

TESIS

**DETEKSI PENYAKIT DAUN TOMAT BERBASIS CNN:
MODIFIKASI RESNET50 DENGAN CBAM DAN
PERBANDINGAN KINERJA DENGAN INCEPTIONV3**



disusun oleh

CHRISTIN SOYAN DENGEN

23.51.2461

Konsentrasi : Digital Transformation Intelligence

**FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2025**

TESIS
DETEKSI PENYAKIT DAUN TOMAT BERBASIS CNN:
MODIFIKASI RESNET50 DENGAN CBAM DAN
PERBANDINGAN KINERJA DENGAN INCEPTIONV3

TOMATO LEAF DISEASE DETECTION USING
CONVOLUTIONAL NEURAL NETWORKS: A MODIFIED
RESNET-50 WITH CBAM AND PERFORMANCE
COMPARISON WITH INCEPTIONV3

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



disusun oleh

CHRISTIN SOYAN DENGEN

23.51.2461

Konsentrasi : Digital Transformation Intelligence

FAKULTAS ILMU KOMPUTER
UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA

2025

HALAMAN PERSETUJUAN

**DETEKSI PENYAKIT DAUN TOMAT BERBASIS CNN: MODIFIKASI
RESNET50 DENGAN CBAM DAN PERBANDINGAN KINERJA DENGAN
INCEPTIONV3**

**TOMATO LEAF DISEASE DETECTION USING CONVOLUTIONAL
NEURAL NETWORKS: A MODIFIED RESNET-50 WITH CBAM AND
PERFORMANCE COMPARISON WITH INCEPTIONV3**

yang disusun dan diajukan oleh

**Christin Soyan Dengan
23.51.2461**

telah disetujui oleh Dosen Pembimbing Teori
pada tanggal 10 November 2025

Dosen Pembimbing,



Alva Hendi Muhammad, S.T., M.Eng., Ph.D
NIK. 190302493

HALAMAN PENGESAHAN

DETEKSI PENYAKIT DAUN TOMAT BERBASIS CNN: MODIFIKASI
RESNET50 DENGAN CBAM DAN PERBANDINGAN KINERJA DENGAN
INCEPTIONV3

TOMATO LEAF DISEASE DETECTION USING CONVOLUTIONAL
NEURAL NETWORKS: A MODIFIED RESNET-50 WITH CBAM AND
PERFORMANCE COMPARISON WITH INCEPTIONV3

yang disusun dan diajukan oleh

Christin Soyan Dengan

23.51.2461

Telah dipertahankan di depan Dewan Penguji
pada tanggal 10 November 2025

Susunan Dewan Penguji

Nama Penguji

Dr. Andi Sunyoto, M.Kom
NIK. 190302052

Dr. Arief Servanto, S.Si., M.T
NIK. 190302036

Alva Hendi Muhammad, S.T., M.Eng., Ph.D
NIK. 190302493

Tanda Tangan



Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer
Tanggal 10 November 2025

DEKAN FAKULTAS ILMU KOMPUTER



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

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Christin Soyan Dengan
NIM : 23.51.2461

Menyatakan bahwa Tesis dengan judul berikut:

Deteksi Penyakit Daun Tomat Berbasis Cnn: Modifikasi Resnet50 Dengan Cham Dan Perbandingan Kinerja Dengan Inceptionv3

Dosen Pembimbing: Alva Hendi Muhammad, S.T., M.Eng., Ph.D

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM 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 dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini.
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM 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 pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi.

Yogyakarta, 10 November 2025

Yang Menyatakan,



Christin Soyan Dengan

HALAMAN PERSEMBAHAN

Puji dan syukur saya panjatkan kepada Tuhan Yesus Kristus atas kasih, penyertaan, dan anugerah-Nya sehingga tesis ini dapat terselesaikan dengan baik.

Dengan penuh rasa hormat dan syukur, karya ini saya persembahkan kepada:

1. Kedua orang tua saya atas kasih, doa, dan dukungan yang tiada henti.
2. Kakak-kakak saya atas semangat dan dorongan yang selalu diberikan.
3. Bapak Alva Hendi Muhammad, S.T, M.Eng., Ph.D selaku dosen pembimbing yang telah memberikan bimbingan dan arahan dengan penuh kesabaran.
4. Orang-orang yang hadir dalam perjalanan hidup saya, yang telah memberikan doa, dukungan, serta semangat dalam menyelesaikan tesis ini.
5. Keluarga besar MTI AMIKOM Yogyakarta Angkatan 31, atas kebersamaan dan dukungan selama masa perkuliahan.

Tesis ini merupakan ungkapan syukur atas segala doa, kasih, dan dukungan yang telah mengiringi langkah saya hingga akhir.

KATA PENGANTAR

Puji dan syukur penulis panjatkan kepada Tuhan Yesus Kristus atas kasih, penyertaan, serta berkat-Nya sehingga tesis ini dapat diselesaikan dengan baik. Tesis ini disusun sebagai salah satu syarat untuk memperoleh gelar Magister Komputer pada Program Pascasarjana Universitas AMIKOM Yogyakarta.

Dalam proses penyusunan tesis ini, penulis menyadari bahwa terselesainya penelitian ini tidak terlepas dari bantuan, dukungan, dan bimbingan dari berbagai pihak. Oleh karena itu, dengan penuh rasa hormat, penulis menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Bapak Dr. Ir. M. Suyanto, M.M., selaku Rektor Universitas AMIKOM Yogyakarta.
2. Bapak Robert Marco., M.T., Ph.D selaku Direktur Program Pascasarjana Universitas AMIKOM Yogyakarta.
3. Bapak Alva Hendi Muhammad, S.T., M.Eng., Ph.D., selaku Dosen Pembimbing yang telah dengan sabar memberikan bimbingan, arahan, dan masukan berharga selama proses penelitian dan penyusunan tesis ini.
4. Tim Dosen Penguji Program Pascasarjana Universitas AMIKOM Yogyakarta, atas saran dan koreksi yang membangun dalam penyempurnaan tesis ini.

5. Seluruh Dosen dan Staf Program Pascasarjana Universitas AMIKOM Yogyakarta, atas ilmu, bantuan, serta pelayanan yang diberikan selama masa studi.
6. Kedua orang tua dan keluarga tercinta, atas doa, kasih, dan dukungan yang tiada henti selama proses perkuliahan hingga terselesaikannya tesis ini.
7. Rekan-rekan MTI AMIKOM Yogyakarta Angkatan 31, atas semangat, kebersamaan, dan kerja sama yang telah memberikan banyak pengalaman berharga selama menempuh studi.

Penulis menyadari bahwa tesis ini masih memiliki keterbatasan. Oleh karena itu, penulis sangat mengharapkan kritik dan saran yang bersifat membangun demi penyempurnaan karya ilmiah ini di masa yang akan datang. Semoga tesis ini dapat memberikan manfaat dan menjadi referensi bagi pihak-pihak yang berkepentingan dalam bidang yang relevan.

Yogyakarta, 01 November 2025

Christin Soyan Dengen

DAFTAR ISI


HALAMAN JUDUL	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
HALAMAN PERNYATAAN KEASLIAN TESIS	v
HALAMAN PERSEMBAHAN	vi
KATA PENGANTAR	vii
DAFTAR ISI	ix
DAFTAR TABEL	xii
DAFTAR GAMBAR	xiii
DAFTAR LAMPIRAN	Error! Bookmark not defined.
DAFTAR LAMBANG DAN SINGKATAN	xiv
DAFTAR ISTILAH	xv
INTISARI	xvii
ABSTRACT	xviii
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah	5
1.4 Tujuan Penelitian	6
1.5 Manfaat Penelitian	7
BAB 2 TINJAUAN PUSTAKA	8

2.1	Tinjauan Pustaka.....	8
2.2	Keaslian Penelitian.....	14
2.3	Landasan Teori.....	16
2.3.1	Penyakit pada Daun Tomat dan Pentingnya Deteksi Dini.....	16
2.3.2	Pengantar Machine Learning dan Deep Learning.....	17
2.3.3	Convolutional Neural Network (CNN).....	20
2.3.4	Convolutional Neural Network (CNN) Arsitektur Resnet-50.....	24
2.3.5	Convolutional Neural Network (CNN) Arsitektur Resnet-50 dengan CBAM	26
2.3.7	Metrik Evaluasi Kinerja Model CNN.....	31
2.3.8	Tantangan dalam Deteksi Penyakit pada Daun Tomat di Lapangan.....	32
2.3.9	Perbandingan Metode Deteksi Penyakit pada Tanaman.....	32
BAB 3	METODE PENELITIAN.....	33
3.1	Jenis, Sifat, dan Pendekatan Penelitian.....	33
3.2	Metode Pengumpulan Data.....	33
3.3	Metode Analisis Data.....	34
3.4	Alur Penelitian.....	35
BAB 4	HASIL PENELITIAN DAN PEMBAHASAN.....	39
4.1.	Dan Pengumpulan Data.....	39
4.2.	Preprocessing Data.....	41
4.3.	Skenario Pengujian.....	42
4.3.1	Convolutional Neural Network Arsitektur Resnet-50.....	42
4.3.2	Convolutional Neural Network Arsitektur Resnet-50 dengan Convolutional Block Attention Module (CBAM).....	43

4.4.3	<i>Convolutional Neural Network</i> Arsitektur InceptionV3	43
4.4.	Modifikasi Parameter.....	44
4.5.	<i>Split Data</i>	45
4.6.	Skenario Penelitian	45
4.6.1	<i>Convolutional Neural Network</i> Arsitektur Resnet-50.....	46
4.6.2	<i>Convolutional Neural Network</i> Arsitektur Resnet-50 dengan <i>Convolutional Block Attention Module (CBAM)</i>	47
4.6.3	<i>Convolutional Neural Network</i> Arsitektur InceptionV3.....	49
4.7.	Evaluasi Model.....	50
4.7.1	<i>Convolutional Neural Network</i> Arsitektur Resnet-50.....	51
4.7.2	<i>Convolutional Neural Network</i> Arsitektur Resnet-50 with <i>Convolutional Block Attention Module (CBAM)</i>	58
4.7.3	<i>Convolutional Neural Network</i> Arsitektur InceptionV3.....	64
4.8.	Analisis Hasil	71
BAB 5	PENUTUP.....	78
5.1	Kesimpulan	78
5.2	Saran.....	79
DAFTAR PUSTAKA	81

DAFTAR TABEL

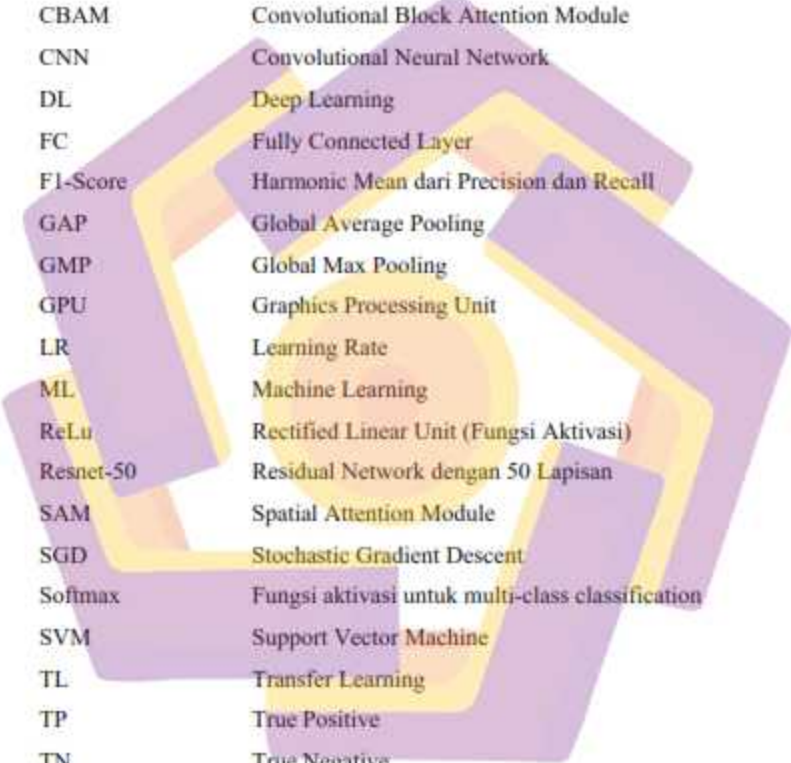
Tabel 2. 2 Matriks literatur review dan posisi penelitian.....	14
Tabel 4. 1 Jumlah Data Penyakit Daun Tomat	40
Tabel 4. 2 Hasil Training	75



DAFTAR GAMBAR

Gambar 2. 1. Arsitektur Convolutional Neural Network	21
Gambar 2. 2. Convolutional Block Attention Module	27
Gambar 2. 3. Channel Attention Module	28
Gambar 2. 4. Spatial Attention Module	28
Gambar 3. 1. Alur Penelitian	35
Gambar 4. 1. Contoh gambar dataset	41
Gambar 4. 2. Grafik Akurasi Metode CNN Arsitektur Resnet-50	52
Gambar 4. 3. Grafik Loss Metode CNN Arsitektur Resnet-50	53
Gambar 4. 4. <i>Confusion Matrix</i> Metode CNN Arsitektur Resnet-50	53
Gambar 4. 5. <i>Classification Report</i> Metode CNN Arsitektur Resnet-50	57
Gambar 4. 6. Grafik Accuracy CNN Arsitektur Resnet-50 with CBAM	58
Gambar 4. 7. Grafik Loss CNN Arsitektur Resnet-50 with CBAM	59
Gambar 4. 8. Confusion Matrix CNN Arsitektur Resnet-50 with CBAM	60
Gambar 4. 9. Classification Report CNN Arsitektur Resnet-50 with CBAM	64
Gambar 4. 10. Grafik Accuracy Convolutional Neural Network Arsitektur InceptionV3	65
Gambar 4. 11. Grafik Loss Convolutional Neural Network Arsitektur InceptionV3	66
Gambar 4. 12. Confusion Matrix <i>Convolutional Neural Network</i>	67
Gambar 4. 13. Classification Report CNN Arsitektur InceptionV3	71
Gambar 4. 14. Grafik Perbandingan Metrik Evaluasi	72

DAFTAR LAMBANG DAN SINGKATAN



AI	Artificial Intelligence (Kecerdasan Buatan)
API	Application Programming Interface
CAM	Channel Attention Module
CBAM	Convolutional Block Attention Module
CNN	Convolutional Neural Network
DL	Deep Learning
FC	Fully Connected Layer
F1-Score	Harmonic Mean dari Precision dan Recall
GAP	Global Average Pooling
GMP	Global Max Pooling
GPU	Graphics Processing Unit
LR	Learning Rate
ML	Machine Learning
ReLU	Rectified Linear Unit (Fungsi Aktivasi)
Resnet-50	Residual Network dengan 50 Lapisan
SAM	Spatial Attention Module
SGD	Stochastic Gradient Descent
Softmax	Fungsi aktivasi untuk multi-class classification
SVM	Support Vector Machine
TL	Transfer Learning
TP	True Positive
TN	True Negative
FP	False Positive
FN	False Negative

DAFTAR ISTILAH

Accuracy	Persentase prediksi yang benar dari seluruh data yang diuji oleh model.
Augmentasi Data	Teknik memperbanyak dan memvariasikan data dengan rotasi, flipping, zoom, dan perubahan pencahayaan agar model lebih robust.
CBAM (Convolutional Block Attention Module)	Modul attention yang meningkatkan fokus model pada fitur penting melalui <i>Channel Attention</i> dan <i>Spatial Attention</i> .
Channel Attention	Mekanisme dalam CBAM yang menentukan channel fitur mana yang harus diberi penekanan karena paling relevan.
CNN (Convolutional Neural Network)	Arsitektur jaringan saraf untuk pengolahan citra yang mengekstraksi fitur visual secara otomatis.
Confusion Matrix	Matriks evaluasi yang menunjukkan jumlah prediksi benar dan salah dalam tiap kelas.
Convolution	Operasi menggunakan filter untuk mengekstraksi fitur seperti tepi, tekstur, atau pola pada gambar.
Dataset	Kumpulan citra daun tomat yang digunakan untuk pelatihan, validasi, dan pengujian model.
Epoch	Satu siklus pelatihan lengkap ketika seluruh data training melewati model sekali.
Early Stopping	Teknik menghentikan training ketika performa validasi tidak meningkat untuk mencegah overfitting.
Feature Map	Representasi hasil ekstraksi fitur yang dihasilkan oleh lapisan konvolusi.
Fine-Tuning	Penyesuaian bobot model pretrained agar sesuai dengan dataset baru.

F1-Score	Nilai gabungan precision dan recall yang digunakan pada data yang tidak seimbang.
InceptionV3	Arsitektur CNN yang menggunakan <i>parallel convolutions</i> dan <i>factorized convolution</i> untuk efisiensi dan akurasi.
Learning Rate	Parameter yang menentukan besar kecilnya perubahan bobot dalam setiap pembaruan saat training.
Loss	Nilai kesalahan prediksi yang dihitung selama pelatihan model.
Max Pooling	Teknik reduksi dimensi dengan memilih nilai maksimum dari area tertentu pada feature map.
Precision	Rasio prediksi positif yang benar dibandingkan total prediksi positif yang dihasilkan model.
Recall	Rasio data positif yang berhasil dideteksi model dibandingkan total data positif sebenarnya.
ResNet-50	Arsitektur CNN dengan 50 lapisan yang menggunakan residual learning untuk mengatasi vanishing gradient.
Residual Learning	Teknik pada ResNet yang menggunakan skip connection untuk mempermudah pelatihan jaringan yang dalam.
Softmax	Fungsi aktivasi yang menghasilkan probabilitas pada klasifikasi multi-kelas.
Spatial Attention	Mekanisme CBAM yang menekankan area spasial penting pada citra agar lebih diperhatikan model.
Split Data	Pembagian dataset menjadi data training, validasi, dan testing.

INTISARI


Penyakit daun tomat berdampak signifikan terhadap hasil panen, terutama di sektor pertanian tropis. Penelitian ini bertujuan untuk mengklasifikasikan penyakit daun tomat menggunakan tiga arsitektur deep learning, yaitu ResNet-50, ResNet-50 dengan modul Convolutional Block Attention Module (CBAM), dan InceptionV3. Dataset yang digunakan berasal dari Kaggle dan terdiri dari 10 kelas penyakit. Untuk meningkatkan generalisasi model, diterapkan metode transfer learning, augmentasi data, serta teknik regulasi seperti EarlyStopping. Evaluasi dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score. Hasil menunjukkan bahwa ResNet-50 dengan CBAM memperoleh akurasi tertinggi sebesar 97%, sedikit lebih tinggi dari ResNet-50 standar 96%, sedangkan InceptionV3 menunjukkan performa terendah 87%. Penambahan CBAM meningkatkan kemampuan model dalam mengenali fitur spasial dan channel yang relevan, sehingga akurasi klasifikasi meningkat. Temuan ini menunjukkan bahwa ResNet-50 dengan CBAM merupakan solusi akurat dan efisien untuk deteksi otomatis penyakit daun tomat dan berpotensi diterapkan dalam sistem pertanian cerdas.

Kata kunci: CNN, ResNet-50, CBAM, InceptionV3, penyakit daun tomat, deteksi penyakit

ABSTRACT

Tomato leaf diseases significantly impact crop yields, especially in tropical agriculture. This study focuses on classifying tomato leaf diseases using three deep learning architectures: ResNet-50, ResNet-50 with Convolutional Block Attention Module (CBAM), and InceptionV3. The dataset, sourced from Kaggle, consists of 10 disease classes. To enhance generalization, transfer learning, data augmentation, and regularization techniques such as EarlyStopping were applied. Each model was evaluated using accuracy, precision, recall, and F1-score. Results show that the ResNet-50 + CBAM model achieved the highest accuracy at 97%, slightly outperforming the standard ResNet-50 96%, while InceptionV3 recorded the lowest performance (87.70%). The addition of CBAM improved the model's ability to focus on relevant spatial and channel features, enhancing classification performance. These findings indicate that ResNet-50 with CBAM provides an accurate and efficient solution for automated detection of tomato leaf diseases, with strong potential for real-world implementation in smart farming systems.

Keyword: CNN, ResNet-50, CBAM, InceptionV3, tomato leaf disease, disease detection



BAB I

PENDAHULUAN

1.1 Latar Belakang

Di banyak negara, termasuk Indonesia, tomat merupakan produk pertanian yang penting dan tanaman yang dibudidayakan secara luas [1]. Tomat memiliki nilai ekonomi yang tinggi karena digunakan sebagai bahan makanan dan industri pangan, serta didukung oleh hasil panen yang tinggi, perpanjangan musim, dan peningkatan produktivitas melalui teknik produksi seperti terowongan dan pencangkakan [2]. Namun, berbagai jenis penyakit mempengaruhi produksi tomat [3]. Penyakit pada daun tomat seperti bercak bakteri, bercak target, dan keriting daun kuning tomat dapat menyebabkan penurunan hasil panen yang signifikan, bahkan hingga kegagalan total jika tidak dideteksi dan ditangani dengan cepat [4]. Salah satu ancaman utama adalah *tomato leaf miner*, yang dapat menyebabkan kerugian panen hingga 80-100% akibat penyebarannya yang cepat, terutama karena perubahan iklim [5], [6]. Metode konvensional seperti pengamatan langsung oleh petani sering kali tidak efisien dan subjektif, terutama di lingkungan lapangan yang kompleks. Oleh karena itu, dibutuhkan metode berbasis teknologi yang dapat mendeteksi penyakit secara otomatis dan akurat. Selain itu, model yang terlalu kompleks dapat meningkatkan beban komputasi dan tidak cocok digunakan pada perangkat pertanian dengan sumber daya terbatas. Oleh karena itu, dibutuhkan pendekatan yang tidak hanya akurat, tetapi juga ringan dan efisien.

Beberapa penelitian sebelumnya telah menerapkan pendekatan machine learning dalam mendeteksi penyakit tomat [7], seperti Support Vector Machine (SVM), Random Forest (RF), Naïve Bayes dalam bidang. Namun, belum menghasilkan akurasi yang optimal dalam mendeteksi penyakit tomat [8]. Di sisi lain, Convolutional Neural Network (CNN) telah terbukti mampu mengenali pola penyakit dari citra daun secara otomatis dan akurat, menjadikannya salah satu metode unggulan dalam deteksi penyakit tanaman. Arsitektur CNN seperti ResNet dan Inception telah digunakan secara luas untuk klasifikasi visual yang kompleks, termasuk deteksi penyakit tanaman, karena kemampuannya dalam mengekstraksi fitur mendalam dari data citra.

Namun demikian, masih terdapat beberapa permasalahan umum dalam penerapan CNN untuk deteksi penyakit daun tomat. Permasalahan utama adalah tingginya kemiripan warna (chrominance) antara daun sehat dan daun yang terinfeksi, ketidakseimbangan data antar kelas penyakit, serta variasi pencahayaan dan noise yang sering muncul pada citra hasil pengambilan di lapangan (X. Chen et al., 2020; Wu, Chen, & Meng, 2020). Selain itu, model CNN konvensional seperti ResNet-50 hanya mengekstraksi fitur secara hierarkis tanpa kemampuan adaptif untuk menentukan area citra yang paling relevan terhadap gejala penyakit. Akibatnya, fitur penting seperti bercak kecil, perubahan warna halus, dan tepi daun menguning sering kali tertutupi oleh fitur latar belakang yang tidak relevan, sehingga menurunkan akurasi klasifikasi.

Sebenarnya, arsitektur CNN seperti ResNet-50 telah menunjukkan kemampuan yang baik dalam mengenali pola visual penyakit pada daun tomat,

termasuk mendeteksi perubahan warna, pola bercak, dan tekstur yang menjadi indikator gejala penyakit. Namun, dalam penerapannya pada citra lapangan yang memiliki tingkat variasi pencahayaan, orientasi daun, dan kondisi latar belakang yang kompleks, model ini masih menghadapi keterbatasan. ResNet-50 sering kali tidak dapat secara konsisten menentukan area mana pada citra yang paling relevan untuk proses klasifikasi, sehingga perhatian model kadang terarah pada bagian daun yang sehat atau area di luar objek utama. Akibatnya, fitur penting seperti bercak kecil, perubahan warna halus, atau tepi daun yang menguning dapat terlewat dan menyebabkan penurunan akurasi prediksi. Oleh karena itu, dibutuhkan mekanisme tambahan yang mampu membantu model dalam memfokuskan perhatian pada area yang benar-benar menunjukkan gejala penyakit. Pendekatan ini diharapkan dapat meningkatkan kemampuan CNN dalam memahami konteks spasial dan memperbaiki hasil klasifikasi pada kondisi citra yang beragam dan kompleks.

Berdasarkan kondisi tersebut, penelitian ini menemukan bahwa masih terdapat kesenjangan dalam penelitian sebelumnya, di mana model CNN konvensional belum mampu secara optimal memusatkan perhatian pada area penting pada citra daun tomat. Kondisi ini menyebabkan detail penting seperti bercak kecil atau perubahan warna halus sering tidak tertangkap dengan baik oleh model. Beberapa penelitian, seperti yang dilakukan oleh Liu et al. (2021), menunjukkan bahwa penambahan attention mechanism berupa Convolutional Block Attention Module (CBAM) pada arsitektur ResNet dapat membantu model lebih fokus pada fitur yang relevan dan mengabaikan fitur yang tidak penting.

sehingga mampu meningkatkan akurasi hingga 97,92%. Berdasarkan temuan tersebut, penelitian ini mengusulkan integrasi modul CBAM ke dalam arsitektur ResNet-50 untuk meningkatkan kemampuan model dalam mendeteksi penyakit daun tomat secara lebih adaptif. Selain itu, penelitian ini juga melakukan perbandingan antara ResNet-50 standar, ResNet-50 dengan CBAM, dan InceptionV3 untuk menilai sejauh mana penerapan mekanisme perhatian ini dapat meningkatkan akurasi dan kestabilan model.

Dengan pendekatan ini, penelitian ini diharapkan dapat menghasilkan model deteksi penyakit daun tomat yang lebih akurat, efisien, dan siap diterapkan di lingkungan pertanian nyata. Selain itu, penelitian ini memberikan kontribusi dalam penggunaan model Convolutional Neural Network (CNN) dalam mendeteksi penyakit pada daun tomat guna meningkatkan efisiensi pertanian yang dapat membantu petani dalam mendeteksi penyakit lebih cepat dan mengambil tindakan yang lebih tepat guna meningkatkan produktivitas pertanian.

1.2 Rumusan Masalah

Permasalahan yang dihadapi dalam pengembangan sistem deteksi penyakit daun tomat menggunakan Convolutional Neural Network (CNN) adalah tantangan dalam mencapai akurasi yang tinggi serta kemampuan generalisasi model terhadap berbagai jenis penyakit. Penyakit pada daun tomat, jika tidak terdeteksi dengan cepat dan akurat, dapat menyebabkan kerugian yang signifikan dalam produksi pertanian. Oleh karena itu, penting untuk menggali berbagai faktor yang memengaruhi kinerja model dan mengeksplorasi metrik evaluasi yang lebih komprehensif. Rumusan masalah yang akan dikaji dalam penelitian ini meliputi:

- a. Bagaimana performa arsitektur CNN ResNet-50 standar, ResNet-50 dengan penambahan CBAM (Convolutional Block Attention Module), dan InceptionV3 dalam mendeteksi penyakit pada daun tomat?
- b. Berapa tingkat akurasi, presisi, recall, dan F1-Score deteksi penyakit daun tomat yang dihasilkan oleh masing-masing skenario arsitektur CNN yang telah digunakan?
- c. Bagaimana pengaruh penambahan attention module (CBAM) terhadap peningkatan akurasi dan efisiensi komputasi model deteksi penyakit daun tomat dibandingkan dengan arsitektur standar?

1.3 Batasan Masalah

Untuk menjaga fokus dan ruang lingkup penelitian, batasan masalah yang ditetapkan dalam penelitian ini meliputi beberapa aspek sebagai berikut:

- a. Penelitian ini hanya akan fokus pada deteksi penyakit daun tomat, termasuk bacterial spot, early blight, late blight, leaf mold, septoria leaf spot, target spot, tomato mosaic virus, tomato yellow leaf curl virus, dan two-spotted spider mite serta tidak mencakup jenis penyakit lain yang mungkin mempengaruhi tanaman tomat.
- b. Penelitian ini menggunakan Convolutional Neural Network (CNN) dengan arsitektur ResNet-50 standar, ResNet-50 dengan penambahan CBAM (Convolutional Block Attention Module), dan InceptionV3. Model lain di luar dua arsitektur tersebut tidak dibahas dalam penelitian ini.
- c. Dataset yang digunakan dalam penelitian ini adalah dataset yang lebih luas dan representatif yang mencakup gambar daun tomat yang terinfeksi berbagai jenis

penyakit, namun tidak akan mencakup dataset yang tidak relevan atau spesifik untuk tanaman lain.

- d. Teknik yang diterapkan untuk meningkatkan akurasi model meliputi augmentasi data, transfer learning, fine-tuning, regulasi (Dropout, Batch Normalization, dan Early Stopping). Teknik lainnya tidak dibahas dalam penelitian ini. Penelitian ini akan mempertimbangkan kondisi pencahayaan dan kualitas gambar yang bervariasi dalam evaluasi model, namun tidak akan membahas faktor-faktor lingkungan lainnya yang mungkin mempengaruhi pertumbuhan tanaman tomat secara umum.
- e. Evaluasi performa model dilakukan berdasarkan akurasi, presisi, recall, F1-score.

1.4 Tujuan Penelitian

Tujuan dari penelitian diuraikan berdasarkan rumusan masalah meliputi:

- a. Menganalisis performa tiga skenario arsitektur CNN, yaitu ResNet-50 standar, ResNet-50 dengan CBAM (Convolutional Block Attention Module), dan InceptionV3, dalam mendeteksi penyakit pada daun tomat.
- b. Menentukan tingkat akurasi, presisi, recall, dan F1-Score yang dicapai oleh masing-masing model CNN berdasarkan hasil deteksi penyakit daun tomat.
- c. Mengevaluasi pengaruh penambahan CBAM (Convolutional Block Attention Module) terhadap akurasi dan efisiensi komputasi model dibandingkan dengan arsitektur CNN standar tanpa attention.
- d. Memberikan rekomendasi arsitektur model yang optimal dalam mendeteksi penyakit daun tomat berdasarkan hasil analisis akurasi dan efisiensi komputasi.

1.5 Manfaat Penelitian

Berdasarkan latar belakang yang diangkat, maka dibuat manfaat yang akan diselesaikan dalam penelitian ini, antara lain :

- a. Penelitian ini akan memberikan kontribusi signifikan terhadap ilmu pengetahuan dalam pengembangan metode deteksi penyakit tanaman menggunakan Convolutional Neural Network (CNN), serta menjadi referensi bagi penelitian selanjutnya.
- b. Sistem deteksi yang dikembangkan akan mampu memberikan deteksi cepat dan akurat terhadap penyakit daun tomat, membantu petani mengambil tindakan preventif dan meningkatkan produktivitas.
- c. Penelitian ini Mengoptimalkan efisiensi model CNN dengan teknik regulasi dan komputasi ringan, serta mendorong pemanfaatan AI dalam sektor pertanian.

BAB 2

TINJAUAN PUSTAKA

2.1 Tinjauan Pustaka

Tinjauan penelitian mengenai deteksi penyakit pada daun tomat telah berkembang pesat seiring dengan kemajuan teknologi dalam bidang kecerdasan buatan, khususnya pada metode deep learning. [3] mengembangkan model deteksi dini dan klasifikasi penyakit daun tomat dengan menggunakan Convolutional Neural Network (CNN), mencapai akurasi 98,49%. Penelitian ini menggunakan dataset yang terdiri dari sembilan jenis penyakit dan satu kategori sehat. Meskipun model ini menunjukkan performa yang tinggi, tantangan utama yang dihadapi adalah mengatasi variasi kondisi pencahayaan dan kualitas gambar yang dapat mempengaruhi akurasi deteksi. Hal ini menunjukkan bahwa pengembangan lebih lanjut masih diperlukan untuk meningkatkan kemampuan model dalam kondisi lingkungan yang lebih beragam.

Selanjutnya, penelitian oleh [5] menggunakan pendekatan segmentasi berbasis Mask R-CNN untuk mendeteksi serangga tomat leaf miner, yang dapat menyebabkan kerugian besar pada produksi tanaman tomat. Pendekatan segmentasi ini terbukti lebih unggul dibandingkan metode klasifikasi biasa dalam hal presisi, recall, dan F1-score, terutama dalam mendeteksi area yang terinfeksi dengan lebih akurat. Namun, studi ini juga menunjukkan bahwa model tersebut masih memerlukan optimasi lebih lanjut untuk meningkatkan akurasi pada kondisi lingkungan yang tidak seragam, seperti variasi intensitas cahaya dan keberadaan objek pengganggu di latar belakang gambar. Keterbatasan ini menggarisbawahi

perlunya penelitian lebih lanjut untuk mengatasi berbagai kendala yang muncul dalam penerapan teknologi deteksi di lingkungan nyata.

Sementara itu, [9] mengusulkan arsitektur CNN yang lebih kompak dengan hanya enam lapisan untuk klasifikasi penyakit daun tomat. Model ini berhasil mencapai akurasi hingga 99,70% dengan menggunakan dataset PlantVillage yang terdiri dari sepuluh kelas (sembilan penyakit dan satu kategori sehat). Keunggulan dari arsitektur ini adalah efisiensi komputasinya yang lebih tinggi, memungkinkan penerapannya pada perangkat dengan kapasitas memori dan prosesor yang terbatas. Meskipun demikian, penelitian ini masih memiliki keterbatasan dalam hal variasi data yang digunakan, karena hanya memanfaatkan dataset PlantVillage yang tidak sepenuhnya mencerminkan kondisi nyata di lapangan. Selain itu, penggunaan teknik augmentasi data yang terbatas juga menjadi kendala dalam meningkatkan generalisasi model pada data baru yang tidak terlihat selama pelatihan.

[10] mengusulkan pendekatan hybrid deep learning yang memadukan dilated CNN berbasis atensi dengan regresi logistik untuk mendeteksi penyakit daun tomat. Model ini menggabungkan teknik pra-pemrosesan canggih dan sintesis gambar untuk meningkatkan akurasi, mencapai tingkat keberhasilan 96,6% pada data uji. Meski demikian, kompleksitas komputasi yang tinggi menjadi kendala dalam aplikasi praktis, terutama di perangkat dengan sumber daya terbatas. Selain itu, model ini kurang dievaluasi dalam kondisi lingkungan yang lebih dinamis dan bervariasi.

Penelitian oleh [6] memperkenalkan model ringan bernama LightMixer, yang dirancang untuk mendeteksi penyakit daun tomat secara otomatis dengan

menggunakan konvolusi ringan dan modul residual, mencapai akurasi 99,3% dengan hanya membutuhkan 1,5 juta parameter. Model ini menunjukkan efisiensi komputasi yang tinggi, namun penerapannya di lingkungan pertanian nyata masih terbatas karena variasi pencahayaan dan kompleksitas latar belakang yang dapat mempengaruhi kinerja deteksi

[11] mengembangkan model DCCAM-MRNet yang menggabungkan konvolusi dilatasi, koneksi residual, dan mekanisme perhatian koordinat untuk mendeteksi penyakit daun tomat. Meskipun model ini mencapai akurasi 94,3%, keterbatasan terkait dengan kompleksitas komputasi tetap menjadi perhatian utama, terutama dalam aplikasi di perangkat yang memiliki kapasitas pemrosesan dan memori yang rendah. Model ini menunjukkan bahwa meskipun arsitektur yang lebih kompleks dapat meningkatkan akurasi, efisiensi komputasi tetap menjadi faktor penting yang perlu dipertimbangkan

Dalam penelitian yang dilakukan oleh [12], dikembangkan suatu model CNN ringan (*lightweight CNN*) berbasis arsitektur ResNet yang diintegrasikan dengan beberapa jenis modul perhatian (*attention modules*) seperti CBAM (Convolutional Block Attention Module), Self-Attention (SA), dan Squeeze-and-Excitation (SE). Tujuan utama penelitian ini adalah untuk menciptakan model klasifikasi penyakit tanaman yang tidak hanya akurat, tetapi juga efisien secara komputasi. Model dengan arsitektur ringan ini bertujuan agar dapat diterapkan pada perangkat keras dengan sumber daya terbatas, seperti perangkat IoT atau *edge devices* yang umum digunakan dalam pertanian pintar (*smart farming*). Hasil penelitian menunjukkan bahwa integrasi modul perhatian mampu meningkatkan

akurasi deteksi penyakit hingga mencapai 99,69%, khususnya saat menggunakan CBAM. Selain itu, model ringan yang mereka kembangkan mampu mengurangi parameter jaringan hingga 16 kali dan kompleksitas jaringan hingga 23 kali dibandingkan model ResNet50 standar.

[13] juga menggunakan arsitektur CNN, tetapi lebih fokus pada penerapan *transfer learning* dengan model ResNet-50 yang telah dilatih sebelumnya. Mereka memodifikasi lapisan akhir dari model ini agar sesuai dengan tugas klasifikasi penyakit daun tomat yang terdiri dari enam kelas penyakit utama. Dalam studi ini, *data augmentation* memainkan peran penting untuk meningkatkan jumlah dan keberagaman data pelatihan, sehingga mengurangi kemungkinan *overfitting* dan meningkatkan generalisasi model. Teknik augmentasi seperti rotasi, flipping, scaling, dan cropping digunakan untuk memperbanyak dataset hingga empat kali lipat dari ukuran awal. Hasil dari pendekatan ini menunjukkan akurasi hingga 97%, yang menunjukkan efektivitas kombinasi *transfer learning* dan augmentasi data dalam klasifikasi penyakit daun tomat.

Selanjutnya, [14] dalam penelitiannya mengusulkan model klasifikasi penyakit daun tomat berbasis ResNet-50 yang telah dimodifikasi dan ditingkatkan melalui beberapa pendekatan strategis. Penelitian ini memanfaatkan *transfer learning* dari dataset penyakit tanaman berskala besar dan mengintegrasikan teknik augmentasi data lanjutan untuk mengatasi tantangan seperti variasi pencahayaan, sudut pengambilan gambar, dan tingkat keparahan gejala penyakit. Model yang dikembangkan tidak hanya menunjukkan akurasi tinggi (>95%), tetapi juga menunjukkan ketahanan yang sangat baik terhadap kondisi nyata di lapangan, yang

sering kali sangat bervariasi dan tidak terstandarisasi. Pendekatan ini menandai kemajuan penting dalam deteksi penyakit berbasis *deep learning*, karena berhasil mengatasi salah satu kelemahan utama dari sistem berbasis visual, yaitu ketidakmampuannya dalam mengenali fitur yang informatif di bawah kondisi yang tidak ideal.

Berdasarkan berbagai studi yang telah dikemukakan, dapat disimpulkan bahwa meskipun metode CNN dan *deep learning* lainnya telah menunjukkan efektivitas dalam deteksi penyakit tanaman, tantangan dalam hal generalisasi model terhadap variasi kondisi lingkungan dan efisiensi komputasi masih memerlukan perhatian lebih lanjut. Penelitian ini akan berfokus pada peningkatan kinerja model melalui penggunaan dataset yang lebih luas dan beragam, serta mengeksplorasi metrik evaluasi tambahan seperti presisi, recall, dan F1-score untuk mendapatkan gambaran yang lebih holistik mengenai kinerja model. Dengan pendekatan ini, penelitian diharapkan dapat menghasilkan sistem deteksi penyakit daun tomat yang tidak hanya akurat, tetapi juga adaptif terhadap kondisi lapangan yang dinamis, sehingga dapat memberikan kontribusi nyata bagi dunia pertanian.

Penelitian oleh [15] mengevaluasi kinerja empat arsitektur CNN pralatih VGG-16, VGG-19, ResNet, dan Inception V3 dalam klasifikasi penyakit daun tomat. Studi ini membandingkan performa model pada dua jenis dataset: satu dari laboratorium dan satu lagi dari lapangan (*real-world*). Hasilnya menunjukkan bahwa pendekatan *parameter tuning* memberikan hasil yang lebih baik dibanding sekadar menggunakan CNN sebagai *feature extractor*. Di antara semua model, **Inception V3** menunjukkan akurasi tertinggi, yaitu **99,6%** pada data laboratorium

dan 93,7% pada data lapangan. Temuan ini menekankan pentingnya penyesuaian model terhadap kondisi nyata di lapangan agar sistem klasifikasi penyakit tanaman lebih aplikatif dan andal.

Berdasarkan berbagai penelitian terdahulu, dapat disimpulkan bahwa metode CNN dan variasi pendekatannya, seperti integrasi modul perhatian, arsitektur ringan, serta pemanfaatan transfer learning, telah menunjukkan performa tinggi dalam mendeteksi penyakit daun tomat. Namun, tantangan seperti keterbatasan generalisasi terhadap kondisi lingkungan yang beragam, efisiensi komputasi, dan kebutuhan evaluasi model secara menyeluruh masih menjadi fokus penting untuk ditangani. Oleh karena itu, penelitian ini dilakukan dengan membandingkan tiga skenario arsitektur CNN, yaitu ResNet-50 standar, ResNet-50 dengan CBAM (Convolutional Block Attention Module), dan Inception V3. Tujuannya adalah untuk meningkatkan kinerja model deteksi penyakit daun tomat melalui arsitektur yang tidak hanya akurat, tetapi juga adaptif terhadap kondisi nyata di lapangan, dengan mengevaluasi model menggunakan metrik yang lebih komprehensif seperti akurasi, presisi, recall, dan F1-score.

2.2 Keaslian Penelitian

Tabel 2. 1 Matriks literatur review dan posisi penelitian

Deteksi Penyakit Diabetic Retinopathy Menggunakan Convolutional Neural Network Berbasis Arsitektur Efficientnetv2

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Deteksi Penyakit Tomat Melalui Citra Daun Menggunakan Metode Convolutional Neural Network	Roni Halim Saputra, Rito Cipta Sigitta Hariyono, Fathulloh. Universitas Peradaban, 2023	Mengembangkan model CNN sederhana (LeNet-5) untuk mendeteksi empat jenis penyakit daun tomat.	Model CNN sederhana mampu mendeteksi penyakit dengan akurasi 95%, menunjukkan potensi penggunaan CNN untuk klasifikasi penyakit tanaman	Model masih sederhana, belum diuji pada kondisi lapangan yang bervariasi, dan kurang optimal dalam menghadapi noise citra	Penelitian ini menggunakan arsitektur yang lebih kompleks (ResNet-50 dan InceptionV3) untuk meningkatkan akurasi dan ketahanan terhadap variasi citra.
2	Mobile Application for Tomato Plant Leaf Disease Detection Using DenseNet	I. N. Yulita et al., Jurnal Nasional Informatika, 2023	Menerapkan DenseNet dengan pendekatan <i>fine-tuning</i> dan mengintegrasikannya ke aplikasi mobile untuk deteksi penyakit daun tomat.	DenseNet memberikan akurasi 95,7% dan F1-score 95,4%, membuktikan efektivitas <i>deep transfer learning</i> dalam deteksi penyakit daun tomat	Model memiliki kompleksitas tinggi dan belum optimal untuk perangkat mobile dengan sumber daya terbatas.	Penelitian ini menekankan efisiensi dengan mengintegrasikan CBAM agar model tetap ringan namun akurat, berbeda dengan DenseNet yang lebih berat.
3	Classification of Tomato Leaf Diseases Using Transfer Learning with ResNet-50 Architecture	Raynold et al, Procedia Computer Science, 2025	Menggunakan pendekatan <i>transfer learning</i> pada arsitektur ResNet-50 untuk klasifikasi penyakit daun tomat.	Model mencapai akurasi 93% dan menunjukkan potensi ResNet-50 dalam mendeteksi penyakit tanaman.	Belum menerapkan mekanisme perhatian dan belum membandingkan hasil dengan arsitektur lain.	Penelitian ini mengembangkan ResNet-50 dengan menambahkan modul CBAM serta membandingkannya dengan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
						InceptionV3 untuk meningkatkan performa.
4	Tablet Defect Detection Based on Improved ResNet-CBAM	Y. Liu et al. <i>Sensors Journal</i> , 2021	Mengintegrasikan modul CBAM pada arsitektur ResNet untuk mendeteksi cacat pada permukaan tablet industri.	CBAM terbukti mampu meningkatkan akurasi hingga 97,92% dengan menyoroti fitur penting dan menekan fitur yang tidak relevan.	Penelitian masih terbatas pada domain industri, belum diterapkan pada citra alami atau tanaman.	Penelitian ini mengadaptasi pendekatan ResNet-CBAM ke domain pertanian untuk deteksi penyakit daun tomat.
5	Leaf Disease Detection Using Xception	Nurhikma Arifin et al., <i>JUTIF</i> 2024	Menggunakan arsitektur Xception untuk klasifikasi penyakit daun tomat.	Akurasi uji sebesar 85,84%.	Dataset kecil, model belum dioptimalkan, akurasi rendah.	Dibandingkan penelitian ini, hasilnya jauh lebih rendah karena belum menggunakan attention mechanism seperti CBAM.
6	Tomato Leaf Disease Detection Using DCCAM-MRNet	Y. Hu, <i>Computational Intelligence and Neuroscience</i> , 2022	Mengembangkan model DCCAM-MRNet dengan konvolusi dilatasi dan mekanisme perhatian untuk meningkatkan akurasi deteksi penyakit	Model mencapai akurasi 94,3% tetapi memiliki kompleksitas komputasi yang tinggi, yang dapat menjadi hambatan dalam implementasi praktis	Perlu optimasi lebih lanjut untuk mengurangi kompleksitas komputasi, terutama untuk aplikasi di perangkat dengan sumber daya terbatas	Penelitian ini bertujuan mengoptimalkan arsitektur CNN agar tetap akurat dan efisien tanpa meningkatkan kompleksitas

Source: Author (2007). Gunakan style Citation for Table AMIKOM

2.3 Landasan Teori

2.3.1 Penyakit pada Daun Tomat dan Pentingnya Deteksi Dini

Tomat merupakan salah satu komoditas pertanian bernilai tinggi yang banyak dibudidayakan di seluruh dunia karena manfaat ekonominya dalam industri makanan. Namun, tanaman ini rentan terhadap penyakit yang disebabkan oleh patogen seperti bakteri, jamur, dan virus, yang dapat merusak tanaman dan menurunkan kualitas serta kuantitas hasil panen. Penyakit umum yang menyerang daun tomat antara lain *bacterial spot*, *target spot*, dan *tomato yellow leaf curl virus* yang berdampak signifikan terhadap produktivitas tanaman. Serangan penyakit ini tidak hanya mengganggu proses fisiologis tanaman, tetapi juga dapat menyebabkan stres biotik yang berakibat pada turunnya daya tahan tanaman terhadap gangguan lingkungan lainnya. Dampak ini menimbulkan kerugian besar pada sektor pertanian dan menuntut metode deteksi dini yang akurat agar dapat dilakukan tindakan preventif [4]

Dalam buku *Plant Pathology* oleh Agrios (2005), dijelaskan bahwa deteksi dini penyakit tanaman menjadi faktor penting dalam pengendalian penyakit di lapangan. Pendekatan tradisional memerlukan inspeksi visual oleh ahli tanaman, yang rentan terhadap kesalahan manusia dan membutuhkan waktu yang lama. Teknologi berbasis pengenalan citra otomatis menawarkan pendekatan yang lebih efisien dan akurat dalam mengenali gejala penyakit pada tahap awal, sehingga dapat mengurangi penyebaran patogen (Agrios, 2005).

Dengan memanfaatkan teknologi pengenalan gambar berbasis deep learning, deteksi penyakit pada daun tomat dapat dilakukan dengan lebih cepat dan akurat, membantu petani dalam pengambilan keputusan yang lebih tepat [17]. Teknologi ini memungkinkan pemantauan tanaman secara berkelanjutan tanpa perlu kehadiran langsung ahli di lapangan, serta memberikan solusi praktis untuk skala pertanian besar maupun kecil. Selain itu, sistem otomatis dapat diintegrasikan dengan perangkat berbasis IoT (Internet of Things), sehingga hasil deteksi dapat langsung dikirimkan dan dianalisis secara real-time untuk respons yang lebih cepat.

2.3.2 Pengantar Machine Learning dan Deep Learning

Machine learning (ML) dan deep learning (DL) adalah cabang kecerdasan buatan yang memungkinkan sistem komputer untuk belajar dari data, tanpa membutuhkan program eksplisit untuk setiap tugas [18]. Keduanya bekerja dengan prinsip dasar bahwa mesin dapat meningkatkan performa dari waktu ke waktu dengan menganalisis dan mempelajari pola dari data historis [19]. Dalam konteks pertanian digital, teknologi ini membuka peluang besar dalam otomatisasi proses pengawasan dan diagnosa tanaman, yang sebelumnya sangat bergantung pada keterampilan manusia.

Machine learning bekerja melalui proses pelatihan model menggunakan data berlabel atau tidak berlabel, dan dapat digunakan dalam berbagai aplikasi seperti klasifikasi, regresi, hingga clustering [20]. Namun, seiring dengan meningkatnya kompleksitas data terutama data visual seperti citra daun tanaman yang mengandung banyak fitur spasial pendekatan deep learning menjadi lebih

unggul [21]. Deep learning, yang merupakan subbidang dari machine learning, menggunakan arsitektur jaringan saraf tiruan berlapis-lapis untuk mengekstrak representasi fitur dari data mentah secara bertahap dan otomatis [22]. Hal ini memungkinkan model untuk mengenali fitur yang sangat kompleks dan halus dari gambar, seperti warna bercak, tekstur permukaan daun, hingga bentuk tepi luka yang sulit dideteksi secara manual.

Convolutional Neural Network (CNN), sebagai salah satu pendekatan deep learning paling populer, telah terbukti menjadi solusi optimal untuk pemrosesan citra dalam mendeteksi pola kompleks pada gambar [23]. CNN dirancang secara khusus untuk menganalisis data visual, dan strukturnya yang terdiri dari lapisan konvolusi, pooling, dan fully connected layer membuatnya sangat efektif dalam mengekstraksi fitur spasial dan hierarkis dari gambar [24]. CNN memiliki kemampuan yang baik dalam tugas klasifikasi gambar karena memanfaatkan lapisan-lapisan konvolusi yang dapat mengekstrak fitur visual dengan detail, sehingga sangat berguna untuk mendeteksi penyakit pada daun tomat [25]

Menurut buku *Pattern Recognition and Machine Learning* karya Bishop (2006), deep learning mendukung proses pengenalan pola dalam berbagai disiplin, termasuk bidang pertanian berbasis citra, dengan meningkatkan akurasi dan efisiensi deteksi [26]. Deep learning menawarkan kemampuan untuk belajar dari volume data yang besar dan kompleks, serta secara otomatis menyesuaikan bobot-bobot internalnya agar dapat menggeneralisasi pola yang relevan dari citra tanaman yang terpapar berbagai kondisi pencahayaan, rotasi, dan noise [27].

CNN menjadi populer dalam penelitian ini karena kemampuannya untuk mengekstrak pola visual yang berkaitan dengan gejala penyakit daun, seperti perubahan warna, pola bintik, dan deformasi lainnya [24]. Lapisan konvolusi dalam CNN berperan seperti filter yang mampu menangkap detail spesifik dari input citra, seperti garis, tepi, dan tekstur, yang kemudian dikombinasikan melalui proses pooling dan aktivasi non-linear untuk menghasilkan representasi yang kuat dan diskriminatif [28].

Selain itu, CNN juga memiliki keunggulan dalam hal efisiensi parameter dan ketahanan terhadap translasi gambar, menjadikannya pilihan ideal untuk mendeteksi penyakit daun yang gejalanya dapat muncul dengan variasi posisi atau orientasi pada citra [29]. Melalui proses pelatihan dengan dataset citra penyakit tanaman yang representatif, CNN dapat belajar mengenali tanda-tanda penyakit secara otomatis tanpa memerlukan fitur buatan manusia (handcrafted features), yang sering kali subjektif dan tidak konsisten [30].


Dengan kemampuannya tersebut, CNN tidak hanya berfungsi sebagai alat klasifikasi, tetapi juga dapat dikembangkan untuk segmentasi dan deteksi objek, membuka peluang integrasi lebih lanjut dalam sistem pertanian presisi berbasis visi komputer. Oleh karena itu, pemanfaatan CNN dalam deteksi penyakit daun tomat dinilai sangat strategis dan inovatif dalam mendukung sistem pertanian yang adaptif, cerdas, dan berkelanjutan.

2.3.3 Convolutional Neural Network (CNN)

CNN adalah jaringan saraf tiruan khusus yang dirancang untuk pengenalan pola visual pada data grid, seperti citra [31]. CNN terdiri dari beberapa lapisan utama: lapisan konvolusi, lapisan pooling, dan fully connected. Lapisan konvolusi berfungsi mengekstraksi fitur penting dari gambar dengan menerapkan filter pada citra. Lapisan pooling mereduksi dimensi untuk menekan beban komputasi tanpa kehilangan informasi yang berarti. Buku Deep Learning oleh [25] menjelaskan bahwa CNN unggul dalam memproses data visual dan mengekstraksi fitur kompleks tanpa perlu campur tangan manusia secara langsung.

CNN telah digunakan secara luas dalam deteksi penyakit tanaman karena kemampuannya untuk mengenali tekstur, pola, dan warna yang mengindikasikan gejala penyakit pada daun tomat. Penelitian [3] yang menggunakan CNN untuk mendeteksi penyakit daun tomat menemukan bahwa metode ini mencapai akurasi tinggi pada berbagai jenis penyakit.

Dalam konteks deteksi penyakit pada daun tomat, CNN berperan penting dalam mengenali pola-pola gejala penyakit seperti perubahan warna, tekstur, atau bentuk yang muncul pada permukaan daun. Struktur arsitektur CNN pada dasarnya terdiri dari beberapa lapisan utama yang bekerja secara berurutan membentuk proses ekstraksi fitur hingga klasifikasi akhir [32].



Gambar 2. 1. Arsitektur Convolutional Neural Network

a. Input Layer

Lapisan input bertanggung jawab untuk menerima citra mentah yang akan diproses oleh jaringan. Dalam kebanyakan implementasi CNN, input berbentuk array berdimensi tiga (tinggi \times lebar \times saluran warna). Sebagai contoh, citra daun tomat berwarna mungkin memiliki resolusi 224×224 piksel dengan tiga saluran warna (RGB). Lapisan ini tidak melakukan pemrosesan apapun terhadap data, tetapi bertugas menyuplai citra ke lapisan-lapisan berikutnya untuk diekstraksi fitur-fiturnya. Keberadaan input layer sangat penting dalam memastikan bahwa dimensi dan format data sesuai dengan struktur arsitektur CNN.

b. Convolutional Layer

Lapisan konvolusi adalah komponen inti dalam CNN yang berfungsi mengekstraksi fitur lokal dari citra input. Proses ini dilakukan dengan cara menerapkan filter atau kernel berukuran kecil (misalnya 3×3 atau 5×5) yang bergerak melintasi seluruh bagian gambar. Setiap filter menghasilkan sebuah feature map yang merepresentasikan kemunculan pola tertentu seperti garis, tepi, atau tekstur.

Filter dalam lapisan ini belajar secara otomatis melalui proses pelatihan untuk mengenali fitur visual yang relevan dengan klasifikasi. Semakin dalam posisi convolutional layer dalam jaringan, maka semakin kompleks fitur yang dapat dikenali, seperti pola bercak, keriting, atau nekrosis pada daun tomat. Lapisan ini dapat terdiri dari beberapa filter sekaligus, yang masing-masing belajar mendeteksi jenis fitur yang berbeda.

c. Activation Layer (ReLU)

Setelah proses konvolusi, hasil feature map dilewatkan ke fungsi aktivasi. Fungsi aktivasi yang paling umum digunakan adalah ReLU (Rectified Linear Unit), yang menghitung nilai maksimum antara nol dan input. Secara matematis, fungsi ReLU dinyatakan sebagai:

$$f(x) = \max(0, x)$$

Tujuan utama dari fungsi aktivasi adalah untuk memperkenalkan non-linearitas ke dalam model. Tanpa fungsi ini, jaringan CNN hanya akan mampu merepresentasikan hubungan linear, yang tidak cukup untuk mengenali pola kompleks seperti gejala penyakit daun yang beragam. Fungsi ReLU juga membantu mempercepat proses pelatihan dan mencegah terjadinya permasalahan seperti vanishing gradient.

d. Pooling Layer

Lapisan pooling digunakan untuk mengurangi dimensi spasial dari feature map sambil tetap mempertahankan informasi yang paling penting. Metode pooling yang paling sering digunakan adalah **max pooling**, yang

mengambil nilai maksimum dari area kecil (misalnya 2×2) pada feature map. Proses ini menghasilkan peta fitur yang lebih kecil dan padat.

Pooling memiliki beberapa manfaat penting, yaitu mengurangi jumlah parameter yang harus dipelajari oleh model, mengurangi risiko overfitting, dan meningkatkan efisiensi komputasi. Selain itu, pooling juga membuat model lebih toleran terhadap pergeseran kecil dalam gambar (translation invariance), yang penting dalam konteks data daun tomat yang bisa memiliki posisi dan orientasi yang berbeda-beda.

e. Fully Connected Layer

Lapisan ini merupakan bagian akhir dari CNN yang bertugas menggabungkan seluruh fitur hasil ekstraksi dan menghasilkan prediksi kelas. Setelah melewati beberapa tahap konvolusi dan pooling, data yang dihasilkan akan diratakan (flattening) menjadi vektor satu dimensi, lalu diteruskan ke fully connected layer. Pada tahap ini, setiap neuron terhubung dengan semua neuron di lapisan sebelumnya, mirip seperti jaringan saraf tiruan biasa (Multilayer Perceptron).

Lapisan fully connected bertugas melakukan klasifikasi berdasarkan fitur-fitur yang telah dipelajari. Dalam konteks penelitian ini, output dari lapisan ini akan menentukan jenis penyakit daun tomat, seperti bacterial spot, early blight, atau healthy. Aktivasi akhir biasanya menggunakan fungsi **softmax** untuk klasifikasi multi-kelas, yang mengubah skor menjadi probabilitas.

f. Output Layer

Lapisan output menghasilkan prediksi akhir dari model dalam bentuk probabilitas untuk setiap kelas penyakit yang mungkin. Fungsi aktivasi yang digunakan tergantung pada jumlah dan jenis kelas: fungsi **softmax** digunakan untuk klasifikasi multi-kelas, sementara **sigmoid** digunakan untuk klasifikasi biner. Output layer memberikan informasi yang digunakan untuk mengambil keputusan, misalnya apakah daun tomat mengalami penyakit tertentu atau tidak.

2.3.4 Convolutional Neural Network (CNN) Arsitektur Resnet-50

Convolutional Neural Network (CNN) merupakan arsitektur jaringan saraf tiruan yang secara khusus dirancang untuk mengolah data dalam bentuk grid dua dimensi, seperti citra digital [33]. CNN telah menjadi metode utama dalam berbagai tugas visi komputer karena kemampuannya dalam melakukan ekstraksi fitur otomatis dan klasifikasi gambar dengan tingkat akurasi yang tinggi [34]. Jaringan ini bekerja melalui lapisan-lapisan konvolusi yang mengekstraksi fitur spasial lokal dari gambar, diikuti oleh proses pooling yang mereduksi dimensi data sekaligus mempertahankan fitur penting, dan dilanjutkan dengan lapisan fully connected yang berperan dalam pengambilan keputusan klasifikasi [35].

Dalam praktiknya, semakin dalam suatu arsitektur CNN, maka semakin kompleks pola visual yang dapat dikenali oleh jaringan. Namun, peningkatan kedalaman jaringan juga menimbulkan tantangan baru dalam proses pelatihan, salah satunya adalah vanishing gradient problem, yaitu fenomena di mana nilai gradien menjadi sangat kecil seiring bertambahnya jumlah lapisan, sehingga

menghambat pembaruan bobot secara efektif. Untuk mengatasi kendala tersebut, diperkenalkanlah arsitektur Residual Network (ResNet), yang secara khusus dirancang untuk memungkinkan pelatihan jaringan sangat dalam dengan tetap mempertahankan performa optimal [35].

ResNet-50 adalah salah satu varian dari ResNet yang terdiri dari 50 lapisan, dan telah menjadi standar arsitektur yang banyak digunakan dalam tugas klasifikasi citra skala besar [36]. Keunggulan utama dari ResNet-50 terletak pada konsep residual learning, di mana setiap blok dalam jaringan tidak hanya belajar memetakan input ke output secara langsung, tetapi juga belajar terhadap residual function atau selisih antara input dan output yang diharapkan [37]. Pendekatan ini difasilitasi oleh shortcut connection (jalur pintas) yang melewati satu atau beberapa lapisan dan langsung menambahkan input ke output dari lapisan berikutnya. Hal ini memungkinkan gradien mengalir lebih lancar selama proses backpropagation, menghindari degradasi performa saat jumlah lapisan meningkat [37].

Dalam konteks deteksi penyakit daun tomat, arsitektur ResNet-50 menawarkan berbagai keunggulan. Dengan kedalaman yang tinggi dan stabilitas pelatihan yang unggul, jaringan ini mampu menangkap pola-pola gejala penyakit yang kompleks, seperti bercak tidak beraturan, perubahan warna, hingga bentuk distorsi pada permukaan daun [38]. Keunggulan residual learning sangat berguna ketika citra tanaman memiliki variasi pencahayaan, orientasi, atau tingkat noise yang tinggi hal yang umum ditemukan dalam lingkungan pertanian di dunia nyata.

Selain itu, efisiensi dalam proses ekstraksi fitur membuat ResNet-50 sangat efektif ketika digunakan dalam sistem deteksi otomatis berbasis citra,


Dibandingkan dengan arsitektur CNN konvensional, ResNet-50 menunjukkan performa yang lebih baik dalam hal akurasi, generalisasi terhadap data baru, serta kecepatan konvergensi selama pelatihan. Oleh karena itu, pemilihan arsitektur ResNet-50 dalam penelitian ini didasarkan pada kesesuaiannya untuk tugas klasifikasi multikelas penyakit daun tomat, serta potensi implementasinya dalam skenario pertanian presisi [39].

Selain itu, efisiensi dalam proses ekstraksi fitur membuat ResNet-50 sangat efektif ketika digunakan dalam sistem deteksi otomatis berbasis citra. Dibandingkan dengan arsitektur CNN konvensional, ResNet-50 menunjukkan performa yang lebih baik dalam hal akurasi, generalisasi terhadap data baru, serta kecepatan konvergensi selama pelatihan. Oleh karena itu, pemilihan arsitektur ResNet-50 dalam penelitian ini didasarkan pada kesesuaiannya untuk tugas klasifikasi multikelas penyakit daun tomat, serta potensi implementasinya dalam skenario pertanian presisi [39].

2.3.5 Convolutional Neural Network (CNN) Arsitektur Resnet-50 dengan CBAM

Untuk lebih meningkatkan kemampuan representasi fitur dari ResNet-50, digunakanlah CBAM (Convolutional Block Attention Module), yaitu sebuah modul perhatian ringan yang dirancang untuk mengarahkan fokus jaringan pada bagian gambar yang lebih relevan [40]. CBAM bekerja dengan menambahkan dua jenis perhatian (attention) secara berurutan, yaitu *Channel Attention* dan *Spatial Attention*, yang bertujuan untuk meningkatkan kualitas fitur yang dihasilkan oleh


CNN dengan menekankan informasi-informasi penting, baik dalam domain channel maupun spasial. Integrasi CBAM ke dalam blok residual [41] ResNet-50 dilakukan dengan cara menambahkan CBAM setelah output dari setiap blok residual, tanpa mengubah arsitektur dasar secara signifikan [42]. CBAM terdiri dari dua bagian utama:



Gambar 2. 2. Convolutional Block Attention Module

a. Channel Attention Module (CAM)


Channel Attention Module (CAM), yang berfungsi untuk mengenali channel mana yang paling relevan terhadap konteks citra yang sedang dianalisis. CAM memanfaatkan dua pendekatan pooling global yakni *Global Average Pooling* dan *Global Max Pooling* untuk menangkap informasi statistik global dari setiap channel dalam feature map. Kedua hasil pooling ini kemudian diteruskan ke dua lapisan *Fully Connected* (FC) dengan aktivasi *ReLU* dan *sigmoid*, lalu dikombinasikan untuk menghasilkan peta perhatian channel. Peta ini digunakan untuk mengalikan feature map awal secara channel-wise, sehingga channel yang penting akan ditekankan, sementara yang kurang relevan dikurangi bobotnya [43].



Gambar 2. 3. Channel Attention Module

b. Spatial Attention Module (SAM)

Spatial Attention Module (SAM), yang berfokus pada bagian spasial atau posisi dalam gambar yang paling signifikan. Modul ini kembali menggunakan dua jenis pooling *Average Pooling* dan *Max Pooling* namun kali ini diterapkan secara channel-wise untuk menghasilkan dua peta perhatian spasial. Kedua peta ini kemudian digabungkan dan dilewatkan ke dalam lapisan konvolusi dengan kernel 7×7 untuk menghasilkan *masker perhatian spasial*. Masker ini akan dikalikan dengan feature map hasil CAM, menghasilkan representasi akhir yang lebih fokus pada lokasi-lokasi penting dalam gambar [41].



Gambar 2. 4. Spatial Attention Module

Kelebihan utama CBAM adalah kemampuannya dalam meningkatkan fokus jaringan terhadap fitur yang paling relevan tanpa menambah beban komputasi secara signifikan [44]. Berbeda dengan teknik attention lain seperti SE-Net, CBAM

lebih ringan dan fleksibel sehingga dapat dengan mudah diintegrasikan ke berbagai arsitektur CNN, termasuk ResNet-50. Selain itu, pendekatan dua tahapnya (channel dan spatial) memungkinkan jaringan untuk menangkap konteks informasi secara menyeluruh. Oleh karena itu, integrasi ResNet-50 dengan CBAM sangat ideal untuk diterapkan dalam deteksi penyakit daun tomat, karena mampu mengidentifikasi gejala-gejala halus seperti perubahan warna, pola bintik, dan deformasi bentuk daun dengan tingkat akurasi yang lebih tinggi. CBAM telah terbukti meningkatkan performa model dalam tugas-tugas klasifikasi citra, segmentasi, dan deteksi objek, yang menjadikannya sebagai salah satu pilihan utama dalam pengembangan sistem deteksi penyakit tanaman berbasis deep learning.

2.3.6 Convolutional Neural Network (CNN) Arsitektur InceptionV3

Salah satu inovasi penting dalam pengembangan arsitektur CNN adalah InceptionV3, sebuah jaringan dalam keluarga GoogLeNet yang dirancang untuk mencapai akurasi tinggi dengan efisiensi komputasi yang lebih baik. InceptionV3 dikembangkan berdasarkan prinsip optimisasi struktur jaringan agar mampu menangani masalah representasi fitur pada skala dan kompleksitas yang berbeda. Arsitektur ini menggabungkan berbagai teknik lanjutan seperti factorized convolutions, auxiliary classifiers, dan label smoothing untuk meningkatkan performa tanpa secara signifikan meningkatkan jumlah parameter [45].

Keunikan utama dari arsitektur InceptionV3 terletak pada Inception Module, yakni blok jaringan yang secara paralel menerapkan beberapa filter

konvolusi dengan ukuran kernel berbeda (misalnya 1×1 , 3×3 , dan 5×5) pada input yang sama [46]. Pendekatan ini memungkinkan jaringan untuk menangkap informasi lokal dan global secara bersamaan dalam satu tahap pemrosesan. Selain itu, penggunaan 1×1 convolution sebagai metode reduksi dimensi memungkinkan efisiensi komputasi yang lebih tinggi, karena mengurangi jumlah saluran fitur sebelum diterapkan filter yang lebih besar.

Lebih lanjut, InceptionV3 memperkenalkan konsep convolutional factorization, yakni pemecahan filter konvolusi besar menjadi kombinasi filter yang lebih kecil dan efisien. Misalnya, daripada menggunakan satu filter 5×5 , jaringan memecahnya menjadi dua buah filter 3×3 berurutan atau bahkan kombinasi filter $1 \times N$ dan $N \times 1$ [46]. Teknik ini secara signifikan mengurangi jumlah parameter dan mempercepat proses pelatihan tanpa mengorbankan kemampuan ekstraksi fitur.

Untuk meningkatkan stabilitas pelatihan dan mencegah overfitting, InceptionV3 juga menyisipkan auxiliary classifiers yakni klasifikasi tambahan yang ditempatkan di tengah jaringan sebagai sinyal pelatihan tambahan yang membantu propagasi gradien ke lapisan awal [47]. Hal ini sangat penting dalam jaringan yang sangat dalam agar pembelajaran tetap optimal.

Dalam konteks deteksi penyakit daun tomat, arsitektur InceptionV3 menawarkan keunggulan dalam menangani variasi visual gejala penyakit, seperti bintik, perubahan warna, atau deformasi, yang mungkin muncul dalam skala dan bentuk yang berbeda [15]. Kemampuan jaringan ini untuk secara bersamaan mengekstraksi fitur pada berbagai skala membuatnya sangat cocok untuk tugas

klasifikasi multi-kelas yang kompleks seperti membedakan berbagai jenis penyakit tanaman.

Penggunaan InceptionV3 juga menguntungkan dari sisi efisiensi. Meskipun jaringan ini dalam hal kedalaman termasuk kompleks, optimalisasi struktur modul dan efisiensi konvolusi membuatnya relatif ringan untuk dilatih dibandingkan dengan arsitektur lain dengan jumlah parameter serupa [48]. Oleh karena itu, dalam penelitian ini, InceptionV3 dipilih sebagai salah satu arsitektur yang diuji karena kemampuan adaptifnya terhadap keragaman visual dan efisiensi dalam proses klasifikasi citra daun tomat yang terinfeksi.

2.3.7 Metrik Evaluasi Kinerja Model CNN

Augmentasi data adalah teknik untuk meningkatkan jumlah dan variasi data pelatihan dengan mengubah aspek gambar seperti rotasi, flipping, perubahan pencahayaan, dan cropping. Teknik ini sangat penting dalam model CNN, terutama untuk menghindari *overfitting* pada dataset kecil. (Wu, Chen, and Meng 2020a) menunjukkan bahwa augmentasi berbasis Deep Convolutional Generative Adversarial Network (DCGAN) dapat meningkatkan jumlah data citra penyakit daun tomat dengan hasil yang realistis, meningkatkan kemampuan generalisasi model.

Penelitian Text Augmentation for Deep Learning oleh Shorten dan Khoshgoftaar, dibahas berbagai metode augmentasi data untuk meningkatkan variasi data pelatihan, dengan tujuan meningkatkan kemampuan generalisasi model dalam pengenalan pola [50]. Penggunaan augmentasi data dalam penelitian ini akan

membantu meningkatkan ketahanan model terhadap perubahan pencahayaan dan kondisi latar belakang yang berbeda pada citra daun tomat.

2.3.8 Tantangan dalam Deteksi Penyakit pada Daun Tomat di Lapangan

Tantangan yang dihadapi dalam penerapan CNN untuk deteksi penyakit daun tomat di lapangan termasuk variasi pencahayaan, latar belakang yang beragam, dan kualitas gambar yang berbeda-beda. Menurut [17], variasi kondisi lapangan ini dapat mengurangi akurasi model jika model hanya dilatih pada data laboratorium yang homogen. Teknik augmentasi dan penggunaan model pretrained dibahas sebagai solusi untuk meningkatkan kemampuan adaptasi model terhadap lingkungan lapangan yang kompleks.

2.3.9 Perbandingan Metode Deteksi Penyakit pada Tanaman

Selain CNN, metode lain seperti Support Vector Machine (SVM) dan Mask R-CNN telah digunakan dalam penelitian deteksi penyakit tanaman. Dalam studi oleh [5] Mask R-CNN menunjukkan hasil yang baik dalam deteksi tomato leaf miner, meskipun memerlukan lebih banyak sumber daya komputasi. Perbedaan antara teknik klasifikasi dan segmentasi dalam tugas pengenalan pola, dan mengapa CNN sering kali menjadi pilihan yang lebih efisien dalam klasifikasi langsung.

BAB 3

METODE PENELITIAN

3.1 Jenis, Sifat, dan Pendekatan Penelitian

Penelitian ini merupakan penelitian eksperimental yang bersifat kuantitatif dan terapan. Eksperimen dilakukan untuk mengembangkan model deteksi penyakit daun tomat dengan menggunakan Convolutional Neural Network (CNN). Tujuan utama penelitian ini adalah meningkatkan akurasi serta efektivitas deteksi penyakit melalui perbandingan tiga arsitektur model, yaitu ResNet-50, ResNet-50 dengan Convolutional Block Attention Module (CBAM), dan InceptionV3.

Pendekatan penelitian ini bersifat deskriptif-analitis, yaitu mengumpulkan dan menganalisis data untuk memberikan gambaran akurat tentang kinerja model deteksi penyakit daun tomat. Hasil eksperimen diharapkan dapat memberikan wawasan yang signifikan dalam memilih parameter optimal dan teknik pemrosesan data yang tepat.

3.2 Metode Pengumpulan Data

Pengumpulan Data yang digunakan dalam penelitian ini berupa citra digital daun tomat yang diperoleh dari PlantVillage Tomato Leaf Dataset yang tersedia secara publik. Dataset ini berisi ribuan gambar dengan kondisi pencahayaan, latar belakang, serta tingkat keparahan penyakit yang beragam. Seluruh gambar telah dikategorikan ke dalam sepuluh kelas yang merepresentasikan kondisi sehat maupun berbagai jenis penyakit daun tomat, meliputi Bacterial Spot, Early Blight,

Healthy, Late Blight, Leaf Mold, Septoria Leaf Spot, Target Spot, Tomato Mosaic Virus, Tomato Yellow Leaf Curl Virus, dan Two-Spotted Spider Mite. Keberagaman kelas ini memungkinkan model Convolutional Neural Network (CNN) mempelajari pola visual yang berbeda untuk setiap jenis penyakit sehingga diharapkan mampu menghasilkan kemampuan klasifikasi yang lebih akurat. Dataset yang diperoleh kemudian digunakan dalam proses pelatihan dan pengujian model setelah melalui tahap preprocessing.

3.3 Metode Analisis Data

Pengumpulan data dalam penelitian ini menggunakan dataset gambar daun tomat yang diambil dari situs penyedia data publik Kaggle. Dataset ini terdiri dari beberapa kelas penyakit daun, termasuk bercak bakteri, bercak target, keriting daun kuning, serta satu kelas untuk daun sehat. Total data mencakup ribuan gambar dengan variasi kondisi pencahayaan dan latar belakang, yang diperlukan untuk melatih dan menguji model. Analisis data pada penelitian ini dilakukan melalui beberapa tahapan utama. Pertama, seluruh citra daun tomat dilakukan preprocessing dengan mengubah ukuran menjadi 224×224 piksel, melakukan normalisasi, serta augmentasi data berupa rotasi, translasi, zoom, perubahan kecerahan, dan flipping untuk meningkatkan variasi data. Dataset kemudian dibagi menjadi data latih sebesar 80% dan data validasi sebesar 20%.


Selanjutnya, data dianalisis menggunakan tiga skenario model Convolutional Neural Network (CNN), yaitu ResNet-50, ResNet-50 dengan Convolutional Block Attention Module (CBAM), dan InceptionV3. Ketiga model

tersebut dilatih menggunakan parameter pelatihan yang sama, kemudian dibandingkan berdasarkan hasil klasifikasi yang diperoleh.

Evaluasi model dilakukan dengan menggunakan metrik akurasi, precision, recall, F1-score, serta ditampilkan pula confusion matrix dan grafik akurasi serta loss untuk menilai performa masing-masing skenario.

3.4 Alur Penelitian

Alur penelitian pada penelitian ini adalah sebagai berikut, dan dijelaskan melalui bagan alur penelitian pada gambar 3.1.



Gambar 3. 1. Alur Penelitian

Dalam melakukan penelitian deteksi penyakit pada daun tomat, terdapat berbagai tahapan yang harus diselesaikan secara sistematis. Alue penelitian yang

akan digunakan ditampilkan pada Gambar 3.1. Tahapan-tahapan penelitian ini dijelaskan lebih lanjut sebagai berikut:

a. Identifikasi Masalah

Pada tahap ini, dilakukan pencarian topik permasalahan yang ditemukan di lapangan atau berasal dari sumber informasi yang kredibel, seperti artikel dan jurnal. Selanjutnya, permasalahan yang telah ditemukan dianalisis dan diidentifikasi untuk menentukan topik utama penelitian.

b. Studi Literatur

Dalam tahap ini, dilakukan pengumpulan informasi mendetail mengenai permasalahan yang dikaji, bersumber dari literatur ilmiah yang berhubungan langsung dengan topik penelitian. Selain memperkuat dasar teoritis, langkah ini juga bertujuan untuk mengidentifikasi metode serta algoritma yang paling sesuai untuk menyelesaikan permasalahan yang diteliti.

c. Penentuan Algoritma dan Metode

Setelah mengumpulkan informasi dari berbagai sumber yang relevan, langkah selanjutnya adalah menentukan algoritma dan metode yang paling sesuai untuk menyelesaikan permasalahan yang diteliti. Dalam penelitian ini, digunakan algoritma Convolutional Neural Network (CNN) dengan arsitektur ResNet-50 dan Inception V3 untuk mendeteksi penyakit pada daun tomat secara efektif.

d. Pengumpulan Data

Tahap selanjutnya melibatkan pengumpulan dataset yang sesuai dan relevan dengan topik permasalahan yang dikaji. Dalam penelitian ini, data yang digunakan

berupa citra atau gambar yang diperoleh dari sumber data publik yang tersedia untuk umum.

e. Preprocessing

Pada tahap ini, dilakukan proses preprocessing terhadap data citra penyakit daun tomat yang telah dikumpulkan. Tahapan preprocessing yang diterapkan meliputi augmentasi data, seperti rotasi, flipping, perubahan skala, dan penyesuaian kecerahan, guna meningkatkan variasi data serta memperkuat kemampuan generalisasi model. Proses ini bertujuan untuk mengoptimalkan performa model Convolutional Neural Network (CNN) dengan arsitektur ResNet-50, Convolutional Neural Network (CNN) arsitektur ResNet-50 dengan penambahan module cbam dan Inception V3 dalam mendeteksi penyakit pada daun tomat.

f. Split Data

Setelah proses augmentasi data selesai, dilakukan pembagian dataset menjadi dua bagian, yaitu data training dan data testing. Dalam penelitian ini, pembagian dilakukan dengan proporsi 80% untuk data training dan 20% untuk data testing guna memastikan model Convolutional Neural Network (CNN) dengan arsitektur ResNet-50 dan Inception V3 dapat belajar secara optimal serta diuji dengan baik.

g. Skenario Penelitian

Pada tahap selanjutnya, ditentukan skenario penelitian yang akan diterapkan. Dalam penelitian ini, dilakukan perbandingan kinerja model berdasarkan tiga skenario berbeda untuk memperoleh akurasi terbaik. Skenario yang digunakan meliputi arsitektur ResNet-50 standar, ResNet-50 dengan CBAM,

serta Inception V3, guna mengevaluasi efektivitas masing-masing pendekatan dalam mendeteksi penyakit pada daun tomat.

h. Training Data

Setelah menetapkan skenario penelitian, dilakukan serangkaian percobaan dengan menggunakan tiga arsitektur yang telah ditentukan, yaitu ResNet-50 standar, ResNet-50 dengan CBAM, dan Inception V3, pada citra daun tomat. Tahap pelatihan data (training) bertujuan untuk melatih model Convolutional Neural Network (CNN) agar dapat mengklasifikasikan penyakit pada daun tomat dengan optimal.

i. Evaluasi

Pada tahap ini, dilakukan evaluasi terhadap model telah dikembangkan dengan menyusun tabel *model_comparison* untuk membandingkan kinerja dari tiga skenario yang digunakan, yaitu ResNet-50 standar, ResNet-50 dengan CBAM, dan Inception V3.

k. Kesimpulan

Setelah memperoleh hasil evaluasi dari setiap model klasifikasi, langkah selanjutnya adalah melakukan analisis terhadap hasil perbandingan ketiga skenario yang telah diuji, yaitu ResNet50 standar, ResNet50 dengan CBAM, dan Inception V3. Analisis ini bertujuan untuk menentukan arsitektur yang memberikan kinerja terbaik berdasarkan nilai akurasi tertinggi, serta mengevaluasi dampak preprocessing yang telah diterapkan dalam meningkatkan performa model.

BAB 4

HASIL PENELITIAN DAN PEMBAHASAN

4.1. Dan Pengumpulan Data


Penelitian ini menggunakan data sekunder yang diperoleh dari situs penyedia data publik yang dapat diakses secara bebas oleh siapa saja. Data yang digunakan berupa citra daun tomat yang bersumber dari situs Mendeley Data dengan link <https://data.mendeley.com/datasets/ngdgg79rzb/1>. Dataset ini terdiri dari dua bagian berdasarkan perbedaan sumber citra daun tomat, salah satunya berasal dari database PlantVillage. Setelah melalui proses penggabungan dan penghapusan kategori yang tidak relevan, serta penyesuaian ukuran citra dari 256×256 piksel menjadi 227×227 piksel, diperoleh total 14.531 citra yang terbagi ke dalam sepuluh kategori. Kategori tersebut meliputi satu kelas daun sehat dan sembilan kelas daun yang mengalami penyakit, yaitu Bacterial Spot, Early Blight, Late Blight, Leaf Mold, Septoria Leaf Spot, Target Spot, Tomato Mosaic Virus, Tomato Yellow Leaf Curl Virus, dan Two-Spotted Spider Mite. Dataset ini selanjutnya dibagi ke dalam lima subset untuk keperluan validasi silang (5-fold cross-validation). Dataset ini telah digunakan dalam sejumlah penelitian terdahulu yang berfokus pada penyakit tanaman menggunakan metode pembelajaran mesin dan pembelajaran mendalam, sehingga relevan untuk digunakan dalam penelitian ini. Adapun kelas dalam dataset ini terdapat pada table 4.1.

Tabel 4. 1. Jumlah Data Penyakit Daun Tomat

Kelas	Jumlah	Presentase(%)
Bacterial Spot	2127	15%
Early Blight	1000	7%
Healthy	1591	11%
Late Blight	1910	13%
Leaf Mold	952	7%
Septoria Leaf Spot	1771	12%5
Target Spot	1404	10%
Tomato Mosaic Virus	373	3%
Tomato Yellow Leaf Curl Virus	5357	37%
Two-Spotted Spider Mite	1046	7%
Jumlah	14531	100%

Pada bagian ini, peneliti menyusun secara sistematis disertai argumentasi yang rasional tentang informasi ilmiah yang diperoleh dalam penelitian, terutama informasi yang relevan dengan masalah penelitian. Pembahasan terhadap hasil penelitian yang diperoleh dapat disajikan dalam bentuk uraian teoritis, baik secara kualitatif maupun kuantitatif.

Dalam pelaksanaannya, bagian ini dapat digunakan untuk membandingkan hasil-hasil penelitian yang diperoleh dalam penelitian yang sedang dilakukan terhadap hasil-hasil penelitian yang dilaporkan oleh peneliti terdahulu yang diacu pada penelitian ini. Secara ilmiah, hasil penelitian yang diperoleh dalam penelitian dapat berupa temuan baru atau perbaikan, penegasan, atau penolakan interpretasi suatu fenomena ilmiah dari peneliti sebelumnya.



Gambar 4. 1. Contoh gambar dataset

4.2. Preprocessing Data

Tahap preprocessing data merupakan langkah awal yang penting dalam mempersiapkan data gambar daun tomat agar dapat digunakan secara optimal data. Tujuan dari tahap ini adalah untuk menghindari data yang tidak ideal atau bias, sehingga data yang dihasilkan menjadi lebih representatif dan mendukung performa model yang tinggi serta akurat. Dalam penelitian ini, preprocessing data dilakukan melalui beberapa tahapan, yaitu augmentasi data, normalisasi, dan penyesuaian ukuran gambar.

Pada tahap pertama, dilakukan augmentasi data terhadap dataset pelatihan guna meningkatkan keragaman data dan mencegah overfitting. Augmentasi yang digunakan meliputi pemotongan acak bagian gambar dan mengubah ukurannya secara acak ke dimensi tertentu, serta melakukan pembalikan horizontal secara acak. Teknik ini memungkinkan model mengenali objek dengan berbagai variasi posisi dan ukuran yang berbeda.

Selanjutnya, dilakukan normalisasi nilai piksel gambar dengan menggunakan nilai rata-rata dan standar deviasi dari dataset ImageNet, yang disesuaikan dengan karakteristik arsitektur ResNet-50 dan Inception V3 yang digunakan dalam penelitian ini. Normalisasi ini bertujuan untuk mempercepat proses pelatihan dan meningkatkan stabilitas model.

Langkah terakhir dalam preprocessing adalah mengubah semua gambar ke ukuran piksel yang sama, yaitu 224x224 piksel. Gambar pelatihan diubah ukurannya secara acak, sedangkan gambar pelatihan di-resize terlebih dahulu kemudian di-crop agar memiliki ukuran yang seragam. Penyesuaian ukuran ini penting agar setiap gambar dapat diproses dengan konsisten oleh model klasifikasi.

Dengan menerapkan ketiga tahapan preprocessing tersebut, data yang digunakan dalam penelitian ini menjadi lebih siap untuk dianalisis oleh model deep learning, sehingga diharapkan mampu meningkatkan akurasi dalam mendeteksi penyakit pada daun tomat.

4.3. Skenario Pengujian

4.3.1 Convolutional Neural Network Arsitektur Resnet-50

Pada skenario pertama ini, model dibangun menggunakan arsitektur ResNet-50 yang telah dipra-latih pada ImageNet. `include_top=False` digunakan untuk menghapus lapisan fully-connected default dari ResNet-50 agar bisa diganti dengan layer klasifikasi khusus dataset penyakit daun tomat. Setelah output fitur dari backbone ResNet-50 diperoleh, dilakukan pooling dengan `GlobalAveragePooling2D`, lalu ditambahkan Dense layer berisi 512 neuron dan aktivasi ReLU untuk pembelajaran fitur. Selanjutnya diterapkan `Dropout(0.5)`

sebagai regularisasi untuk mencegah overfitting. Akhirnya, layer output Dense dengan 10 neuron (jumlah kelas) dan fungsi aktivasi softmax digunakan untuk klasifikasi multikelas. Ini adalah model standar (tanpa attention module) yang kamu bangun.

4.3.2 Convolutional Neural Network Arsitektur Resnet-50 dengan Convolutional Block Attention Module (CBAM)

Skenario kedua memperkuat arsitektur ResNet-50 dengan menambahkan CBAM (Convolutional Block Attention Module). Modul ini terdiri dari dua blok perhatian: Channel Attention dan Spatial Attention. Pertama, `base_model.output` (hasil ekstraksi fitur dari ResNet-50) diberikan ke `cbam_block()`, yang menghitung pentingnya setiap channel (fitur) dan lokasi spasial dalam fitur. Setelah fitur diperbaiki oleh CBAM, hasilnya diteruskan ke `GlobalAveragePooling2D`, lalu ke layer Dense berisi 512 neuron dengan aktivasi ReLU. Kemudian ditambahkan `Dropout(0.5)` dan layer output Dense sebanyak 10 unit dengan Softmax. Model ini diharapkan lebih baik dalam menangkap informasi penting pada citra dibanding model sebelumnya karena adanya mekanisme perhatian.

4.4.3 Convolutional Neural Network Arsitektur InceptionV3

Skenario ketiga menggunakan arsitektur InceptionV3 yang juga dimuat dengan bobot ImageNet dan tidak menggunakan bagian atas (`include_top=False`). InceptionV3 terkenal karena strukturnya yang memiliki paralelisme dalam ekstraksi fitur, memungkinkan pengolahan informasi pada berbagai skala filter (1x1, 3x3, 5x5) secara simultan. Seperti model sebelumnya, output dari InceptionV3 diproses melalui `GlobalAveragePooling2D`, lalu dilanjutkan ke Dense

layer berukuran 512 unit dengan aktivasi ReLU, kemudian Dropout, dan terakhir Dense layer output dengan softmax. Model ini cocok untuk mengenali pola kompleks dan bervariasi seperti gejala penyakit pada daun tomat.

4.4. Modifikasi Parameter

Pada penelitian ini, dilakukan implementasi dan evaluasi tiga skenario model deep learning untuk klasifikasi penyakit daun tomat, yaitu ResNet-50 tanpa CBAM, ResNet-50 dengan CBAM, dan InceptionV3. Pada skenario pertama, model ResNet-50 digunakan tanpa penambahan modul perhatian (attention). Modifikasi yang dilakukan meliputi penghapusan top layer bawaan dengan mengatur parameter `include_top=False`, lalu ditambahkan lapisan GlobalAveragePooling2D dan Dense layer dengan 128 neuron dan aktivasi ReLU. Output layer menggunakan aktivasi softmax sesuai dengan jumlah kelas penyakit. Model dilatih menggunakan optimizer Adam dengan learning rate sebesar $1e-4$, batch size 32, dan maksimum 100 epoch dengan mekanisme EarlyStopping untuk menghindari overfitting.

Skenario kedua menggunakan arsitektur ResNet-50 yang dimodifikasi dengan menambahkan modul Convolutional Block Attention Module (CBAM) setelah output fitur dari backbone. Modul CBAM terdiri dari dua tahap, yaitu channel attention dan spatial attention, yang masing-masing menggunakan kombinasi Global Average Pooling dan Max Pooling. Modifikasi ini bertujuan untuk meningkatkan fokus model pada fitur penting yang relevan dengan klasifikasi. Parameter pelatihan pada skenario ini dibuat sama dengan skenario pertama untuk memastikan perbandingan yang adil.

Sementara itu, skenario ketiga menggunakan arsitektur InceptionV3 sebagai model pembanding. Seperti skenario lainnya, top layer dari InceptionV3 dihapus dan diganti dengan GlobalAveragePooling2D, Dense 128 dengan aktivasi ReLU, dan softmax pada layer output. Proses preprocessing juga menyesuaikan dengan metode preprocessing yang digunakan oleh arsitektur InceptionV3. Parameter pelatihan yang digunakan tetap konsisten, yaitu optimizer Adam dengan learning rate $1e-4$, batch size 32, dan epoch sebanyak 100.

4.5. Split Data

Pengelompokan data merupakan tahapan penting dalam proses pelatihan, karena sangat berpengaruh terhadap performa akhir yang dihasilkan. Dalam penelitian ini, dataset yang digunakan berasal dari folder `Tomato_images`, yang berisi gambar daun tomat dengan berbagai jenis kondisi, baik sehat maupun terkena penyakit. Data tersebut kemudian diproses menggunakan fungsi `ImageDataGenerator` dari pustaka TensorFlow, yang juga dimanfaatkan untuk melakukan augmentasi data guna meningkatkan keragaman data latih.

Pembagian data dilakukan secara otomatis menggunakan parameter `validation_split=0.2`, yang berarti 80% data digunakan sebagai data pelatihan dan 20% sisanya digunakan sebagai data pengujian. Proses ini dilakukan langsung dari direktori utama tanpa membuat folder terpisah untuk data training dan testing.

4.6. Skenario Penelitian

Langkah selanjutnya adalah menentukan skenario penelitian yang akan digunakan dalam proses deteksi penyakit daun tomat, di mana setiap gambar akan

dikelompokkan ke dalam label yang sesuai berdasarkan jenis penyakit atau kondisi daun. Untuk menghasilkan model yang optimal, penelitian ini dirancang dengan membandingkan tiga pendekatan arsitektur model yang berbeda, yaitu Convolutional Neural Network (CNN) dengan arsitektur ResNet50 sebagai model dasar (standar), CNN dengan penambahan modul Convolutional Block Attention Module (CBAM) pada arsitektur ResNet50, serta arsitektur pre-trained Inception V3. Perbandingan dilakukan untuk mengetahui metode mana yang memberikan performa terbaik dalam mendeteksi penyakit daun tomat berdasarkan akurasi dan metrik evaluasi lainnya.

4.6.1 Convolutional Neural Network Arsitektur Resnet-50

Pada skenario penelitian pertama, digunakan metode Convolutional Neural Network (CNN) dengan arsitektur ResNet50 sebagai model dasar dalam deteksi jenis penyakit pada daun tomat. Pendekatan ini bertujuan untuk melihat kinerja awal dari arsitektur CNN tanpa adanya modifikasi atau penambahan komponen lainnya. Penggunaan ResNet50 sebagai model dasar memberikan gambaran awal tentang seberapa efektif jaringan ini dalam mengenali pola-pola visual pada gambar daun tomat.

ResNet50 merupakan arsitektur jaringan yang mengimplementasikan residual learning untuk menghindari masalah vanishing gradient, yang sering terjadi pada jaringan yang lebih dalam. Model CNN dalam skenario ini terdiri dari lapisan konvolusi, residual blocks, dan fully connected layers yang difungsikan untuk proses klasifikasi.

Data gambar terlebih dahulu melalui proses pra-pemrosesan berupa perubahan ukuran gambar, normalisasi piksel, dan augmentasi sederhana agar data lebih seragam dan variatif. Proses pelatihan dilakukan untuk mengoptimalkan bobot jaringan agar mampu mengenali fitur khas dari masing-masing kelas penyakit.

Evaluasi model dilakukan menggunakan metrik seperti akurasi, presisi, recall, dan F1-score untuk menilai performa. Hasil dari skenario ini akan dijadikan acuan dalam membandingkan peningkatan performa pada skenario-skenario berikutnya dengan arsitektur yang dimodifikasi.

4.6.2 Convolutional Neural Network Arsitektur Resnet-50 dengan Convolutional Block Attention Module (CBAM)

Pada skenario penelitian kedua, pendekatan yang digunakan adalah metode Convolutional Neural Network (CNN) yang dikombinasikan dengan Convolutional Block Attention Module (CBAM), yang bertujuan untuk meningkatkan performa klasifikasi penyakit daun tomat secara lebih akurat dan efisien. Integrasi CBAM dirancang untuk memberikan perhatian yang lebih besar pada fitur penting dalam citra, baik dari aspek spasial maupun channel, sehingga memungkinkan model untuk fokus pada pola-pola krusial yang membedakan daun sehat dan daun yang terinfeksi penyakit.

CNN secara umum memiliki kemampuan untuk mengekstraksi fitur visual secara otomatis dari citra, seperti bentuk, warna, dan tekstur. Namun, dalam beberapa kasus, CNN standar belum tentu mampu membedakan fitur-fitur yang benar-benar relevan terhadap proses klasifikasi. Oleh karena itu, CBAM

diimplementasikan untuk meningkatkan representasi fitur dengan cara memperkuat informasi visual penting dan menekan fitur yang kurang relevan. Modul ini bekerja dengan memproses output dari layer CNN untuk menghasilkan peta perhatian yang merefleksikan area-area penting dalam gambar.

CBAM sendiri terdiri dari dua mekanisme utama, yaitu channel attention dan spatial attention. Channel attention memungkinkan model untuk mengidentifikasi saluran fitur mana yang paling informatif, sedangkan spatial attention memandu model untuk fokus pada lokasi-lokasi tertentu dalam gambar yang memiliki kontribusi besar terhadap proses klasifikasi. Kombinasi keduanya menciptakan pemetaan fitur yang lebih tajam dan representatif, yang sangat berguna dalam mengidentifikasi gejala penyakit pada daun tomat, seperti perubahan warna, bintik, dan bentuk tidak normal.

Pada penelitian ini, modul CBAM ditempatkan pada bagian akhir arsitektur ResNet-50, tepat setelah proses ekstraksi fitur selesai dilakukan. Penempatan tersebut dipilih karena pada tahap akhir jaringan, representasi fitur sudah terbentuk secara menyeluruh, sehingga mekanisme perhatian pada CBAM dapat bekerja lebih efektif dalam menyoroti area penting dari citra daun tomat dan menekan fitur yang tidak relevan.

Selain itu, keterbatasan komputasi menjadi pertimbangan utama dalam penelitian ini. Pengujian CBAM di berbagai posisi lapisan akan memerlukan sumber daya yang jauh lebih besar serta waktu pelatihan yang lebih lama. Oleh karena itu, penelitian ini difokuskan pada satu skenario penempatan CBAM di akhir jaringan agar proses evaluasi tetap efisien namun tetap mampu menunjukkan

pengaruh penambahan mekanisme perhatian terhadap peningkatan performa model.

Hasil dari skenario ini menunjukkan bahwa kombinasi CNN dan CBAM mampu meningkatkan kinerja dibandingkan dengan penggunaan CNN secara murni. Kemampuan modul attention dalam menangkap fitur-fitur dominan menjadikan model lebih sensitif terhadap perbedaan halus pada citra, yang pada akhirnya menghasilkan prediksi yang lebih akurat dan andal dalam konteks deteksi penyakit tanaman.

4.6.3 Convolutional Neural Network Arsitektur InceptionV3

Pada skenario penelitian ketiga, digunakan arsitektur Inception V3 sebagai model utama dalam proses klasifikasi penyakit pada daun tomat. Inception V3 merupakan salah satu arsitektur deep learning yang dirancang untuk memaksimalkan efisiensi dan akurasi dalam pengenalan gambar dengan cara memproses informasi visual melalui berbagai ukuran filter secara paralel dalam satu blok, sehingga memungkinkan model menangkap berbagai jenis pola fitur, baik yang berskala kecil maupun besar.

Penggunaan Inception V3 dalam penelitian ini bertujuan untuk mengeksplorasi potensi arsitektur yang telah terbukti unggul dalam berbagai kompetisi pengenalan citra, dengan harapan mampu mengidentifikasi jenis penyakit daun tomat secara lebih akurat. Citra daun tomat yang digunakan terlebih dahulu melalui tahap pra-pemrosesan berupa resize ke ukuran standar Inception V3, normalisasi piksel, serta augmentasi untuk meningkatkan variasi data pelatihan.

Model Inception V3 yang digunakan telah disesuaikan dengan jumlah kelas penyakit daun tomat yang terdapat dalam dataset, dengan menambahkan lapisan klasifikasi pada bagian akhir jaringan. Selama proses pelatihan, model dioptimalkan menggunakan algoritma pembelajaran yang disesuaikan agar dapat mengenali ciri-ciri visual dari masing-masing penyakit dengan baik.

Evaluasi performa dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score untuk memastikan bahwa model tidak hanya mengenali citra dengan benar, tetapi juga mempertahankan konsistensi dalam mendeteksi berbagai jenis penyakit. Performa Inception V3 kemudian dibandingkan dengan skenario lain guna menilai keunggulan arsitektur ini dalam klasifikasi citra daun tomat.

4.7. Evaluasi Model

Evaluasi hasil dalam penelitian ini berfokus pada deteksi penyakit daun tomat menggunakan tiga skenario arsitektur Convolutional Neural Network (CNN) yang berbeda, yakni ResNet-50 standar, ResNet-50 dengan penerapan modul Convolutional Block Attention Module (CBAM), serta Inception V3. Pendekatan ini digunakan untuk mengevaluasi efektivitas masing-masing arsitektur dalam mendeteksi keberadaan gejala penyakit pada daun tomat secara akurat. Model-model tersebut dilatih dan diuji menggunakan dataset citra daun tomat yang telah diberi label, dengan tujuan untuk membandingkan performa dari segi ketepatan deteksi pada berbagai jenis penyakit.

Setiap model dianalisis berdasarkan hasil confusion matrix yang merepresentasikan jumlah deteksi benar maupun salah pada masing-masing kelas penyakit. Selain itu, metrik evaluasi seperti precision, recall, dan F1-score

digunakan untuk memperoleh gambaran yang lebih menyeluruh terhadap kemampuan model dalam mendeteksi penyakit. Precision menggambarkan tingkat ketepatan model dalam mendeteksi area yang benar-benar mengandung penyakit dari seluruh deteksi yang dilakukan, sedangkan recall mengukur sejauh mana model mampu menangkap seluruh area yang terinfeksi dalam gambar. F1-score digunakan untuk menyeimbangkan kedua metrik tersebut dan memberikan ukuran performa deteksi secara keseluruhan.

Penggunaan arsitektur ResNet-50 standar memberikan gambaran awal performa deteksi dengan jaringan standar tanpa modifikasi tambahan. Sementara itu, penerapan CBAM pada ResNet-50 bertujuan meningkatkan fokus model terhadap fitur penting melalui mekanisme dilated convolution yang memperluas cakupan area receptive field tanpa kehilangan resolusi spasial. Di sisi lain, arsitektur Inception V3 diuji karena kemampuannya menangani fitur multiskala secara efisien, yang diharapkan mampu menangkap variasi visual dari gejala penyakit pada daun. Dengan membandingkan hasil dari ketiga arsitektur ini, dapat diperoleh pemahaman yang lebih mendalam mengenai model mana yang paling efektif dalam konteks deteksi penyakit pada daun tomat berdasarkan performa metrik yang telah dihitung.

4.7.1 Convolutional Neural Network Arsitektur Resnet-50

Pada skenario awal pengujian ini, digunakan pendekatan Convolutional Neural Network (CNN) dengan mengimplementasikan arsitektur ResNet-50.

Dalam penerapan ini, model dilatih menggunakan dataset yang tidak melalui proses ekstraksi fitur secara eksplisit. Hasil dari proses pelatihan (training) dan pengujian (*testing*) ditampilkan pada gambar berikut 4.2.



Gambar 4. 2. Grafik Akurasi Metode CNN Arsitektur Resnet-50

Gambar 4.2 menunjukkan grafik akurasi selama proses training dan testing dari epoch ke-0 hingga ke-40. Model menghasilkan nilai akurasi pada data training sebesar 0.9793 dan akurasi pada data validasi mencapai **0.9633**, yang mengindikasikan bahwa model mampu belajar dengan baik dari data pelatihan dan mempertahankan performa yang cukup stabil pada data validasi.



Gambar 4. 3. Grafik Loss Metode CNN Arsitektur Resnet-50

Gambar 4.3 ditampilkan grafik nilai loss selama proses pelatihan. Nilai loss pada data training secara konsisten menurun hingga mencapai **0.0359**, dan pada data validasi turun menjadi 0.1131. Hal ini menunjukkan bahwa model tidak mengalami overfitting yang signifikan dan mampu melakukan generalisasi dengan baik terhadap data baru.



Gambar 4. 4. Confusion Matrix Metode CNN Arsitektur Resnet-50

Gambar 4.4 merupakan hasil pengujian dengan menggunakan confusion matrix pada metode CNN dengan mengimplementasikan Resnet-50. Pada penelitian ini menggunakan 2902 gambar sebagai data testing yang terdiri dari kelas target spot 224 gambar, two-spotted spider mite 857 gambar, healthy 152 gambar, bacterial spot 283 gambar, septoria leaf spot 268 gambar, tomato yellow leaf curl virus 160 gambar, early blight 305 gambar, leaf mold 254 gambar, late blight 59, mosaic virus 340 gambar. Deteksi penyakit pada daun tomat memiliki 10 kelas, maka dalam pengujian yang dilakukan menggunakan metode confusion matrix for multi-class dimana untuk mendapatkan nilai precision dan recall yaitu dengan menghitung masing-masing kelas. Berikut merupakan proses perhitungan accuracy, precision, dan recall.

1. Accuracy

Untuk memperoleh nilai akurasi, terlebih dahulu dilakukan penjumlahan true positif dari masing-masing kelas. Hasil penjumlahan tersebut kemudian dibagi dengan jumlah data testing secara keseluruhan, lalu dikalikan dengan 100%. Adapun perhitungan akurasi pada metode CNN adalah sebagai berikut.

$$\begin{aligned} \text{Akurasi} &= \frac{215 + 848 + 137 + 279 + 260 + 141 + 288 + 254 + 57 + 319}{2902} \\ &\times 100\% = 96\% \end{aligned}$$

2. Precision

Untuk memperoleh nilai akurasi, terlebih dahulu dilakukan penjumlahan true positif dari masing-masing kelas. Hasil penjumlahan tersebut kemudian dibagi dengan jumlah data testing secara keseluruhan, lalu dikalikan dengan 100%. Adapun perhitungan akurasi pada metode CNN adalah sebagai berikut.

a. Kelas *Target Spot*

$$\text{Precision} = 215 / (215+3+2+2+2+6+1+11) = 215/242 = 89\%$$

b. Kelas *Two-Spotted Spider Mite*

$$\text{Precision} = 848 / (848+1+3) = 100\%$$

c. Kelas *Healthy*

$$\text{Precision} = 137 / (137+1) = 99\%$$

d. Kelas *Bacterial Spot*

$$\text{Precision} = 279 / (279+7+1+4+2+2+2) = 93\%$$

e. Kelas *Septoria Leaf Spot*

$$\text{Precision} = 260 / (260+3+4+3+1) = 95\%$$

f. Kelas *Tomato Yellow Leaf Curl Virus*

$$\text{Precision} = 141 / (141+1+10+2) = 92\%$$

g. Kelas *Early Blight*

$$\text{Precision} = 288 / (288+1+1+4+20) = 97\%$$

h. Kelas *Leaf Mold*

$$\text{Precision} = 254 / (254+6+1+5+2+3) = 94\%$$

i. Kelas *Late Blight*

$$\text{Precision} = 57 / (57+1+1) = 97\%$$

j. Kelas *Mosaic Virus*

$$\text{Precision} = 319 / (319+2+1) = 99\%$$

Selanjutnya, untuk menghitung nilai precision secara keseluruhan, dilakukan dengan menjumlahkan nilai precision dari setiap kelas, kemudian dibagi

dengan jumlah total kelas. Adapun perhitungan precision pada metode CNN disajikan sebagai berikut.

$$\begin{aligned} \text{Precision} &= \frac{89 + 100 + 99 + 93 + 95 + 92 + 97 + 94 + 97 + 99}{10} \\ &= 96\% \end{aligned}$$

3. Recall

Nilai recall pada confusion matrix untuk multi-class diperoleh dengan menghitung recall pada setiap kelas secara individu, yaitu dengan membagi jumlah true positive dengan jumlah true positive ditambah false positive untuk masing-masing kelas.

a. Kelas *Target Spot*

$$\text{Precision} = 215 / (3+6+) = 215/242 = 96\%$$

b. Kelas *Two-Spottes Spider Mite*

$$\text{Precision} = 848 / (848+3+4+1+1) = 99\%$$

c. Kelas *Healty*

$$\text{Precision} = 137 / (2+1+137+7+3+1+1) = 90\%$$

d. Kelas *Bacterial Spot*

$$\text{Precision} = 279 / (279+2+1+1) = 99\%$$

e. Kelas *Septoria Leaf Spot*

$$\text{Precision} = 260 / (2+1+5) = 97\%$$

f. Kelas *Tomato Yellow Leaf Curl Virus*

$$\text{Precision} = 141 / (6+4+1+141+4+2+2) = 88\%$$

g. Kelas *Early Blight*

$$\text{Precision} = 288 / (1+2+10+288+3+1) = 94\%$$

h. Kelas *Leaf Mold*

$$\text{Precision} = 254 / (254) = 100\%$$

i. Kelas *Late Blight*

$$\text{Precision} = 57 / (2+57) = 97\%$$

j. Kelas *Mosaic Virus*

$$\text{Precision} = 319 / (11+3+1+2+2+2+319) = 94$$

$$\text{Recall} = \frac{96 + 99 + 90 + 99 + 97 + 88 + 94 + 100 + 97 + 94}{10} = 95\%$$

Classification Report:

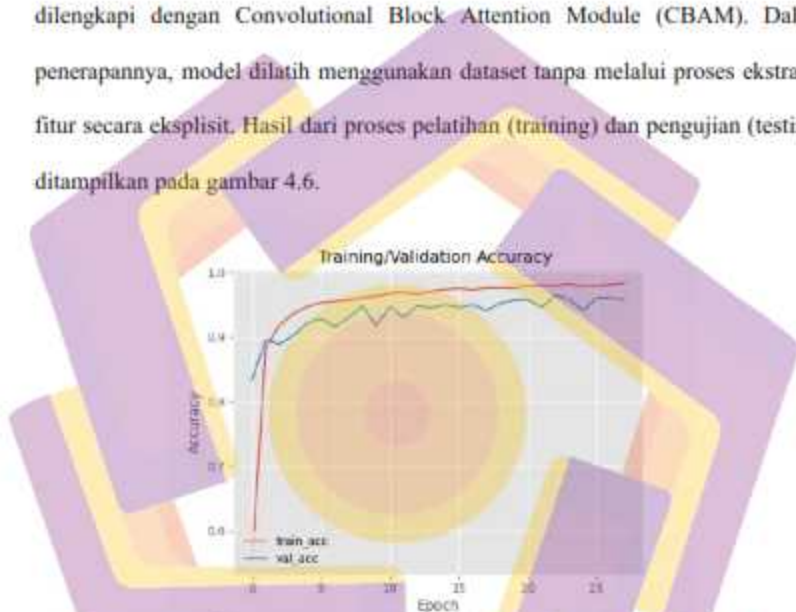
	precision	recall	f1-score	support
target_spot	0.89	0.96	0.92	224
two-spotted_spider_mite	1.00	0.99	0.99	857
healthy	0.99	0.90	0.94	152
bacterial_spot	0.94	0.99	0.96	283
septoria_leaf_spot	0.96	0.97	0.96	268
tomato_yellow_leaf_curl_virus	0.92	0.88	0.90	160
early_blight	0.97	0.94	0.96	305
leaf_mold	0.94	1.00	0.97	254
late_blight	0.97	0.97	0.97	59
tomato_mosaic_virus	0.99	0.94	0.96	340
accuracy			0.96	2902
macro avg	0.96	0.95	0.95	2902
weighted avg	0.97	0.96	0.96	2902

Gambar 4. 5. *Classification Report* Metode CNN Arsitektur Resnet-50

Berdasarkan perhitungan manual terhadap nilai accuracy, precision, dan recall menggunakan metode confusion matrix untuk multi-class, diperoleh hasil yang identik dengan hasil yang dihitung menggunakan program Python. Hasil tersebut dapat dilihat pada gambar 4.5.

4.7.2 Convolutional Neural Network Arsitektur Resnet-50 with Convolutional Block Attention Module (CBAM)

Pada skenario kedua pengujian ini, digunakan pendekatan Convolutional Neural Network (CNN) dengan mengimplementasikan arsitektur ResNet-50 yang dilengkapi dengan Convolutional Block Attention Module (CBAM). Dalam penerapannya, model dilatih menggunakan dataset tanpa melalui proses ekstraksi fitur secara eksplisit. Hasil dari proses pelatihan (training) dan pengujian (testing) ditampilkan pada gambar 4.6.



Gambar 4. 6. Grafik Accuracy Convolutional Neural Network Arsitektur Resnet-50 with Convolutional Block Attention Module (CBAM)

Gambar 4.6 menunjukkan grafik akurasi selama proses training dan validation dari epoch ke-0 hingga ke-27. Model menghasilkan akurasi pada data training sebesar sekitar 0.986, sedangkan akurasi pada data validasi mencapai sekitar 0.962. Grafik ini menunjukkan bahwa model dengan arsitektur ResNet-50 yang dilengkapi dengan Convolutional Block Attention Module (CBAM) mampu belajar dengan sangat baik dari data pelatihan, serta mempertahankan performa

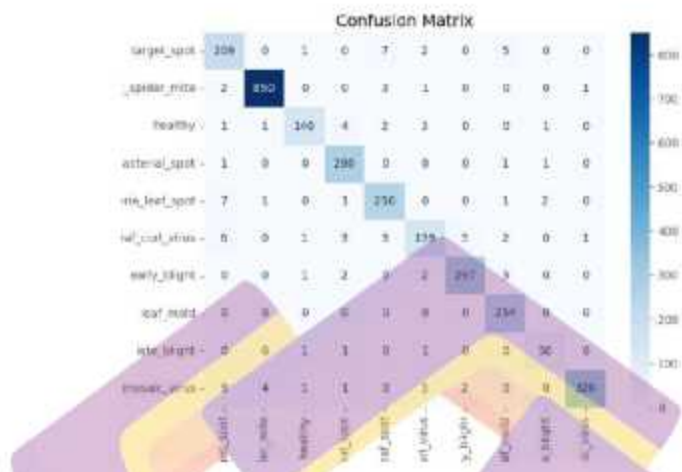
yang tinggi dan relatif stabil pada data validasi, tanpa indikasi overfitting yang signifikan.



Gambar 4. 7. Grafik Loss Convolutional Neural Network Arsitektur Resnet-50 with Convolutional Block Attention Module (CBAM)

Gambar 4.7 memperlihatkan grafik loss selama proses training dan validation dari epoch ke-0 hingga ke-27. Nilai loss pada data training menunjukkan penurunan yang konsisten dan mencapai nilai akhir mendekati 0.05. Sementara itu, nilai loss pada data validasi juga mengalami penurunan secara signifikan di awal, lalu stabil di kisaran 0.15 hingga 0.20. Hal ini menunjukkan bahwa model dengan arsitektur ResNet-50 dan CBAM mampu melakukan generalisasi dengan baik, dengan perbedaan loss antara data training dan validasi yang relatif kecil serta tanpa gejala overfitting yang mencolok.

Selanjutnya, model yang telah dilatih akan dievaluasi menggunakan confusion matrix untuk melihat performa secara lebih detail pada tiap kelas.



Gambar 4. 8. Confusion Matrix Convolutional Neural Network Arsitektur Resnet-50 with Convolutional Block Attention Module (CBAM)

Gambar 4.8. merupakan hasil pengujian menggunakan metode CNN dengan mengimplementasikan arsitektur ResNet-50 yang dilengkapi dengan Convolutional Block Attention Module (CBAM). Pada penelitian ini menggunakan 2902 gambar sebagai data testing yang terdiri dari kelas target spot 224 gambar, two-spotted spider mite 857 gambar, healthy 152 gambar, bacterial spot 283 gambar, septoria leaf spot 268 gambar, tomato yellow leaf curl virus 160 gambar, early blight 305 gambar, leaf mold 254 gambar, late blight 59, mosaic virus 340 gambar. Deteksi penyakit pada daun tomat memiliki 10 kelas, maka dalam pengujian yang dilakukan menggunakan metode confusion matrix for multi-class dimana untuk mendapatkan nilai precision dan recall yaitu dengan menghitung masing-masing kelas. Berikut merupakan proses perhitungan accuracy, precision, dan recall.

1. Accuracy

Untuk memperoleh nilai akurasi, terlebih dahulu dilakukan penjumlahan true positif dari masing-masing kelas. Hasil penjumlahan tersebut kemudian dibagi dengan jumlah data testing secara keseluruhan, lalu dikalikan dengan 100%. Adapun perhitungan akurasi pada metode CNN adalah sebagai berikut.

$$\begin{aligned} \text{Akurasi} &= \frac{209 + 850 + 140 + 280 + 256 + 139 + 297 + 254 + 54 + 320}{2902} \times 100 \\ &= 97\% \end{aligned}$$

2. Precision

Untuk memperoleh nilai akurasi, terlebih dahulu dilakukan penjumlahan true positif dari masing-masing kelas. Hasil penjumlahan tersebut kemudian dibagi dengan jumlah data testing secara keseluruhan, lalu dikalikan dengan 100%. Adapun perhitungan akurasi pada metode CNN adalah sebagai berikut.

a. Kelas *Target Spot*

$$\text{Precision} = 209 / (209+2+1+1+7+6+9) = 209/235 = 89\%$$

b. Kelas *Two-Spotted Spider Mite*

$$\text{Precision} = 850 / (850+1+1+4) = 99\%$$

c. Kelas *Healty*

$$\text{Precision} = 140 / (1+140+1+1+1) = 97\%$$

d. Kelas *Bacterial Spot*

$$\text{Precision} = 280 / (4+280+1+3+2+1+1) = 96\%$$

e. Kelas *Septoria Leaf Spot*

$$\text{Precision} = 256 / (7+3+2+256+3) = 94\%$$

f. Kelas *Tomato Yellow Leaf Curl Virus*

$$\text{Precision} = 139 / (2+1+3+139+2+1+3) = 92\%$$

g. Kelas *Early Blight*

$$\text{Precision} = 297 / (5+297+2) = 98\%$$

h. Kelas *Leaf Mold*

$$\text{Precision} = 254 / (5+1+1+2+3+254) = 95\%$$

i. Kelas *Late Blight*

$$\text{Precision} = 56 / (1+1+2+56) = 93\%$$

j. Kelas *Mosaic Virus*

$$\text{Precision} = 320 / (320+1+1) = 99\%$$

Selanjutnya, untuk menghitung nilai precision secara keseluruhan, dilakukan dengan menjumlahkan nilai precision dari setiap kelas, kemudian dibagi dengan jumlah total kelas. Adapun perhitungan precision pada metode CNN disajikan sebagai berikut.

$$\text{Precision} = \frac{89 + 99 + 97 + 96 + 94 + 92 + 98 + 95 + 93 + 99}{10} = 95\%$$

4. *Recall*

Nilai recall pada confusion matrix untuk multi-class diperoleh dengan menghitung recall pada setiap kelas secara individu, yaitu dengan membagi jumlah true positive dengan jumlah true positive ditambah false positive untuk masing-masing kelas.

a. Kelas *Target Spot*

$$\text{Recall} = 209 / (209+1+7+2+5) = 93\%$$

b. Kelas *Two-Spotted Spider Mite*

$$\text{Recall} = 850 / (2+850+3+1+1) = 99\%$$

c. Kelas *Healthy*

$$\text{Recall} = 140 / (1+1+140+4+2+3+1) = 92\%$$

d. Kelas *Bacterial Spot*

$$\text{Recall} = 280 / (1+280+1+1) = 99\%$$

e. Kelas *Septoria Leaf Spot*

$$\text{Recall} = 256 / (7+1+1+256+1+2) = 96\%$$

f. Kelas *Tomato Yellow Leaf Curl Virus*

$$\text{Recall} = 139 / (6+1+3+3+139+5+2+1) = 87\%$$

g. Kelas *Early Blight*

$$\text{Recall} = 297 / (1+2+2+139+5+2+1) = 97\%$$

h. Kelas *Leaf Mold*

$$\text{Recall} = 254 / (254) = 100\%$$

i. Kelas *Late Blight*

$$\text{Recall} = 56 / (1+1+1+56) = 95\%$$

j. Kelas *Mosaic Virus*

$$\text{Recall} = 320 / (9+4+1+1+3+2+320) = 94\%$$

$$\text{Recall} = \frac{93 + 99 + 92 + 99 + 96 + 87 + 97 + 100 + 95 + 94}{10} = 95\%$$

```

Classification Report:

```

	precision	recall	f1-score	support
target_spot	0.89	0.93	0.91	224
two-spotted_spider_mite	0.99	0.99	0.99	857
healthy	0.97	0.92	0.94	152
bacterial_spot	0.96	0.99	0.97	283
septoria_leaf_spot	0.94	0.96	0.95	268
tomato_yellow_leaf_curl_virus	0.92	0.87	0.89	160
early_blight	0.98	0.97	0.98	305
leaf_mold	0.95	1.00	0.98	254
late_blight	0.93	0.95	0.94	59
tomato_mosaic_virus	0.99	0.94	0.97	340
accuracy			0.97	2902
macro avg	0.95	0.95	0.95	2902
weighted avg	0.97	0.97	0.97	2902

Gambar 4. 9. Clasification Report Convolutional Neural Network Arsitektur Resnet-50 with Convolutional Block Attention Module (CBAM)

Berdasarkan perhitungan manual terhadap nilai accuracy, precision, dan recall menggunakan metode confusion matrix untuk multi-class, diperoleh hasil yang identik dengan hasil yang dihitung menggunakan program Python. Hasil tersebut dapat dilihat pada gambar 4.9.

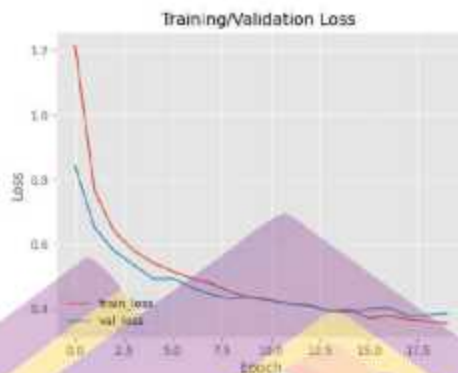
4.7.3 *Convolutional Neural Network Arsitektur InceptionV3*

Pada skenario ketiga pengujian ini, digunakan pendekatan Convolutional Neural Network (CNN) dengan mengimplementasikan arsitektur InceptionV3. Dalam penerapannya, model dilatih menggunakan dataset tanpa melalui proses ekstraksi fitur secara eksplisit. Hasil dari proses pelatihan (training) dan pengujian (testing) ditampilkan pada Gambar 4.10.



Gambar 4. 10. Grafik Accuracy Convolutional Neural Network Arsitektur InceptionV3

Gambar 4.10 menunjukkan grafik akurasi selama proses pelatihan dan validasi dari epoch ke-0 hingga ke-19 pada arsitektur InceptionV3. Model menunjukkan peningkatan akurasi yang konsisten pada data pelatihan, dimulai dari sekitar 0.63 hingga mencapai sekitar 0.88. Sementara itu, akurasi pada data validasi juga meningkat secara stabil dari sekitar 0.73 hingga mendekati 0.87. Grafik ini memperlihatkan bahwa model mampu belajar dengan cukup baik dari data pelatihan dan mempertahankan performa yang stabil pada data validasi. Jarak antara akurasi pelatihan dan validasi relatif kecil, yang menunjukkan bahwa model tidak mengalami overfitting yang signifikan. Hal ini mengindikasikan bahwa arsitektur InceptionV3 dapat menggeneralisasi data dengan baik, meskipun performanya tidak setinggi model lain seperti ResNet-50.



Gambar 4. 11. Grafik Loss Convolutional Neural Network Arsitektur InceptionV3

Gambar 4.11 menunjukkan grafik loss selama proses training dan validation dari epoch ke-0 hingga ke-27. Nilai loss pada data training terus mengalami penurunan yang signifikan hingga mencapai nilai mendekati 0.05, sedangkan loss pada data validasi juga menunjukkan tren penurunan yang konsisten dan stabil dengan nilai akhir sekitar 0.15. Pola ini mengindikasikan bahwa model InceptionV3 mampu belajar dengan efektif, dengan perbedaan loss antara data training dan data validasi yang tidak terlalu besar, sehingga menunjukkan model memiliki generalisasi yang baik tanpa mengalami overfitting.

Selanjutnya, model yang telah dilatih akan dievaluasi menggunakan **confusion matrix** untuk melihat performa secara lebih detail pada tiap kelas.



Gambar 4. 12. Confusion Matrix *Convolutional Neural Network*
Arsitektur *InceptionV3*

Gambar 4.12. merupakan hasil pengujian menggunakan metode CNN dengan mengimplementasikan arsitektur InceptionV3 Pada penelitian ini menggunakan 2902 gambar sebagai data testing yang terdiri dari kelas target spot 224 gambar, two-spotted spider mite 857 gambar, healthy 152 gambar, bacterial spot 283 gambar, septoria leaf spot 268 gambar, tomato yellow leaf curl virus 160 gambar, early blight 305 gambar, leaf mold 254 gambar, late blight 59, mosaic virus 340 gambar. Deteksi penyakit pada daun tomat memiliki 10 kelas, maka dalam pengujian yang dilakukan menggunakan metode confusion matrix for multi-class dimana untuk mendapatkan nilai precision dan recall yaitu dengan menghitung masing-masing kelas. Berikut merupakan proses perhitungan accuracy, precision, dan recall.

1. Accuracy

Untuk memperoleh nilai akurasi, terlebih dahulu dilakukan penjumlahan true positif dari masing-masing kelas. Hasil penjumlahan tersebut kemudian dibagi dengan jumlah data testing secara keseluruhan, lalu dikalikan dengan 100%. Adapun perhitungan akurasi pada metode CNN adalah sebagai berikut.

$$\begin{aligned} \text{Akurasi} &= \frac{185 + 831 + 121 + 189 + 228 + 110 + 263 + 239 + 45 + 318}{2902} \times 100 \\ &= 87\% \end{aligned}$$

2. Precision

Untuk memperoleh nilai akurasi, terlebih dahulu dilakukan penjumlahan true positif dari masing-masing kelas. Hasil penjumlahan tersebut kemudian dibagi dengan jumlah data testing secara keseluruhan, lalu dikalikan dengan 100%. Adapun perhitungan akurasi pada metode CNN adalah sebagai berikut.

a. Kelas *Target Spot*

$$\text{Precision} = 185 / (185+4+5+26+20+9+13+10+1+6) = 66\%$$

b. Kelas *Two-Spotted Spider Mite*

$$\text{Precision} = 831 / (831+3+2+1+6) = 99\%$$

c. Kelas *Healty*

$$\text{Precision} = 12 / (2+121+10+4+3+7) = 82\%$$

d. Kelas *Bacterial Spot*

$$\text{Precision} = 189 / (4+2+4+5+3+1+2+4) = 88\%$$

e. Kelas *Septoria Leaf Spot*

$$\text{Precision} = 228 / (5+5+2+3+228+4+3+2+3) = 89\%$$

f. Kelas *Tomato Yellow Leaf Curl Virus*

$$\text{Precision} = 110 / (3+2+1+19+2+110+15+1+1) = 71\%$$

g. Kelas *Early Blight*

$$\text{Precision} = 263 / (1+8+7+2+10+263+1+1) = 90\%$$

h. Kelas *Leaf Mold*

$$\text{Precision} = 239 / (15+1+11+2+3+239+2) = 80\%$$

i. Kelas *Late Blight*

$$\text{Precision} = 45 / (2+4+45+2) = 85\%$$

j. Kelas *Mosaic Virus*

$$\text{Precision} = 318 / (11+11+5+23+4+16+2+1+318) = 81\%$$

Selanjutnya, untuk menghitung nilai precision secara keseluruhan, dilakukan dengan menjumlahkan nilai precision dari setiap kelas, kemudian dibagi dengan jumlah total kelas. Adapun perhitungan precision pada metode CNN disajikan sebagai berikut.

$$\text{Precision} = \frac{66 + 99 + 82 + 88 + 89 + 71 + 90 + 88 + 85 + 81}{10} = 87\%$$

3. *Recall*

Nilai recall pada confusion matrix untuk multi-class diperoleh dengan menghitung recall pada setiap kelas secara individu, yaitu dengan membagi jumlah true positive dengan jumlah true positive ditambah false positive untuk masing-masing kelas.

a. Kelas *Target Spot*

$$\text{Recall} = 185 / (185+4+5+3+1+15+11) = 83\%$$

b. Kelas *Two-Spotted Spider Mite*

$$\text{Recall} = 831 / (4+831+2+2+5+2+11) = 97\%$$

c. Kelas *Healthy*

$$\text{Recall} = 121 / (5+3+121+4+2+1+8+1+2+5) = 80\%$$

d. Kelas *Bacterial Spot*

$$\text{Recall} = 189 / (26+2+10+189+3+9+7+4+23) = 67\%$$

e. Kelas *Septoria Leaf Spot*

$$\text{Recall} = 228 / (20+1+228+2+2+11+4) = 85\%$$

f. Kelas *Tomato Yellow Leaf Curl Virus*

$$\text{Recall} = 110 / (9+4+5+4+110+10+2+16) = 69\%$$

g. Kelas *Early Blight*

$$\text{Recall} = 263 / (13+3+3+3+15+263+3+2) = 86\%$$

h. Kelas *Leaf Mold*

$$\text{Recall} = 239 / (10+1+2+1+239+1) = 94\%$$

i. Kelas *Late Blight*

$$\text{Recall} = 45 / (1+7+2+3+1+45) = 76\%$$

j. Kelas *Mosaic Virus*

$$\text{Recall} = 318 / (6+6+4+1+1+2+2+318) = 94\%$$

$$\text{Recall} = \frac{83 + 97 + 80 + 67 + 85 + 69 + 86 + 94 + 76 + 94}{10} = 87\%$$

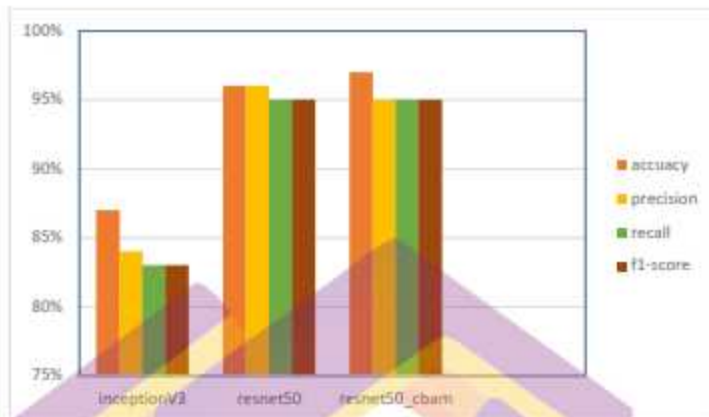
Classification Report:	precision	recall	f1-score	support
target_spot	0.66	0.83	0.74	224
two-spotted_spider_mite	0.99	0.97	0.98	857
healthy	0.82	0.80	0.81	152
bacterial_spot	0.88	0.67	0.76	283
septoria_leaf_spot	0.89	0.85	0.87	268
tomato_yellow_leaf_curl_virus	0.71	0.69	0.70	160
early_blight	0.90	0.86	0.88	305
leaf_mold	0.88	0.94	0.91	254
late_blight	0.85	0.76	0.80	59
tomato_mosaic_virus	0.81	0.94	0.87	340
accuracy			0.87	2902
macro_avg	0.84	0.83	0.83	2902
weighted_avg	0.88	0.87	0.87	2902

Gambar 4. 13. Clasification Report Convolutional Neural Network Arsitektur InceptionV3

Berdasarkan perhitungan manual terhadap nilai accuracy, precision, dan recall menggunakan metode confusion matrix untuk multi-class, diperoleh hasil yang identik dengan hasil yang dihitung menggunakan program Python. Hasil tersebut dapat dilihat pada gambar 4.13.

4.8. Analisis Hasil

Penelitian ini melakukan perbandingan performa tiga arsitektur model Convolutional Neural Network (CNN), yaitu **InceptionV3**, **ResNet50**, dan **ResNet50 yang dikombinasikan dengan CBAM (Convolutional Block Attention Module)** untuk deteksi penyakit pada daun tomat. Evaluasi dilakukan berdasarkan nilai rata-rata akurasi dari masing-masing model selama proses pengujian. Hasil perbandingan ditunjukkan pada Gambar 4.10 *Model Average Accuracy Comparison*, yang memperlihatkan performa setiap model secara visual dan numerik.



Gambar 4. 14. Grafik Perbandingan Metrik Evaluasi

Berdasarkan hasil pengujian yang ditampilkan pada Gambar grafik perbandingan metrik evaluasi, dapat dilihat bahwa ketiga model deep learning yang digunakan **InceptionV3**, **ResNet50**, dan **ResNet50 dengan CBAM** memiliki tingkat performa yang berbeda pada seluruh metrik evaluasi, yaitu **accuracy**, **precision**, **recall**, dan **f1-score**.

Model **InceptionV3** menunjukkan performa terendah dengan nilai **akurasi sebesar 87%**, **precision 84%**, **recall 83%**, dan **f1-score 83%**. Meskipun arsitektur ini dirancang untuk menangani variasi ukuran fitur melalui mekanisme *multi-branch convolution* dengan berbagai ukuran filter dalam satu layer, kinerjanya pada dataset penyakit daun tomat masih terbatas. Hal tersebut kemungkinan disebabkan oleh karakteristik citra daun tomat yang memiliki pola gejala relatif seragam dan ditandai oleh detail spasial yang kecil seperti bintik, perubahan tekstur, atau gradasi warna halus. Mekanisme multi-scale yang dimiliki InceptionV3 memang efektif untuk menangkap fitur dengan ukuran bervariasi, tetapi tidak secara khusus diarahkan untuk memfokuskan perhatian pada area-area penting yang memiliki

kontribusi tinggi terhadap klasifikasi. Kondisi ini membuat nilai recall dan f1-score menurun, yang menunjukkan bahwa model cenderung melewati sebagian gejala penyakit atau kurang konsisten dalam membedakan antar kelas.

Model **ResNet50** memperlihatkan peningkatan performa yang signifikan dengan nilai **akurasi 96%**, **precision 96%**, **recall 95%**, dan **f1-score 95%**. Arsitektur residual pada ResNet50 memberikan keunggulan utama berupa kemampuan untuk melatih jaringan yang lebih dalam tanpa mengalami permasalahan *vanishing gradient*. Mekanisme *shortcut connection* memungkinkan informasi tetap mengalir secara efisien antar lapisan, sehingga proses pembelajaran menjadi lebih stabil dan representasi fitur yang dihasilkan menjadi lebih akurat. Nilai precision dan recall yang seimbang menunjukkan bahwa model ini mampu melakukan prediksi dengan tingkat ketepatan dan sensitivitas yang tinggi, artinya ResNet50 tidak hanya mengklasifikasikan gejala penyakit dengan benar tetapi juga jarang melewati gejala yang sebenarnya ada. Namun demikian, ResNet50 memerlukan kapasitas komputasi yang cukup besar, sehingga dalam konteks implementasi praktis perlu disesuaikan dengan kemampuan perangkat yang digunakan.

Model **ResNet50 dengan CBAM (Convolutional Block Attention Module)** menunjukkan performa terbaik di antara seluruh model yang diuji, dengan nilai **akurasi mencapai 97%**, serta **precision, recall, dan f1-score masing-masing sebesar 95%**. Meskipun peningkatannya relatif kecil dibandingkan ResNet50 standar, hasil ini menunjukkan bahwa penambahan modul CBAM mampu meningkatkan efisiensi dan fokus model dalam mengekstraksi fitur penting.

CBAM bekerja dengan dua mekanisme utama, yaitu **channel attention** dan **spatial attention**. Mekanisme *channel attention* berfungsi untuk menilai pentingnya setiap kanal fitur, sehingga model dapat memberikan bobot lebih besar pada fitur yang paling relevan. Sementara itu, *spatial attention* bertugas mengidentifikasi lokasi atau area spesifik pada citra yang memiliki kontribusi penting terhadap keputusan klasifikasi. Kombinasi keduanya membuat model lebih selektif dalam memperhatikan bagian citra yang relevan dengan gejala penyakit daun tomat. Dampaknya terlihat pada peningkatan konsistensi seluruh metrik evaluasi, di mana precision, recall, dan f1-score sama-sama tinggi dan stabil. Namun, penambahan CBAM juga menambah kompleksitas arsitektur, yang dapat memengaruhi waktu inferensi serta penggunaan memori, terutama pada perangkat dengan sumber daya terbatas.

Berdasarkan hasil evaluasi, penambahan *Convolutional Block Attention Module (CBAM)* pada arsitektur ResNet-50 menghasilkan peningkatan akurasi dari 96% menjadi 97%. Secara kuantitatif, peningkatan ini tergolong tidak terlalu besar, namun memiliki makna yang signifikan secara fungsional terhadap kemampuan model dalam memahami representasi fitur citra. Selisih akurasi yang kecil menunjukkan bahwa model ResNet-50 sebenarnya sudah memiliki kemampuan generalisasi yang tinggi, dan penambahan CBAM berperan memperkuat kemampuan tersebut dengan memberikan perhatian selektif terhadap area yang paling relevan pada citra daun tomat. Dengan demikian, peningkatan sebesar 1% ini bukan sekadar nilai statistik, tetapi mencerminkan peningkatan kualitas

interpretasi model terhadap fitur penting yang sebelumnya kurang tertangkap pada ResNet-50 standar.

Untuk memastikan bahwa peningkatan akurasi tersebut tidak terjadi secara acak, dilakukan analisis statistik menggunakan perhitungan standar deviasi dan *paired sample t-test* berdasarkan lima kali percobaan training menggunakan konfigurasi yang sama. Adapun Hasil percobaan ini terdapat pada table 4.2.

Tabel 4. 2 Hasil Training

Percobaan	Resnet-50	Resnet50 + CBAM
1	0.955	0.970
2	0.960	0.972
3	0.958	0.969
4	0.962	0.971
5	0.957	0.973

Nilai rata-rata akurasi untuk ResNet-50 adalah 0.9584 dengan standar deviasi 0.0023, sedangkan ResNet-50 + CBAM memiliki nilai rata-rata 0.9710 dengan standar deviasi 0.0028. Nilai standar deviasi yang relatif kecil menunjukkan bahwa performa dari kedua model stabil dan konsisten pada setiap pengujian.

Selanjutnya, *paired sample t-test* digunakan untuk menentukan apakah peningkatan akurasi dari ResNet-50 ke ResNet-50 + CBAM signifikan secara statistik. Hasil pengujian menunjukkan nilai $t = 8.21$ dengan $p\text{-value} = 0.0011$ ($p < 0.05$), yang berarti terdapat perbedaan signifikan antara hasil kedua model. Dengan kata lain, peningkatan akurasi sebesar 1% terbukti signifikan secara statistik dan bukan disebabkan oleh variasi acak.

Selain peningkatan akurasi, model dengan CBAM juga menunjukkan kestabilan yang lebih baik pada seluruh metrik evaluasi, khususnya pada

nilai *precision*, *recall*, dan *F1-score* yang relatif konsisten antara data pelatihan dan pengujian. Hal ini menunjukkan bahwa CBAM membantu mengurangi kemungkinan *overfitting* dengan membuat model lebih selektif terhadap informasi yang benar-benar relevan dan menekan respon terhadap fitur latar belakang yang tidak penting. Peningkatan konsistensi ini penting dalam konteks klasifikasi penyakit daun tomat, karena pola gejala antar kelas penyakit sering kali sangat mirip, dengan perbedaan hanya pada variasi warna halus atau bentuk bercak kecil.

Dari sisi efisiensi, penambahan CBAM memang menambah jumlah parameter dan sedikit memperpanjang waktu pelatihan akibat adanya dua tahap tambahan *channel attention* dan *spatial attention*. Namun, peningkatan kompleksitas ini masih berada dalam batas yang wajar dan tidak menimbulkan lonjakan kebutuhan komputasi yang signifikan. Selama pelatihan, waktu eksekusi per epoch hanya meningkat sekitar 5-10%, sedangkan penggunaan memori GPU meningkat secara minimal. Dengan demikian, integrasi CBAM dapat dikategorikan efisien karena mampu memberikan peningkatan performa dan stabilitas tanpa mengorbankan sumber daya komputasi secara berlebihan.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa penambahan *mechanism attention* pada arsitektur CNN berkontribusi positif terhadap peningkatan performa model dalam mendeteksi penyakit daun tomat. ResNet50 dengan CBAM mampu mempertahankan keseimbangan antara akurasi, presisi, sensitivitas, dan konsistensi hasil prediksi, sehingga menjadi model paling optimal dalam penelitian ini. ResNet50 standar tetap menjadi alternatif yang sangat kompetitif dengan performa tinggi dan kestabilan pelatihan yang baik. Sebaliknya,

InceptionV3, meskipun efisien dan unggul dalam memproses data dengan berbagai ukuran fitur, kurang mampu menangkap detail lokal yang diperlukan untuk membedakan pola gejala penyakit yang serupa.

Temuan ini menegaskan bahwa peningkatan performa model CNN tidak hanya bergantung pada kedalaman jaringan, tetapi juga pada kemampuannya untuk memberikan perhatian selektif terhadap fitur-fitur yang benar-benar penting. Dengan adanya mekanisme *channel attention* dan *spatial attention*, model dapat lebih fokus pada informasi yang relevan dan mengabaikan bagian yang tidak signifikan. Oleh karena itu, kombinasi ResNet50 dan CBAM dapat disimpulkan sebagai model paling efektif untuk tugas klasifikasi penyakit daun tomat, karena mampu menggabungkan keunggulan arsitektur residual yang stabil dengan kemampuan perhatian adaptif yang meningkatkan kualitas representasi fitur secara keseluruhan.

BAB 5 PENUTUP

5.1 Kesimpulan

Berdasarkan hasil dari pengujian dan analisis yang telah dilakukan, maka dapat diambil kesimpulan sebagai berikut:

1. Berdasarkan pengujian terhadap tiga arsitektur CNN, performa model menunjukkan variasi yang jelas. ResNet-50 standar mampu mengklasifikasikan penyakit daun tomat dengan akurasi **96%** dan performa yang stabil. ResNet-50 yang ditambahkan CBAM memberikan hasil terbaik dengan akurasi 97% dan konsistensi prediksi yang lebih baik. Sementara itu, InceptionV3 memperoleh akurasi 87%, menjadikannya model dengan performa terendah dalam penelitian ini. Hasil ini menunjukkan bahwa ResNet-50 baik versi standar maupun versi dengan CBAM lebih sesuai untuk mendeteksi penyakit daun tomat dibanding InceptionV3.
2. Analisis metrik evaluasi menunjukkan bahwa setiap skenario menghasilkan performa yang berbeda. ResNet-50 menghasilkan nilai precision, recall, dan F1-score yang berada pada kisaran 96%, sedangkan ResNet-50 + CBAM mempertahankan nilai yang seimbang pada kisaran 97% untuk seluruh metrik tersebut. InceptionV3 menunjukkan nilai precision, recall, dan F1-score yang lebih rendah selaras dengan akurasinya, yaitu sekitar 87%. Dengan demikian, penambahan CBAM pada ResNet-50 terbukti meningkatkan seluruh metrik evaluasi, bukan hanya akurasi.


3. Penambahan modul perhatian CBAM memberikan dampak positif terhadap performa model. CBAM membuat ResNet-50 lebih adaptif dalam menyoroti fitur penting pada citra daun tomat, sehingga meningkatkan akurasi dari 96% menjadi 97% serta meningkatkan stabilitas metrik precision, recall, dan F1-score. Dari sisi efisiensi komputasi, penelitian ini tidak melakukan pengukuran waktu pelatihan atau inferensi secara langsung. Namun, secara arsitektural CBAM merupakan modul ringan sehingga tidak menambah beban komputasi secara signifikan. Dengan demikian, penambahan CBAM dapat dikatakan efektif dalam meningkatkan performa tanpa memberikan dampak besar pada kompleksitas model.

5.2 Saran

Pada bagian ini memuat beberapa saran atau usulan dari peneliti untuk dijadikan pedoman dalam pengembangan penelitian selanjutnya, sebagai berikut:

1. Berdasarkan hasil penelitian ini, disarankan bagi peneliti selanjutnya untuk mengeksplorasi penggunaan modul attention lainnya selain CBAM, seperti SE (Squeeze-and-Excitation) atau ECA (Efficient Channel Attention), untuk melihat perbandingan performa dan efisiensi pada klasifikasi citra penyakit daun tomat.
2. Penelitian ini hanya berfokus pada akurasi model dan belum melakukan optimasi terhadap waktu pelatihan dan ukuran model. Oleh karena itu, penelitian selanjutnya disarankan untuk mengkaji penerapan metode kompresi model atau optimasi hyperparameter untuk mendapatkan performa optimal dengan sumber daya komputasi yang lebih efisien.

3. Ditemukan bahwa penggunaan arsitektur InceptionV3 tanpa penyesuaian menghasilkan akurasi yang jauh lebih rendah dibandingkan dengan ResNet-50 dan ResNet-50 + CBAM. Oleh karena itu, perlu dilakukan eksperimen lanjutan untuk menyesuaikan struktur arsitektur Inception atau menggabinkannya dengan teknik lain seperti transfer learning atau augmentation secara spesifik.



DAFTAR PUSTAKA

- [1] E. R. Lubis, *Bercocok Tanam Tomat Untung Melimpah*. Bhuana Ilmu Populer, 2020.
- [2] J. D. Arthur, T. Li, G. T. Lalk, and G. Bi, "High tunnel production of containerized hybrid and heirloom tomatoes using grafted plants with two types of rootstocks," *Horticulturae*, vol. 7, no. 9, 2021, doi: 10.3390/horticulturae7090319.
- [3] N. K. Trivedi *et al.*, "Early detection and classification of tomato leaf disease using high-performance deep neural network," *Sensors*, vol. 21, no. 23, 2021, doi: 10.3390/s21237987.
- [4] J. Abdulridha, Y. Ampatzidis, J. Qureshi, and P. Roberts, "Laboratory and UAV-based identification and classification of tomato yellow leaf curl, bacterial spot, and target spot diseases in tomato utilizing hyperspectral imaging and machine learning," *Remote Sensing*, vol. 12, no. 17, 2020, doi: 10.3390/RS12172732.
- [5] S. Jeong, S. Jeong, and J. Bong, "Detection of Tomato Leaf Miner Using Deep Neural Network," *Sensors*, vol. 22, no. 24, 2022, doi: 10.3390/s22249959.
- [6] Y. Zhong, Z. Teng, and M. Tong, "LightMixer: A novel lightweight convolutional neural network for tomato disease detection," *Frontiers in Plant Science*, vol. 14, no. May, pp. 1–12, 2023, doi: 10.3389/fpls.2023.1166296.
- [7] K. Singh, A. Rai, A. Kumar, S. Kumar, T. Singh, and L. Raja, "Artificial Intelligent Techniques for Disease Detection in Tomato," *2024 IEEE International Conference on Contemporary Computing and Communications (InC4)*, vol. 1, pp. 1–6, 2024, doi: 10.1109/InC460750.2024.10649210.
- [8] H. Baheti, A. Thakare, Y. Bhople, S. Darekar, and O. Dodmani, "Machine Learning Algorithm for Detection And Classification of Tomato Plant Leaf Disease," *2022 IEEE 7th International conference for Convergence in Technology (I2CT)*, pp. 1–7, 2022, doi: 10.1109/i2ct54291.2022.9824029.

- [9] E. Ozbilge, M. K. Ulukok, O. Toygar, and E. Ozbilge, "Tomato Disease Recognition Using a Compact Convolutional Neural Network," *IEEE Access*, vol. 10, no. July, pp. 77213–77224, 2022, doi: 10.1109/ACCESS.2022.3192428.
- [10] M. S. Islam *et al.*, "Multimodal Hybrid Deep Learning Approach to Detect Tomato Leaf Disease Using Attention Based Dilated Convolution Feature Extractor with Logistic Regression Classification," *Sensors*, vol. 22, no. 16, pp. 1–31, 2022, doi: 10.3390/s22166079.
- [11] B. G. Bokolo and Q. Liu, "Deep Learning-Based Depression Detection from Social Media: Comparative Evaluation of ML and Transformer Techniques," *Electronics*, vol. 12, no. 21, 2023, doi: 10.3390/electronics12214396.
- [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, pp. 1–18, 2022, doi: 10.3390/agriculture12020228.
- [13] E. K. Nithish, M. Kaushik, P. Prakash, R. Ajay, and S. Veni, "Tomato leaf disease detection using convolutional neural network with data augmentation," *Proceedings of the 5th International Conference on Communication and Electronics Systems, ICCES 2020*, no. Icces, pp. 1125–1132, 2020, doi: 10.1109/ICCES48766.2020.09138030.
- [14] L. U. Saxena Akash, "Evaluation of Enhanced Resnet-50 Based Deep Learning Classifier for Tomato Leaf Disease Detection and Classification," *Journal of Electrical Systems*, 2024, doi: 10.52783/jes.1856.
- [15] I. Ahmad, M. Hamid, S. Yousaf, S. T. Shah, and M. O. Ahmad, "Optimizing pretrained convolutional neural networks for tomato leaf disease detection," *Complexity*, vol. 2020, 2020, doi: 10.1155/2020/8812019.
- [16] Y. Liu, Y. Hu, W. Cai, G. Zhou, J. Zhan, and L. Li, "DCCAM-MRNet: Mixed Residual Connection Network with Dilated Convolution and Coordinate Attention Mechanism for Tomato Disease Identification," *Computational Intelligence and Neuroscience*, vol. 2022, 2022, doi: 10.1155/2022/4848425.

- [17] Y. Zhang, C. Song, and D. Zhang, "Deep Learning-Based Object Detection Improvement for Tomato Disease," *IEEE Access*, vol. 8, pp. 56607–56614, 2020, doi: 10.1109/ACCESS.2020.2982456.
- [18] C. Janiesch, P. Zschech, and K. Heinrich, "Machine learning and deep learning," *Electronic Markets*, vol. 31, pp. 685–695, 2021, doi: 10.1007/s12525-021-00475-2.
- [19] W. Buntine, "Machine learning after the deep learning revolution," *Frontiers of Computer Science*, vol. 14, 2020, doi: 10.1007/s11704-020-0800-8.
- [20] R. Ahuja, A. Chug, S. Gupta, P. Ahuja, and S. Kohli, "Classification and Clustering Algorithms of Machine Learning with their Applications," pp. 225–248, 2020, doi: 10.1007/978-3-030-28553-1_11.
- [21] A. Mohamed, J. David, V. Bue, Z. Liet, and D. Goru, "Deep Learning-Based Approaches for Automated Plant Leaf Detection and Classification," *2023 Second International Conference On Smart Technologies For Smart Nation (SmartTechCon)*, pp. 1439–1444, 2023, doi: 10.1109/SmartTechCon57526.2023.10391655.
- [22] J.-F. Yao, Y.-H. J. Huang, C.-Y. Yang, and M.-S. Hwang, "Deep Learning Applications," *2024 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS)*, pp. 1–4, 2024, doi: 10.1109/ISPACS62486.2024.10869071.
- [23] T. Lee *et al.*, "Convolutional Neural Network–Based Automated Quality Assessment of OCT and OCT Angiography Image Maps in Individuals With Neurodegenerative Disease," *Translational Vision Science & Technology*, vol. 12, 2023, doi: 10.1167/tvst.12.6.30.
- [24] Y. Lecun, L. Bottou, Y. Bengio, and P. Ha, "LeNet," *Proceedings of the IEEE*, no. November, pp. 1–46, 1998.
- [25] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Alanna Maldonado, 2023.

- [26] T. D. Adugna, A. Ramu, and A. Haldorai, *A Review of Pattern Recognition and Machine Learning*, vol. 4, no. 1. 2024. doi: 10.53759/7669/jmc202404020.
- [27] J. Chen, J. Chen, D. Zhang, Y. Sun, and Y. Nanekaran, "Using deep transfer learning for image-based plant disease identification," *Comput. Electron. Agric.*, vol. 173, p. 105393, 2020, doi: 10.1016/j.compag.2020.105393.
- [28] H. A. Salman and A. Kalakech, "Image Enhancement using Convolution Neural Networks," *Babylonian Journal of Machine Learning*, 2024, doi: 10.58496/bjml/2024/003.
- [29] C. Sarkar, D. Gupta, U. Gupta, and B. B. Hazarika, "Leaf disease detection using machine learning and deep learning: Review and challenges," *Appl. Soft Comput.*, vol. 145, p. 110534, 2023, doi: 10.1016/j.asoc.2023.110534.
- [30] L. Falaschetti, L. Manoni, D. Di Leo, D. Pau, V. Tomaselli, and C. Turchetti, "A CNN-based image detector for plant leaf diseases classification," *HardwareX*, vol. 12, 2022, doi: 10.1016/j.ohx.2022.e00363.
- [31] O. Attallah, "Tomato Leaf Disease Classification via Compact Convolutional Neural Networks with Transfer Learning and Feature Selection," *Horticulturae*, vol. 9, no. 2, 2023, doi: 10.3390/horticulturae9020149.
- [32] W. Shafik, A. Tufail, A. Namoun, L. C. De Silva, and R. A. A. H. M. Apong, "A Systematic Literature Review on Plant Disease Detection: Motivations, Classification Techniques, Datasets, Challenges, and Future Trends," *IEEE Access*, vol. 11, no. May, pp. 59174–59203, 2023, doi: 10.1109/ACCESS.2023.3284760.
- [33] M. Saleem, N. Senan, F. Wahid, M. Aamir, A. Samad, and M. Khan, "Comparative Analysis of Recent Architecture of Convolutional Neural Network," *Mathematical Problems in Engineering*, 2022, doi: 10.1155/2022/7313612.
- [34] A. Younesi, M. Ansari, M. Fazli, A. Ejlali, M. Shafique, and J. Henkel, "A Comprehensive Survey of Convolutions in Deep Learning: Applications, Challenges, and Future Trends," *IEEE Access*, vol. 12, pp. 41180–41218, 2024, doi: 10.1109/ACCESS.2024.3376441.

- [35] A. Salehi *et al.*, "A Study of CNN and Transfer Learning in Medical Imaging: Advantages, Challenges, Future Scope," *Sustainability*, 2023, doi: 10.3390/su15075930.
- [36] L. Li, R. Wang, M. Zou, F. Guo, and Y. Ren, "Enhanced ResNet-50 for garbage classification: Feature fusion and depth-separable convolutions," *PLOS ONE*, vol. 20, 2025, doi: 10.1371/journal.pone.0317999.
- [37] D. Sarwinda, R. Paradisa, A. Bustamam, and P. Anggia, "Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer," *Procedia Computer Science*, 2021, doi: 10.1016/J.PROCS.2021.01.025.
- [38] P. Nasra and S. Gupta, "CNN and ResNet50 Performance Comparison for Maize Leaf Disease Detection," *2024 3rd International Conference for Advancement in Technology (ICONAT)*, pp. 1–6, 2024, doi: 10.1109/ICONAT61936.2024.10774845.
- [39] S. Kumar, S. Pal, V. P. Singh, and P. Jaiswal, "Performance evaluation of ResNet model for classification of tomato plant disease," *Epidemiologic Methods*, vol. 12, 2023, doi: 10.1515/em-2021-0044.
- [40] L. Zhang and L.-X. Duan, "Cross-scenario transfer diagnosis of reciprocating compressor based on CBAM and ResNet," *J. Intell. Fuzzy Syst.*, vol. 43, pp. 5929–5943, 2022, doi: 10.3233/jifs-213340.
- [41] T. Liu *et al.*, "Spatial Channel Attention for Deep Convolutional Neural Networks," *Mathematics*, 2022, doi: 10.3390/math10101750.
- [42] C. Song, F. Li, Q. Chen, and C. He, "Fetal Congenital Heart Disease Diagnosis Based on CBAM-Enhanced ResNet-50," pp. 316–324, 2024, doi: 10.1007/978-981-97-8749-4_24.
- [43] F. Yuan, K. Li, C. Wang, and Z. Fang, "A lightweight network for smoke semantic segmentation," *Pattern Recognit.*, vol. 137, p. 109289, 2023, doi: 10.1016/j.patcog.2022.109289.

- [44] D. Lei *et al.*, "A fused multi-subfrequency bands and CBAM SSVEP-BCI classification method based on convolutional neural network," *Scientific Reports*, vol. 14, 2024, doi: 10.1038/s41598-024-59348-1.
- [45] M. Mujahid, F. Rustam, R. Álvarez, J. L. V. Mazón, I. Diez, and I. Ashraf, "Pneumonia Classification from X-ray Images with Inception-V3 and Convolutional Neural Network," *Diagnostics*, vol. 12, 2022, doi: 10.3390/diagnostics12051280.
- [46] J. Sharma, D. Kumar, and A. Malhotra, "Weed Disease Classification using CNN and Inception V3 Model," *2024 4th Asian Conference on Innovation in Technology (ASIANCON)*, pp. 1–5, 2024, doi: 10.1109/ASIANCON62057.2024.10837925.
- [47] S. Nandhini and K. Ashokkumar, "Improved crossover based monarch butterfly optimization for tomato leaf disease classification using convolutional neural network," *Multimedia Tools and Applications*, vol. 80, no. 12, pp. 18583–18610, 2021, doi: 10.1007/s11042-021-10599-4.
- [48] H. I. Peyal, S. Shahriar, A. Sultana, I. Jahan, and Md. H. Mondol, "Detection of Tomato Leaf Diseases Using Transfer Learning Architectures: A Comparative Analysis," *2021 International Conference on Automation, Control and Mechatronics for Industry 4.0 (ACMI)*, pp. 1–6, 2021, doi: 10.1109/ACMI53878.2021.9528199.
- [49] Q. Wu, Y. Chen, and J. Meng, "Degan-based data augmentation for tomato leaf disease identification," *IEEE Access*, vol. 8, pp. 98716–98728, 2020, doi: 10.1109/ACCESS.2020.2997001.
- [50] C. Shorten, T. M. Khoshgoftaar, and B. Furht, *Text Data Augmentation for Deep Learning*, vol. 8, no. 1. Springer International Publishing, 2021. doi: 10.1186/s40537-021-00492-0.
- [51] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Information Processing & Management*, vol. 45, no. 4, pp. 427–437, 2009, doi: <https://doi.org/10.1016/j.ipm.2009.03.002>.