Recall adalah perbandingan antara jumlah true positive dengan jumlah true positive ditambahkan false negative. Recall mengukur kemampuan model dalam mengenali seluruh data aktual dari suatu kelas. Nilai recall juga dihitung untuk setiap kelas dari confusion matrix.

$$a) \text{ Blight} = \frac{159}{159+18} = 0.898$$

$$b) \text{ Common\_Rust} = \frac{191}{191+2} = 0.990$$

$$c) \text{ Grey Leaf Spot} = \frac{80}{80+6} = 0.930$$

$$d) \text{ Healthy} = \frac{173}{173+0} = 1.0000$$

## 4. F1-Score

Rata-rata harmonis dari precision dan recall. Nilai ini digunakan untuk menyeimbangkan antara ketepatan prediksi (precision) dan kelengkapan

prediksi (recall), sehingga lebih objektif dalam menilai performa model, terutama pada data yang tidak seimbang.

Kelas Blight:

$$F1_{Blight} = \frac{2 \times (0.957 \times 0.898)}{0.957 + 0.898} = 0.926$$

Kelas Common Rust:

$$F1_{CR} = \frac{2 \times (0.990 \times 0.990)}{0.990 + 0.990} = 0.990$$

Kelas Grey Leaf Spot:


$$F1_{GLS} = \frac{2 \times (0.825 \times 0.930)}{0.825 + 0.930} = 0.874$$

Kelas Healthy:

$$F1_{HI} = \frac{2 \times (1.000 \times 1.000)}{1.000 + 1.000} = 1.000$$

#### b. Learning Rate 1e-2

Skenario kedua pada penelitian ini menerapkan model ResNet-50 dimodifikasi dengan menambahkan modul CBAM dan menggunakan optimizer Stochastic Gradient Descent (SGD) dengan pengaturan learning rate 0.01 tertentu untuk mempercepat proses konvergensi dan meningkatkan stabilitas pembelajaran.




Gambar 4.17 Plot Akurasi dan Loss Optimizer SGD + Learning Ratae 1e-2

Pada Gambar 4.17 menunjukkan grafik akurasi model selama proses pelatihan (Accuracy Over Epochs). Garis berwarna biru menggambarkan akurasi data pelatihan (train accuracy), sedangkan garis oranye menunjukkan akurasi data validasi (validation accuracy). Pada awal pelatihan, akurasi model masih rendah namun meningkat dengan cepat hingga sekitar epoch ke-10. Setelah itu, akurasi pelatihan terus meningkat secara stabil dan mencapai hampir 100%, sementara akurasi validasi juga meningkat tetapi cenderung berfluktuasi di sekitar 96%. Pola ini menunjukkan bahwa model belajar dengan baik dan memiliki kemampuan generalisasi yang cukup baik, meskipun terdapat sedikit perbedaan antara akurasi pelatihan dan validasi yang menandakan potensi overfitting ringan.

Gambar kedua memperlihatkan grafik loss model selama pelatihan (Loss Over Epochs). Garis merah menggambarkan loss data pelatihan (train loss), sedangkan garis hijau menunjukkan loss data validasi (validation loss). Pada awal pelatihan, kedua nilai loss sangat tinggi, namun keduanya menurun tajam seiring bertambahnya epoch. Loss pelatihan terus menurun secara konsisten hingga mendekati nilai minimum sekitar 0.25, sedangkan loss validasi juga menurun meskipun lebih berfluktuasi di kisaran 0.5. Tren ini menegaskan bahwa model berhasil mempelajari pola data dengan baik, namun selisih kecil antara loss pelatihan dan validasi menunjukkan adanya sedikit perbedaan kemampuan model antara data pelatihan dan data baru, yang masih dalam batas wajar.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.18 Plot Confusion Matrix Optimizer SGD + Learning Rate 1e-2

Gambar 4.18 menunjukkan Confusion Matrix yang digunakan untuk mengevaluasi kinerja model klasifikasi penyakit daun jagung yang terdiri dari empat kelas, yaitu *Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*. Berdasarkan matriks tersebut, model berhasil mengklasifikasikan sebagian besar citra dengan benar. Kelas *Blight* memiliki 168 citra yang terklasifikasi dengan benar, dengan sedikit kesalahan pada kelas *Common Rust* (4 citra) dan *Gray Leaf Spot* (5 citra). Kelas *Common Rust* menunjukkan performa sangat baik dengan 190 citra terklasifikasi benar dan hanya 3 citra yang salah ke kelas *Blight*. Sementara itu, kelas *Gray Leaf Spot* memiliki 73 prediksi benar, namun terdapat kesalahan klasifikasi sebanyak 12 citra ke kelas *Blight* dan 1 citra ke kelas *Common Rust*. Untuk kelas *Healthy*, model menunjukkan hasil sempurna dengan 173 citra terklasifikasi benar tanpa kesalahan. Secara keseluruhan, confusion matrix ini memperlihatkan bahwa model memiliki akurasi tinggi, terutama dalam mengenali kelas *Common Rust* dan *Healthy*, dengan sedikit kesalahan pada kelas *Gray Leaf Spot* dan *Blight*.

Selanjutnya dilakukan perhitungan manual akurasi, presisi, recall, dan F1-score untuk mengetahui performa model secara keseluruhan.

### 1. Akurasi

Menunjukkan seberapa banyak prediksi model yang benar dibandingkan dengan keseluruhan data uji. Nilai akurasi dihitung dengan menjumlahkan seluruh true positive dari setiap kelas, kemudian dibagi dengan total seluruh data pada confusion matrix.

$$Accuracy = \frac{169 + 190 + 73 + 173}{629} = \frac{604}{629} = 0.960 \approx 96.0\%$$

### 2. Presisi

Rasio antara jumlah true positive dengan jumlah true positive ditambahkan false positive. Precision menunjukkan seberapa tepat model dalam mengklasifikasikan suatu kelas dibandingkan dengan prediksi yang dibuat. Nilai ini diambil untuk setiap kelas pada confusion matrix.

$$a) \textit{Blight} = \frac{168}{168+15} = 0.918$$

$$b) \textit{Common\_Rust} = \frac{190}{190+5} = 0.974$$

$$c) \textit{Grey Leaf Spot} = \frac{73}{73+5} = 0.936$$

$$d) \textit{Healthy} = \frac{173}{173+0} = 1.000$$

### 3. Recall

Recall adalah perbandingan antara jumlah true positive dengan jumlah true positive ditambahkan false negative. Recall mengukur kemampuan model dalam mengenali seluruh data aktual dari suatu kelas. Nilai recall juga dihitung untuk setiap kelas dari confusion matrix.

$$a) \textit{Blight} = \frac{168}{168+9} = 0.949$$

$$b) \textit{Common\_Rust} = \frac{190}{190+3} = 0.984$$

$$c) \text{ Grey Leaf Spot} = \frac{73}{73+13} = 0.848$$

$$d) \text{ Healthy} = \frac{173}{173+0} = 1.0000$$

#### 4. F1-Score

Rata-rata harmonis dari precision dan recall. Nilai ini digunakan untuk menyeimbangkan antara ketepatan prediksi (precision) dan kelengkapan prediksi (recall), sehingga lebih objektif dalam menilai performa model, terutama pada data yang tidak seimbang.

Kelas Blight:

$$F1_{Blight} = \frac{2 \times (0.918 \times 0.949)}{0.918 + 0.949} = 0.933$$

Kelas Common Rust:

$$F1_{CR} = \frac{2 \times (0.974 \times 0.984)}{0.974 + 0.984} = 0.979$$

Kelas Grey Leaf Spot:

$$F1_{GLS} = \frac{2 \times (0.936 \times 0.848)}{0.936 + 0.848} = 0.890$$

Kelas Healthy:


$$F1_H = \frac{2 \times (1.000 \times 1.000)}{1.000 + 1.000} = 1.000$$

#### 4.7.5 Analisis Hasil Optimalizer Adam ResNet-50 + CLAHE

##### a. Learning Rate 1e-3

Pada Gambar 4.19 terlihat bahwa akurasi data latih meningkat secara konsisten sejak epoch awal, dari sekitar 0,85 hingga mendekati 0,98 pada epoch-epoch akhir. Hal ini menunjukkan bahwa model mampu mempelajari pola pada data latih dengan

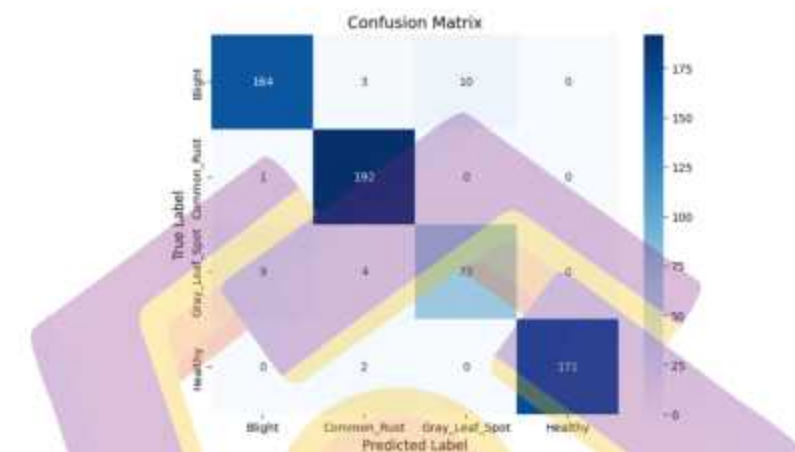
sangat baik seiring bertambahnya iterasi pelatihan. Akurasi validasi juga menunjukkan tren peningkatan yang relatif stabil, meskipun terdapat fluktuasi kecil di beberapa epoch. Kesenjangan antara akurasi pelatihan dan validasi yang relatif kecil mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting* yang signifikan.



Gambar 4.19 Plot Akurasi dan Loss Optimizer Adam + Learning Rate  $1e-3$

Sementara itu, grafik *Loss Over Epochs* memperlihatkan bahwa nilai *loss* pada data latih dan data validasi mengalami penurunan tajam pada epoch-epoch awal dan kemudian menurun secara lebih gradual hingga mencapai nilai yang relatif rendah di akhir pelatihan. Penurunan *training loss* yang konsisten menandakan bahwa proses optimisasi berjalan efektif dalam meminimalkan kesalahan prediksi. Di sisi lain, *validation loss* yang juga cenderung menurun dan tetap berada pada kisaran yang stabil menunjukkan bahwa model tidak hanya menyesuaikan diri dengan data latih, tetapi juga mampu mempertahankan kinerja yang baik pada data yang tidak dilihat sebelumnya. Secara keseluruhan, pola ini mengindikasikan konvergensi model yang baik dan performa klasifikasi yang stabil.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.




Gambar 4.20 Plot Confusion Matrix Optimizer Adam + Learning Rate  $1e-3$

Dapat dilihat pada Gambar 4.20 bahwa model memiliki tingkat ketepatan yang tinggi dalam mengklasifikasikan sebagian besar kelas. Kelas Blight berhasil diprediksi dengan benar sebanyak 164 sampel, meskipun masih terdapat kesalahan klasifikasi ke kelas Common\_Rust (3 sampel) dan Gray\_Leaf\_Spot (10 sampel). Kelas Common\_Rust menunjukkan performa yang sangat baik dengan 192 prediksi benar dan hanya 1 sampel yang salah diklasifikasikan sebagai Blight. Untuk kelas Gray\_Leaf\_Spot, sebanyak 73 sampel berhasil dikenali dengan benar, sementara sebagian kecil masih tertukar dengan Blight (9 sampel) dan Common\_Rust (4 sampel), yang mengindikasikan adanya kemiripan karakteristik visual antar kelas tersebut.

Kelas Healthy menunjukkan performa yang sangat stabil dengan 171 prediksi benar dan hanya 2 kesalahan klasifikasi ke kelas Common\_Rust, sementara tidak ada sampel yang salah diprediksi sebagai Blight atau Gray\_Leaf\_Spot. Dominasi nilai pada diagonal utama matriks memperlihatkan bahwa mayoritas data diklasifikasikan secara tepat, mencerminkan kinerja model yang baik secara keseluruhan. Pola kesalahan yang relatif kecil dan terfokus pada kelas-kelas tertentu menunjukkan bahwa model masih dapat ditingkatkan, khususnya dalam membedakan Blight dan Gray\_Leaf\_Spot yang memiliki karakteristik visual yang cenderung saling tumpang tindih.

b. Learning Rate  $1e-4$

Berdasarkan grafik Accuracy Over Epochs Pada Gambar 4.21, terlihat bahwa akurasi pelatihan meningkat sangat cepat dari sekitar 0,70 pada epoch awal hingga melampaui 0,90 hanya dalam beberapa epoch pertama, kemudian terus meningkat secara bertahap hingga mencapai nilai mendekati 0,95 pada akhir proses pelatihan. Akurasi validasi juga menunjukkan pola yang sejalan, berada pada kisaran tinggi sejak awal dan relatif stabil di sekitar 0,94–0,96. Kedekatan kurva akurasi pelatihan dan validasi ini menunjukkan bahwa model tidak hanya mampu mempelajari data latih dengan baik, tetapi juga memiliki kemampuan generalisasi yang kuat terhadap data yang tidak dilihat selama pelatihan, serta tidak menunjukkan indikasi overfitting yang berarti.



Gambar 4.21 Plot Akurasi dan Loss Optimizer Adam + Learning Rate  $1e-4$

Pada grafik Loss Over Epochs, baik training loss maupun validation loss mengalami penurunan yang konsisten sepanjang epoch, dari nilai awal yang cukup tinggi hingga mendekati 0,75 pada akhir pelatihan. Penurunan yang stabil dan sejajar antara kedua kurva ini mengindikasikan bahwa proses optimisasi berjalan efektif dan model terus memperbaiki kualitas prediksinya. Tidak adanya divergensi yang signifikan antara training loss dan validation loss juga memperkuat bahwa model telah mencapai kondisi konvergensi yang baik, di mana peningkatan kinerja pada data latih diikuti secara proporsional oleh peningkatan kinerja pada data validasi.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.22 Plot Confusion Matrix Optimizer Adam + Learning Rate 1e-4


Pada Gambar 4.22 merupakan confusion matrix yang digunakan untuk mengevaluasi kinerja suatu model klasifikasi dalam mengidentifikasi empat kelas kondisi tanaman, yaitu Blight, Common Rust, Gray Leaf Spot, dan Healthy. Sumbu vertikal menunjukkan label sebenarnya (true label), sedangkan sumbu horizontal menunjukkan label hasil prediksi model (predicted label). Nilai pada diagonal utama merepresentasikan jumlah prediksi yang benar untuk masing-masing kelas, sementara nilai di luar diagonal menunjukkan kesalahan klasifikasi. Dari matriks tersebut terlihat bahwa model memiliki tingkat prediksi yang tinggi pada kelas Common Rust (192 data terklasifikasi dengan benar) dan Healthy (171 data terklasifikasi dengan benar), yang mengindikasikan kemampuan model yang sangat baik dalam mengenali kedua kondisi tersebut.

Namun demikian, masih terdapat beberapa kesalahan klasifikasi pada kelas Blight dan Gray Leaf Spot. Sebanyak 14 data Blight salah diprediksi sebagai Gray Leaf Spot, dan 12 data Gray Leaf Spot salah diprediksi sebagai Blight, yang menunjukkan adanya kemiripan karakteristik visual antara kedua penyakit tersebut sehingga menyulitkan model dalam membedakannya secara konsisten. Meskipun

demikian, secara keseluruhan distribusi nilai pada matriks kebingungan ini menunjukkan bahwa model memiliki performa yang relatif baik dan stabil, dengan tingkat kesalahan yang rendah serta dominasi prediksi benar pada sebagian besar kelas. Hal ini mengindikasikan bahwa model cukup andal untuk digunakan dalam sistem klasifikasi penyakit tanaman berbasis citra.

#### 4.7.6 Analisis Hasil Stochastic Gradient Descent (SGD) ResNet-50 + CLAHE Learning Rate $1e-2$

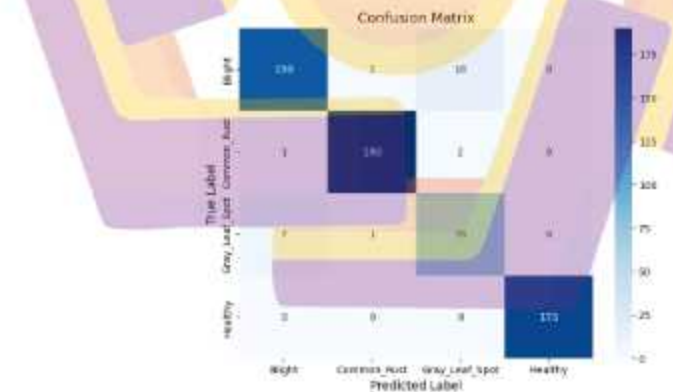
Pada Gambar 4.23 menunjukkan perkembangan akurasi model selama proses pelatihan dan validasi. Terlihat bahwa akurasi pelatihan (training accuracy) meningkat secara signifikan sejak epoch awal dan kemudian mendekati nilai maksimum, yakni sekitar 99%, seiring bertambahnya jumlah epoch. Hal ini menandakan bahwa model mampu mempelajari pola data pelatihan dengan sangat baik. Sementara itu, akurasi validasi (validation accuracy) juga mengalami peningkatan yang relatif stabil dan berada pada kisaran 95–97%. Meskipun terdapat fluktuasi kecil, perbedaan antara akurasi pelatihan dan validasi tidak terlalu besar, yang mengindikasikan bahwa model memiliki kemampuan generalisasi yang cukup baik terhadap data yang tidak dilatih secara langsung.



Gambar 4.23 Plot Akurasi dan Loss Optimizer SGD + Learning Rate  $1e-2$

Grafik Loss Over Epochs memperlihatkan tren penurunan nilai loss baik pada data pelatihan maupun data validasi. Nilai training loss menurun secara konsisten dari epoch awal hingga akhir, yang menunjukkan proses optimasi model berjalan efektif. Di sisi lain, validation loss juga mengalami penurunan meskipun dengan fluktuasi kecil pada beberapa epoch tertentu. Pola ini menandakan bahwa model tidak hanya semakin baik dalam meminimalkan kesalahan pada data pelatihan, tetapi juga tetap mempertahankan kinerja yang baik pada data validasi. Secara keseluruhan, kedua grafik tersebut mengindikasikan bahwa proses pelatihan berlangsung stabil, tanpa gejala overfitting yang signifikan, serta menghasilkan model dengan performa yang baik dan reliabel.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.24 Plot Confusion Matrix Optimizer SGD + Learning Rate  $1e-2$

Pada Gambar 4.24 confusion matrix yang menunjukkan kinerja model klasifikasi dalam mengidentifikasi empat kelas kondisi tanaman, yaitu Blight, Common Rust,


Gray Leaf Spot, dan Healthy. Nilai pada diagonal utama menunjukkan jumlah prediksi yang benar untuk masing-masing kelas, di mana kelas Healthy memiliki performa sempurna dengan seluruh data (173) berhasil diklasifikasikan secara benar. Kelas Common Rust juga menunjukkan tingkat akurasi yang sangat tinggi dengan 190 data terprediksi benar, sementara kelas Blight dan Gray Leaf Spot masing-masing memiliki 159 dan 78 prediksi yang sesuai dengan label sebenarnya.

Di sisi lain, kesalahan klasifikasi masih terlihat terutama antara kelas Blight dan Gray Leaf Spot. Sebanyak 16 data Blight salah diprediksi sebagai Gray Leaf Spot, dan 7 data Gray Leaf Spot salah diprediksi sebagai Blight, yang mengindikasikan adanya kemiripan karakteristik visual antara kedua jenis penyakit tersebut. Selain itu, terdapat kesalahan kecil pada kelas Common Rust yang masing-masing satu dan dua data salah diprediksi sebagai Blight dan Gray Leaf Spot. Secara keseluruhan, distribusi nilai pada matriks kebingungan ini menunjukkan bahwa model memiliki performa klasifikasi yang sangat baik dengan tingkat kesalahan yang relatif rendah, sehingga dapat dikatakan andal untuk mendukung sistem deteksi penyakit tanaman berbasis citra.

a. Learning Rate  $1e-3$

Pada Gambar 4.25 menunjukkan perkembangan akurasi pelatihan (training accuracy) dan akurasi validasi (validation accuracy) terhadap jumlah epoch. Terlihat bahwa akurasi pelatihan meningkat secara konsisten dari nilai awal sekitar 0,75 hingga mendekati 0,98 pada epoch akhir, yang mengindikasikan bahwa model semakin mampu mempelajari pola dalam data pelatihan. Akurasi validasi juga meningkat dengan cepat pada epoch awal dan kemudian relatif stabil di kisaran 0,95–0,96, meskipun terdapat fluktuasi kecil. Perbedaan yang tidak terlalu besar


antara akurasi pelatihan dan validasi menunjukkan bahwa model memiliki kemampuan generalisasi yang baik, dengan indikasi overfitting yang minimal karena tidak terjadi penurunan akurasi validasi secara signifikan pada epoch-epoch akhir.



Gambar 4.25 Plot Akurasi dan Loss Optimizer SGD + Learning Rate  $1e-3$

Gambar kedua memperlihatkan perubahan nilai loss pelatihan dan loss validasi selama proses pelatihan. Loss pelatihan mengalami penurunan yang stabil dari nilai awal yang relatif tinggi hingga mencapai nilai yang lebih rendah pada epoch akhir, mencerminkan proses optimisasi model yang berjalan efektif. Sementara itu, loss validasi juga menurun pada fase awal pelatihan dan kemudian cenderung stabil dengan fluktuasi kecil di sekitar nilai tertentu. Pola ini menunjukkan bahwa model telah mencapai konvergensi, di mana peningkatan performa lebih lanjut menjadi terbatas. Konsistensi antara tren loss pelatihan dan loss validasi memperkuat kesimpulan bahwa model tidak mengalami overfitting yang serius dan telah belajar merepresentasikan data secara seimbang antara data pelatihan dan data validasi.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.26 Plot Confusion Matrix Optimizer SGD + Learning Rate  $1e-3$

Pada Gambar 4.26 menampilkan confusion matrix yang digunakan untuk mengevaluasi kinerja model klasifikasi empat kelas, yaitu Blight, Common\_Rust, Gray\_Leaf\_Spot, dan Healthy. Baris merepresentasikan label sebenarnya (true label), sedangkan kolom menunjukkan label hasil prediksi model. Nilai pada diagonal utama menunjukkan jumlah prediksi yang benar untuk setiap kelas, yang relatif tinggi pada seluruh kategori, seperti Blight (166), Common\_Rust (190), Gray\_Leaf\_Spot (69), dan Healthy (172). Hal ini mengindikasikan bahwa model memiliki kemampuan klasifikasi yang baik secara umum, dengan tingkat akurasi yang tinggi pada masing-masing kelas.


Meskipun demikian, masih terdapat beberapa kesalahan klasifikasi yang terlihat pada nilai di luar diagonal. Kesalahan paling menonjol terjadi pada kelas Gray\_Leaf\_Spot yang cukup sering diprediksi sebagai Blight (16 kasus), serta Blight yang sesekali diprediksi sebagai Gray\_Leaf\_Spot (9 kasus). Hal ini menunjukkan adanya kemiripan karakteristik visual antara kedua kelas tersebut yang menyulitkan model dalam membedakannya secara konsisten. Sebaliknya, kelas Healthy menunjukkan tingkat kesalahan yang sangat rendah, menandakan

bahwa ciri-ciri kondisi sehat lebih mudah dikenali oleh model. Secara keseluruhan, confusion matrix ini memberikan gambaran rinci mengenai kekuatan dan kelemahan model, serta menjadi dasar penting untuk analisis lanjutan dan peningkatan performa klasifikasi.

#### 4.7.7 Analisis Hasil Optimazer Adam ResNet-50 + CBAM + CLAHE

##### a. Learning Rate $1e-3$

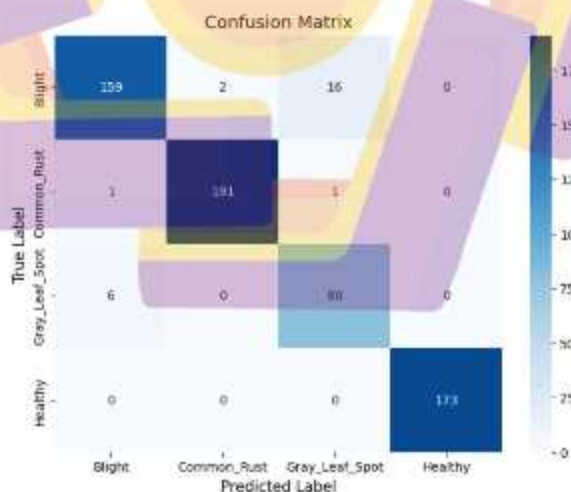
Pada Gambar 4.27 menunjukkan perkembangan akurasi pelatihan (training accuracy) dan akurasi validasi (validation accuracy) sepanjang epoch. Terlihat bahwa akurasi pelatihan meningkat secara signifikan pada epoch-epoch awal, kemudian mengalami peningkatan yang lebih stabil hingga mencapai nilai yang sangat tinggi mendekati 0,99. Akurasi validasi juga menunjukkan tren peningkatan yang relatif konsisten, meskipun dengan fluktuasi kecil di beberapa epoch. Perbedaan antara akurasi pelatihan dan validasi cenderung kecil, yang mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami overfitting yang berat. Fluktuasi ringan pada akurasi validasi merupakan fenomena umum yang dapat disebabkan oleh variasi data validasi atau sensitivitas model terhadap pembaruan bobot pada setiap epoch.



Gambar 4.27 Plot Akurasi dan Loss Optimazer Adam + Learning Ratae  $1e-3$

Grafik kedua menggambarkan perubahan nilai loss pelatihan dan loss validasi selama proses pelatihan. Loss pelatihan menurun secara tajam pada tahap awal dan terus berkurang secara bertahap hingga mencapai nilai yang rendah, menunjukkan bahwa model semakin baik dalam meminimalkan kesalahan pada data pelatihan. Loss validasi juga mengalami penurunan secara umum, meskipun terdapat beberapa kenaikan lokal di tengah hingga akhir epoch, yang menandakan adanya variasi performa pada data validasi. Namun, karena tren keseluruhan loss validasi tetap menurun dan tidak meningkat secara drastis, hal ini mengindikasikan bahwa proses pelatihan berlangsung secara stabil dan model tidak menunjukkan gejala overfitting yang signifikan.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.28 Plot Confusion Matrix Optimizer Adam + Learning Rate 1e-3


Pada Gambar 4.28 menampilkan confusion matrix yang menggambarkan kinerja model klasifikasi terhadap empat kelas, yaitu Blight, Common Rust, Gray Leaf Spot, dan Healthy. Nilai pada diagonal utama menunjukkan jumlah prediksi yang benar untuk setiap kelas. Terlihat bahwa model mampu mengklasifikasikan sebagian besar data dengan tepat, khususnya pada kelas Common Rust (191 data benar) dan Healthy (173 data benar), yang menunjukkan tingkat sensitivitas dan ketepatan klasifikasi yang sangat tinggi pada kedua kelas tersebut. Hal ini mengindikasikan bahwa ciri-ciri visual pada kelas-kelas tersebut dapat dipelajari dengan baik oleh model.

Di sisi lain, kesalahan klasifikasi relatif kecil namun masih terlihat pada beberapa kelas, terutama pada kelas Blight yang sebagian data salah diprediksi sebagai Gray Leaf Spot (16 data) dan dalam jumlah sangat kecil sebagai Common Rust. Kelas Gray Leaf Spot juga menunjukkan beberapa kesalahan prediksi ke kelas Blight. Pola ini mengindikasikan adanya kemiripan karakteristik antar kelas tertentu yang menyebabkan ambiguitas dalam proses klasifikasi. Meskipun demikian, secara keseluruhan confusion matrix ini menunjukkan performa model yang kuat dan seimbang, dengan tingkat kesalahan yang rendah serta kemampuan generalisasi yang baik pada sebagian besar kelas.

#### b. Learning Rate $1e-4$

Pada Gambar 4.29 menampilkan perkembangan akurasi pelatihan (training accuracy) dan akurasi validasi (validation accuracy) terhadap jumlah epoch. Terlihat bahwa pada fase awal pelatihan, kedua kurva akurasi meningkat secara signifikan, yang menunjukkan bahwa model dengan cepat mempelajari pola dasar dari data. Seiring bertambahnya epoch, akurasi pelatihan terus meningkat hingga mendekati

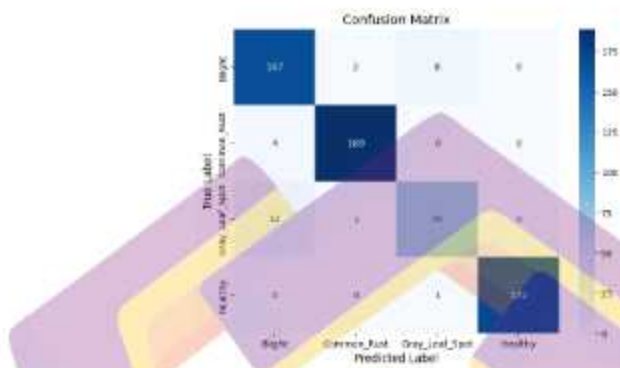
nilai maksimum, sementara akurasi validasi cenderung stabil pada kisaran yang sedikit lebih rendah. Perbedaan kecil antara akurasi pelatihan dan validasi mengindikasikan bahwa model memiliki kemampuan generalisasi yang cukup baik, meskipun terdapat fluktuasi minor pada akurasi validasi yang dapat disebabkan oleh variasi data validasi atau efek stokastik selama proses optimisasi.



Gambar 4.29 Plot Akurasi dan Loss Optimizer Adam + Learning Rate  $1e-4$

Gambar kedua memperlihatkan perubahan nilai loss pelatihan dan loss validasi sepanjang epoch. Nilai training loss menurun secara konsisten, menandakan bahwa kesalahan model terhadap data pelatihan semakin berkurang dan proses pembelajaran berjalan efektif. Sementara itu, validation loss juga menunjukkan tren penurunan, meskipun dengan beberapa kenaikan lokal pada epoch tertentu. Pola ini menunjukkan bahwa model tidak mengalami overfitting yang signifikan, karena validation loss tidak meningkat secara tajam atau berkelanjutan. Secara keseluruhan, kombinasi tren akurasi dan loss tersebut menunjukkan bahwa model telah dilatih dengan baik dan mencapai keseimbangan yang relatif optimal antara kemampuan belajar dari data pelatihan dan generalisasi terhadap data yang tidak dilihat sebelumnya.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.30 Plot Confusion Matrix Optimizer Adam + Learning Rate 1e-4

Pada Gambar 4.30 menampilkan confusion matrix yang digunakan untuk mengevaluasi kinerja suatu model klasifikasi dengan empat kelas, yaitu Blight, Common Rust, Gray Leaf Spot, dan Healthy. Sumbu vertikal merepresentasikan label sebenarnya (true label), sedangkan sumbu horizontal menunjukkan label hasil prediksi model (predicted label). Nilai pada diagonal utama menunjukkan jumlah prediksi yang benar untuk setiap kelas, yang relatif tinggi pada seluruh kategori (misalnya 167 untuk Blight, 189 untuk Common Rust, 73 untuk Gray Leaf Spot, dan 172 untuk Healthy). Hal ini mengindikasikan bahwa model memiliki kemampuan klasifikasi yang baik secara umum, dengan tingkat akurasi yang tinggi pada masing-masing kelas.


Meskipun demikian, masih terdapat beberapa kesalahan klasifikasi yang tercermin pada nilai di luar diagonal. Kesalahan paling menonjol terjadi pada kelas Gray Leaf Spot yang beberapa kali diprediksi sebagai Blight, serta sebagian kecil sampel

Blight yang diprediksi sebagai Gray Leaf Spot. Selain itu, terdapat kesalahan minor pada kelas Common Rust yang sesekali diprediksi sebagai Blight. Sebaliknya, kelas Healthy menunjukkan performa yang sangat baik dengan hampir tidak ada kesalahan prediksi. Secara keseluruhan, confusion matrix ini menunjukkan bahwa model memiliki sensitivitas dan spesifisitas yang tinggi, meskipun masih diperlukan peningkatan untuk mengurangi ambiguitas antar kelas penyakit yang memiliki karakteristik visual yang mirip.

#### 4.7.8 Analisis Hasil Stochastic Gradient Descent (SGD) ResNet-50 + CBAM + CLAHE

##### a. Learning Rate $1e-2$


Pada Gambar 4.31 menunjukkan perkembangan akurasi pelatihan (training accuracy) dan akurasi validasi (validation accuracy) sepanjang epoch. Terlihat bahwa akurasi pelatihan meningkat secara konsisten dari nilai awal yang relatif rendah hingga mendekati 1,00 pada epoch-epoch akhir, yang menandakan bahwa model semakin mampu mempelajari pola pada data latih. Akurasi validasi juga menunjukkan tren peningkatan yang stabil, meskipun dengan fluktuasi kecil di beberapa epoch. Perbedaan yang relatif kecil antara akurasi pelatihan dan validasi mengindikasikan bahwa model memiliki kemampuan generalisasi yang baik, serta tidak menunjukkan gejala overfitting yang signifikan.



Gambar 4.31 Plot Akurasi dan Loss Optimizer SGD + Learning Rate  $1e-2$

Gambar kedua memperlihatkan perubahan nilai loss pada data pelatihan dan validasi selama proses pelatihan. Training loss mengalami penurunan yang konsisten seiring bertambahnya epoch, menunjukkan bahwa kesalahan prediksi model pada data latih semakin berkurang. Validation loss juga menurun secara bertahap, meskipun dengan variasi kecil, yang mencerminkan peningkatan performa model pada data yang tidak dilatih secara langsung. Pola penurunan loss yang sejalan antara data pelatihan dan validasi menunjukkan bahwa proses optimasi berjalan dengan baik dan model mampu mencapai konvergensi yang stabil tanpa indikasi overfitting yang kuat.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.32 Plot Confusion Matrix Optimizer SGD + Learning Rate 1e-2

Pada Gambar 4.32 menampilkan confusion matrix yang digunakan untuk mengevaluasi kinerja model klasifikasi multikelas dalam mengidentifikasi empat kategori kondisi tanaman, yaitu Blight, Common Rust, Gray Leaf Spot, dan Healthy. Setiap baris merepresentasikan label aktual, sedangkan setiap kolom menunjukkan


label hasil prediksi model. Nilai pada diagonal utama menunjukkan jumlah prediksi yang benar untuk masing-masing kelas. Terlihat bahwa model memiliki tingkat klasifikasi yang tinggi pada seluruh kelas, khususnya pada kelas Common Rust (190 data benar), Healthy (173 data benar), dan Blight (168 data benar), yang mengindikasikan kemampuan model yang baik dalam mengenali pola visual khas dari masing-masing penyakit maupun kondisi sehat.

Namun demikian, masih terdapat sejumlah kesalahan klasifikasi yang relatif kecil, terutama pada kelas Gray Leaf Spot dan Blight. Sebagai contoh, beberapa sampel Gray Leaf Spot salah diprediksi sebagai Blight, dan sebagian kecil data Blight keliru diklasifikasikan sebagai Common Rust atau Gray Leaf Spot. Kesalahan ini dapat disebabkan oleh kemiripan karakteristik visual antar penyakit daun, seperti pola bercak dan perubahan warna. Secara keseluruhan, distribusi kesalahan yang minim dan dominasi nilai diagonal menunjukkan bahwa model memiliki akurasi dan konsistensi yang tinggi, meskipun peningkatan lebih lanjut masih dimungkinkan melalui penambahan data latih atau ekstraksi fitur yang lebih diskriminatif.

#### b. Learning Rate $1e-3$

Pada Gambar 4.33 menunjukkan perkembangan akurasi pelatihan (training accuracy) dan akurasi validasi (validation accuracy) terhadap jumlah epoch. Terlihat bahwa akurasi pelatihan meningkat secara signifikan pada epoch awal dan kemudian cenderung stabil pada nilai tinggi, mendekati 0,98. Pola serupa juga ditunjukkan oleh akurasi validasi yang berada pada kisaran 0,95–0,97, dengan fluktuasi yang relatif kecil. Kedekatan nilai antara akurasi pelatihan dan validasi mengindikasikan bahwa model mampu melakukan generalisasi dengan baik terhadap data yang tidak


dilatih, serta tidak menunjukkan gejala overfitting yang signifikan. Stabilitas ini menandakan bahwa proses pembelajaran telah mencapai konvergensi yang optimal.



Gambar 4.33 Plot Akurasi dan Loss Optimizer SGD + Learning Rate  $1e-3$

Gambar kedua memperlihatkan kurva loss pelatihan dan loss validasi selama proses pelatihan. Nilai training loss mengalami penurunan yang konsisten seiring bertambahnya epoch, menunjukkan bahwa model semakin mampu meminimalkan kesalahan prediksi pada data latih. Sementara itu, validation loss juga menurun pada fase awal dan kemudian cenderung stabil dengan sedikit fluktuasi pada epoch selanjutnya. Perbedaan yang relatif kecil antara training loss dan validation loss menguatkan indikasi bahwa model memiliki keseimbangan yang baik antara kemampuan belajar dan generalisasi. Secara keseluruhan, kedua grafik ini menunjukkan bahwa model telah dilatih secara efektif dan mencapai performa yang optimal tanpa degradasi kinerja pada data validasi.

Dari model yang telah terbentuk, selanjutnya dilakukan evaluasi lanjutan menggunakan confusion matrix untuk menganalisis kemampuan klasifikasi pada setiap kelas.



Gambar 4.34 Plot Confusion Matrix Optimizer SGD + Learning Rate 1e-3

Pada Gambar 4.34 menunjukkan performa yang kuat secara keseluruhan dalam mengidentifikasi empat kategori penyakit pada tanaman jagung, yaitu Bright, Common\_Rust, Gray\_Leaf\_Spot, dan Healthy. Diagonal utama matriks, yang merepresentasikan prediksi benar (true positive), menunjukkan nilai yang tinggi untuk semua kelas. Secara khusus, kelas Common\_Rust dan Healthy mencapai akurasi yang sangat baik dengan masing-masing 191 dan 172 instansi terklasifikasi dengan benar, serta hanya memiliki sedikit kasus salah klasifikasi. Kelas Bright juga mencatat performa yang solid dengan 164 prediksi benar, meskipun terdapat sejumlah kesalahan yang terutama terkonsentrasi pada Gray\_Leaf\_Spot.

Namun, analisis lebih lanjut mengungkapkan area yang memerlukan perbaikan, terutama pada kelas Gray\_Leaf\_Spot. Terdapat 12 sampel Gray\_Leaf\_Spot yang salah diklasifikasikan sebagai Bright, serta satu sampel yang salah diklasifikasikan sebagai Common\_Rust, yang menunjukkan adanya tumpang tindih ciri atau kebingungan model antara kelas-kelas tersebut. Selain itu, satu sampel Healthy secara keliru diidentifikasi sebagai Gray\_Leaf\_Spot, yang dapat menjadi perhatian khusus dalam konteks aplikasi pertanian karena berpotensi menyebabkan tindakan

yang tidak diperlukan pada tanaman yang sehat. Secara keseluruhan, meskipun model telah mencapai tingkat keandalan yang tinggi, upaya kalibrasi lebih lanjut diperlukan untuk mengurangi kesalahan antar kelas penyakit, khususnya yang melibatkan *Gray\_Leaf\_Spot*, guna meningkatkan presisi dan keakuratan sistem diagnostik.

#### 4.8. Perbandingan Hasil Pengujian

Setelah dilakukannya serangkaian proses klasifikasi pengujian metode ResNet-50 dengan penambahan Preprocessing CLAHE dan modul CBAM serta beberapa skenario dengan optimizer dan learning rate yang berbeda, peneliti akan menyajikan hasil pengujian masing-masing skenario penelitian yang telah dilakukan yang bertujuan untuk mengetahui seberapa baik kinerja suatu model yang telah dibuat. Berikut merupakan hasil pelatihan dan pengujian setiap skenario penelitian yang dapat ditampilkan pada Tabel 4.4 sebagai berikut.

Tabel 4. 4 Perbandingan Hasil Pengujian

No	Model	Learning Rate	Akurasi	Presisi	Recall	F1-Score	Rata-Rata Akurasi
S1	ResNet-50	Adam (0.001)	93.16%	93.26%	93.16%	92,87 %	93.80%
S2		Adam (0.0001)	95.07%	95.02%	95.07%	95.04 %	
S3		SGD (0.01)	93.16%	93.30%	93.16%	93,04 %	
S4		SGD (0.001)	93.80%	93.83%	93.80%	93.61 %	
S5	ResNet-50 + CBAM	Adam (0.001)	93.96%	94.06%	93.96%	94%	
S6		Adam	94.91%	94.86%	94.91%	94.87 %	



Kombinasi optimizer Adam dengan learning rate 0.0001 (S2) menunjukkan performa terbaik pada kelompok ini dengan akurasi, presisi, recall, dan F1-score yang relatif seimbang di atas 95%, mengindikasikan bahwa penurunan learning rate mampu meningkatkan stabilitas pembelajaran dan generalisasi model dibandingkan konfigurasi lainnya.

Pada skenario S5-S8 yang mengintegrasikan ResNet-50 dengan modul CBAM, terjadi peningkatan performa yang cukup konsisten, dengan rata-rata akurasi mencapai 94,67%. Hal ini menunjukkan bahwa mekanisme perhatian (attention mechanism) pada CBAM efektif dalam memperkuat fitur-fitur penting baik pada dimensi kanal maupun spasial. Konfigurasi terbaik pada kelompok ini diperoleh pada S7 dengan optimizer SGD dan learning rate 0.01, yang menghasilkan akurasi 95.07% dan F1-score 95.03%. Temuan ini mengindikasikan bahwa CBAM mampu bekerja optimal tidak hanya dengan Adam, tetapi juga dengan SGD ketika learning rate disesuaikan secara tepat.

Selanjutnya, pada skenario S9-S12 yang menerapkan ResNet-50 dengan preprocessing CLAHE, diperoleh rata-rata akurasi sebesar 95,07%, lebih tinggi dibandingkan model dasar dan model dengan CBAM saja. Peningkatan ini menunjukkan bahwa CLAHE berperan efektif dalam memperbaiki kontras citra sehingga fitur visual menjadi lebih diskriminatif. Skenario S11 (SGD, learning rate 0.01) menunjukkan performa terbaik dengan akurasi 95.39% dan F1-score 95.44%, yang mencerminkan keseimbangan yang baik antara kemampuan deteksi kelas positif dan negatif. Performa tertinggi dicapai pada skenario S13-S16 yang mengombinasikan ResNet-50, CBAM, dan CLAHE, dengan rata-rata akurasi sebesar 95,71%. Kombinasi ini menunjukkan efek sinergis antara peningkatan

kualitas citra melalui CLAHE dan penguatan representasi fitur melalui CBAM. Skenario S15, yang menggunakan optimizer SGD dengan learning rate 0.01, menghasilkan kinerja terbaik secara keseluruhan dengan akurasi 96.03% dan F1-score 95.99%. Secara keseluruhan, hasil ini menegaskan bahwa integrasi modul attention dan teknik preprocessing, serta pemilihan optimizer dan learning rate yang tepat, berkontribusi signifikan dalam meningkatkan kinerja model klasifikasi berbasis ResNet-50.

#### 4.8.1 Perbandingan Hasil Pengujian Sebelum dan Sesudah CLAHE

Pada perbandingan sebelum dan sesudah penerapan CLAHE menunjukkan adanya peningkatan performa model pada seluruh metrik evaluasi, yaitu akurasi, precision, recall, dan F1-score. Model ResNet-50 yang telah melalui tahap preprocessing CLAHE memperoleh nilai performa yang lebih tinggi dibandingkan model tanpa CLAHE. Hal ini mengindikasikan bahwa CLAHE mampu meningkatkan kualitas visual citra dengan memperbaiki kontras lokal dan memperjelas tekstur penyakit pada daun jagung. Dapat dilihat pada Tabel 4.5

Tabel 4. 5 Perbandingan Performa ResNet-50 sebelum dan Sesudah CLAHE

Kondisi Model	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
ResNet-50 (Tanpa CLAHE – S1 terbaik)	95.07	95.02	95.07	95.04
ResNet-50 + CLAHE (S9 terbaik)	95.39	95.36	95.39	95.36
<b>Peningkatan (%)</b>	<b>+0.32</b>	<b>+0.34</b>	<b>+0.32</b>	<b>+0.32</b>

Peningkatan performa yang konsisten pada seluruh metrik menunjukkan bahwa CLAHE berperan penting dalam membantu proses ekstraksi fitur oleh model. Dengan citra yang memiliki kontras lebih baik, model dapat mengenali pola penyakit secara lebih akurat, sehingga kesalahan klasifikasi dapat diminimalkan.

Hasil ini menegaskan bahwa preprocessing CLAHE memberikan kontribusi positif terhadap kinerja model klasifikasi penyakit daun jagung.

#### 4.8.2 Perbandingan Hasil Pengujian Sebelum dan Sesudah CBAM

Tabel 4.6 menyajikan perbandingan performa model ResNet-50 sebelum dan sesudah penambahan modul Convolutional Block Attention Module (CBAM). Berdasarkan hasil yang ditampilkan, penambahan CBAM memberikan peningkatan yang relatif kecil pada metrik evaluasi jika dibandingkan dengan model dasar. Hal ini menunjukkan bahwa CBAM secara individual belum memberikan peningkatan yang signifikan terhadap performa klasifikasi.

Tabel 4. 6 Perbandingan Performa ResNet-50 sebelum dan Sesudah CBAM

Kondisi Model	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
ResNet-50 (Tanpa CBAM – S2 terbaik)	95.07	95.02	95.07	95.04
ResNet-50 + CBAM (S7 terbaik)	95.07	95.07	95.07	95.03
Peningkatan (%)	0.00	+0.05	0.00	-0.01

Meskipun demikian, CBAM memiliki peran penting dalam meningkatkan fokus model terhadap area penting pada citra daun yang mengandung gejala penyakit. Modul perhatian ini membantu model mengurangi pengaruh latar belakang atau area yang tidak relevan. Efektivitas CBAM terlihat lebih optimal ketika dikombinasikan dengan preprocessing CLAHE, yang secara bersama-sama meningkatkan kualitas citra dan fokus perhatian model.

#### 4.8.3 Perbandingan Hasil Pengujian Optimizer Adam dan SGD

Tabel 4.7 perbandingan optimizer menunjukkan perbedaan performa model ketika menggunakan optimizer Adam dan Stochastic Gradient Descent (SGD). Hasil eksperimen memperlihatkan bahwa optimizer SGD mampu menghasilkan nilai

akurasi tertinggi, sedangkan optimizer Adam menunjukkan performa yang stabil pada metrik precision. Perbedaan ini mencerminkan karakteristik masing-masing optimizer dalam proses optimasi parameter model.

Tabel 4. 7 Perbandingan Performa Optimizer Adam dan SGD

Optimizer	Skenario	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
Adam	S13	95.87	96.10	95.87	95.81
SGD	S15	<b>96.03</b>	<b>96.03</b>	<b>96.03</b>	<b>95.99</b>

Optimizer Adam dikenal memiliki kemampuan adaptif dalam menyesuaikan learning rate, sehingga proses pelatihan berlangsung lebih stabil dan cepat konvergen. Sementara itu, optimizer SGD cenderung menghasilkan generalisasi yang lebih baik pada beberapa skenario. Oleh karena itu, pemilihan optimizer menjadi faktor penting yang memengaruhi performa akhir model klasifikasi.

#### 4.8.4 Perbandingan Hasil Pengujian Seluruh Skenario

Tabel 4.8 total peningkatan performa membandingkan model baseline ResNet-50 dengan model terbaik yang menggunakan kombinasi CLAHE, CBAM, dan optimizer terbaik. Hasil yang ditampilkan menunjukkan adanya peningkatan performa yang signifikan pada seluruh metrik evaluasi. Peningkatan ini menegaskan bahwa kombinasi metode yang diusulkan mampu mengatasi keterbatasan model dasar dalam mengklasifikasikan penyakit daun jagung.

Tabel 4. 8 Peningkatan Performa dari Baseline ke Model Terbaik Secara

Model	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
Baseline (ResNet-50 – S1)	93.16	93.26	93.16	92.87
Kombinasi (ResNet-50 + CBAM + CLAHE + SGD – S15)	96.03	96.03	96.03	95.99
<b>Total Peningkatan (%)</b>	<b>+2.87</b>	<b>+2.77</b>	<b>+2.87</b>	<b>+3.12</b>

Secara keseluruhan, peningkatan performa tersebut menunjukkan bahwa integrasi

preprocessing CLAHE, modul CBAM, dan pemilihan optimizer yang tepat mampu meningkatkan kualitas ekstraksi fitur serta kemampuan diskriminatif model. Dengan demikian, pendekatan yang diusulkan terbukti efektif dalam menghasilkan model klasifikasi yang lebih akurat, stabil, dan andal.

#### 4.9. Analisis Kombinasi Model Terbaik

Tabel 4.9 analisis dominasi metode menunjukkan kontribusi masing-masing teknik yang digunakan dalam penelitian terhadap peningkatan performa model. Berdasarkan hasil evaluasi, preprocessing CLAHE dan pemilihan optimizer memberikan dampak yang paling signifikan terhadap peningkatan kinerja model. CLAHE berperan dalam meningkatkan kualitas citra, sedangkan optimizer memengaruhi stabilitas dan konvergensi proses pelatihan.

Tabel 4. 9 Perbandingan Metode

Metode	Dampak terhadap Performa	Keterangan
CLAHE	Tinggi	Meningkatkan kualitas citra & fitur
CBAM	Sedang	Meningkatkan fokus area penting
Optimizer	Tinggi	Mempengaruhi stabilitas & konvergensi
<b>Kombinasi</b>	<b>Sangat Tinggi</b>	Memberikan performa terbaik

Sementara itu, modul CBAM memberikan kontribusi dalam meningkatkan fokus perhatian model terhadap area penting pada citra, meskipun dampaknya lebih optimal ketika dikombinasikan dengan metode lain. Secara keseluruhan, kombinasi CLAHE, CBAM, dan optimizer merupakan pendekatan paling dominan dalam meningkatkan performa model klasifikasi penyakit daun jagung, sehingga menjawab tujuan penelitian dan revisi yang diberikan oleh dosen.

## BAB V PENUTUP

### 1.1. Kesimpulan

1. Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa penerapan metode *Convolutional Neural Network* (CNN) dengan arsitektur ResNet-50 mampu mengklasifikasikan penyakit tanaman jagung berdasarkan citra daun dengan tingkat akurasi yang tinggi. Model ini efektif dalam mengenali empat kelas kondisi daun jagung, yaitu *Blight*, *Common Rust*, *Gray Leaf Spot*, dan *Healthy*, sehingga menunjukkan kemampuan yang baik dalam mengekstraksi fitur visual yang relevan dari citra daun.
2. Penambahan *Convolutional Block Attention Module* (CBAM) terbukti memberikan peningkatan kinerja model dibandingkan ResNet-50 tanpa modul perhatian. CBAM memungkinkan model untuk lebih fokus pada area penting pada citra daun yang mengandung gejala penyakit, sehingga dapat mengurangi kesalahan klasifikasi akibat gangguan latar belakang atau bagian daun yang tidak relevan. Selain itu, penerapan teknik *preprocessing* CLAHE mampu meningkatkan kualitas citra dengan memperjelas kontras dan detail tekstur daun, yang berdampak positif terhadap proses ekstraksi fitur.
3. Hasil pengujian menunjukkan bahwa kombinasi ResNet-50 + CBAM + CLAHE dengan optimizer SGD dan learning rate 0.01 menghasilkan performa terbaik, dengan nilai akurasi sebesar 96,03%, precision 95,03%, dan recall 95,03%. Nilai tersebut menunjukkan keseimbangan yang baik

antara ketepatan dan kemampuan model dalam mendeteksi penyakit daun jagung. Dengan demikian, pendekatan yang diusulkan dalam penelitian ini dapat dijadikan solusi yang efektif untuk mendukung proses identifikasi penyakit tanaman jagung secara otomatis berbasis citra digital.

## 1.2. Saran

1. penelitian di masa depan disarankan untuk menggunakan dataset dengan jumlah yang lebih besar dan kondisi citra yang lebih bervariasi, termasuk citra yang diambil langsung di lapangan dengan latar belakang dan pencahayaan yang beragam, agar model lebih robust terhadap kondisi nyata.
2. pengembangan model dapat dilakukan dengan membandingkan arsitektur CNN lain, seperti EfficientNet atau DenseNet, serta mengombinasikannya dengan mekanisme attention yang berbeda untuk mengetahui konfigurasi model yang paling optimal. Selain itu, penerapan teknik penyeimbangan data seperti *class weighting* atau *data augmentation* yang lebih beragam juga dapat dipertimbangkan untuk mengatasi ketidakseimbangan jumlah data antar kelas.
3. Hasil pengujian menunjukkan bahwa optimizer SGD mencapai akurasi 96,03% dengan nilai precision, recall, dan F1-score yang tinggi serta seimbang, menandakan kinerja model yang optimal dalam klasifikasi penyakit daun jagung. Peningkatan performa ini mengindikasikan bahwa penerapan CBAM dan peningkatan kualitas citra menggunakan CLAHE efektif dalam membantu model memfokuskan pembelajaran pada area gejala penyakit yang relevan.

## DAFTAR PUSTAKA

- [1] S. Panikkai, M. Azrai, and F. N. Fahmi, "Model production of corn development for industrial needs and increasing economy," *IOP Conf Ser Earth Environ Sci*, vol. 484, no. 1, p. 012137, Apr. 2020, doi: 10.1088/1755-1315/484/1/012137.
- [2] S. del C. Mina and J. D. Quintana-Garrido, "Corn as an alternative method for contributing to the country's public policies in terms of health, sustainable economy and food security, accordance with the 2030 Agenda and FAO," *Journal Law and Economy*, vol. 8, no. 14, Dec. 2024, doi: 10.35429/JLE.2024.8.14.1.10.
- [3] Asifha Defitrian Salsabila, Solfema Solfema, and Lili Dasa Putri, "Pengolahan Hasil Pertanian Jagung untuk Meningkatkan Perekonomian Desa," *Harmoni Pendidikan : Jurnal Ilmu Pendidikan*, vol. 2, no. 1, pp. 192–200, Dec. 2024, doi: 10.62383/hardik.v2i1.1055.
- [4] D. S. Mueller *et al.*, "Corn Yield Loss Estimates Due to Diseases in the United States and Ontario, Canada, from 2016 to 2019," *Plant Health Prog*, vol. 21, no. 4, pp. 238–247, Jan. 2020, doi: 10.1094/PHP-05-20-0038-RS.
- [5] D. T. Chirinos *et al.*, "Entomofauna Associated with Corn Cultivation and Damage Caused by Some Pests According to the Planting Season on the Ecuadorian Coast," *Agronomy*, vol. 14, no. 4, p. 748, Apr. 2024, doi: 10.3390/agronomy14040748.

- [6] J. Agarwal, S. Naithani, U. Singh, and H. Raj, "Plant Disease Detection using Convolutional Neural Network," in *2023 International Conference on Smart Devices (ICSD)*, IEEE, May 2024, pp. 1–5. doi: 10.1109/ICSD60021.2024.10751329.
- [7] L. Chen, S. Li, Q. Bai, J. Yang, S. Jiang, and Y. Miao, "Review of Image Classification Algorithms Based on Convolutional Neural Networks," *Remote Sens. (Basel)*, vol. 13, no. 22, p. 4712, Nov. 2021, doi: 10.3390/rs13224712.
- [8] 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.
- [9] A. D. Nurcahyati, R. M. Akbar, and S. Zahara, "Klasifikasi Citra Penyakit pada Daun Jagung Menggunakan Deep Learning dengan Metode Convolution Neural Network (CNN)," *SUBMIT: Jurnal Ilmiah Teknologi Infomasi dan Sains*, vol. 2, no. 2, pp. 43–51, Jun. 2022, doi: 10.36815/submit.v2i2.1877.
- [10] R. Kusumastuti, T. Dwi Putra, and Z. Zufahmi Yudam, "KLASIFIKASI CITRA PENYAKIT DAUN JAGUNG MENGGUNAKAN ALGORITMA CNN EFFICIENTNET," *MULTITEK INDONESIA*, vol. 17, no. 2, pp. 143–153, Aug. 2024, doi: 10.24269/mtkind.v17i2.10085.
- [11] W. G. Pamungkas, M. I. P. Wardhana, Z. Sari, and Y. Azhar, "Leaf Image Identification: CNN with EfficientNet-B0 and ResNet-50 Used to Classified

- Corn Disease,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 2, pp. 326–333, Mar. 2023, doi: 10.29207/resti.v7i2.4736.
- [12] A. Bhujel, N. E. Kim, E. Arulmozhi, J. K. Basak, and H. T. Kim, “A Lightweight Attention-Based Convolutional Neural Networks for Tomato Leaf Disease Classification,” *Agriculture (Switzerland)*, vol. 12, no. 2, Feb. 2022, doi: 10.3390/agriculture12020228.
- [13] M. Fraiwan, E. Faouri, and N. Khasawneh, “Classification of Corn Diseases from Leaf Images Using Deep Transfer Learning,” *Plants*, vol. 11, no. 20, p. 2668, Oct. 2022, doi: 10.3390/plants11202668.
- [14] V. Tiwari, R. C. Joshi, and M. K. Dutta, “Dense convolutional neural networks based multiclass plant disease detection and classification using leaf images,” *Ecol Inform*, vol. 63, p. 101289, Jul. 2021, doi: 10.1016/j.ecoinf.2021.101289.
- [15] D. Palma, F. Blanchini, and P. L. Montessoro, “A system-theoretic approach for image-based infectious plant disease severity estimation,” *PLoS One*, vol. 17, no. 7, p. e0272002, Jul. 2022, doi: 10.1371/journal.pone.0272002.
- [16] L. Chen, S. Li, Q. Bai, J. Yang, S. Jiang, and Y. Miao, “Review of Image Classification Algorithms Based on Convolutional Neural Networks,” *Remote Sens (Basel)*, vol. 13, no. 22, p. 4712, Nov. 2021, doi: 10.3390/rs13224712.
- [17] S. Y. Alaba *et al.*, “Class-Aware Fish Species Recognition Using Deep Learning for an Imbalanced Dataset,” *Sensors*, vol. 22, no. 21, p. 8268, Oct. 2022, doi: 10.3390/s22218268.

- [18] M. Heydarian, T. E. Doyle, and R. Samavi, "MLCM: Multi-Label Confusion Matrix," *IEEE Access*, vol. 10, pp. 19083–19095, 2022, doi: 10.1109/ACCESS.2022.3151048.
- [19] D. Krstinić, A. K. Skelin, I. Slapničar, and M. Braović, "Multi-Label Confusion Tensor," *IEEE Access*, vol. 12, pp. 9860–9870, 2024, doi: 10.1109/ACCESS.2024.3353050.
- [20] W. G. Pamungkas, M. I. P. Wardhana, Z. Sari, and Y. Azhar, "Leaf Image Identification: CNN with EfficientNet-B0 and ResNet-50 Used to Classified Corn Disease," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 2, pp. 326–333, Mar. 2023, doi: 10.29207/resti.v7i2.4736.
- [21] R. Firmansyah and N. Nafi'iyah, "Identifying Types of Corn Leaf Diseases with Deep Learning," *Journal of Intelligent System and Computation*, vol. 6, no. 1, pp. 18–23, May 2024, doi: 10.52985/insyst.v6i1.347.
- [22] V. Ayumi, "Classification of Plant Diseases Based on Rice Leaf Image Analysis Using SVM and CLAHE Methods," *JSAI (Journal Scientific and Applied Informatics)*, vol. 7, no. 3, pp. 699–704, Nov. 2024, doi: 10.36085/jsai.v7i3.7559.
- [23] R. Kurniawan and L. Sunardi, "Integration of Image Enhancement Technique with DenseNet201 Architecture for Identifying Grapevine Leaf Disease," *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 24, no. 2, pp. 333–346, Mar. 2025, doi: 10.30812/matrik.v24i2.4137.