

**OPTIMALISASI ARSITEKTUR INCEPTIONV4 DENGAN  
MEKANISME PERHATIAN CBAM DALAM MENDIAGNOSIS  
PENYAKIT DAUN JERUK**

**SKRIPSI**

**OLEH:**

**ASTRI YOHANA SIDAURUK**

**218160034**



**PROGRAM STUDI TEKNIK INFORMATIKA  
FAKULTAS TEKNIK  
UNIVERSITAS MEDAN AREA  
MEDAN  
2025**

**UNIVERSITAS MEDAN AREA**

-----  
© Hak Cipta Di Lindungi Undang-Undang

Document Accepted 1/8/25

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber  
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah  
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Access From (repository.uma.ac.id)1/8/25

**OPTIMALISASI ARSITEKTUR INCEPTIONV4 DENGAN  
MEKANISME PERHATIAN CBAM DALAM MENDIAGNOSIS  
PENYAKIT DAUN JERUK**

**SKRIPSI**

**Diajukan sebagai Salah Satu Syarat untuk Memperoleh  
Gelar Sarjana di Fakultas Teknik  
Universitas Medan Area**

**Oleh:**

**ASTRI YOHANA SIDAURUK**

**218160034**

**PROGRAM STUDI TEKNIK INFORMATIKA  
FAKULTAS TEKNIK  
UNIVERSITAS MEDAN AREA  
MEDAN  
2025**

**UNIVERSITAS MEDAN AREA**

-----  
© Hak Cipta Di Lindungi Undang-Undang

Document Accepted 1/8/25

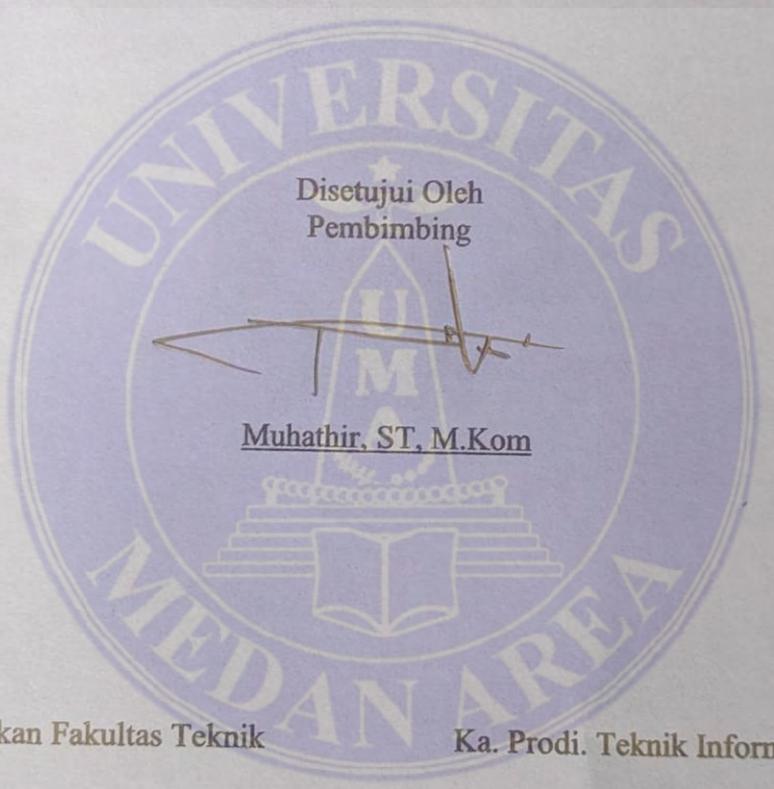
1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber  
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah  
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Access From (repository.uma.ac.id)1/8/25

## **HALAMAN PENGESAHAN**

Judul Skripsi : Optimalisasi arsitektur InceptionV4 dengan Mekanisme Perhatian CBAM dalam Mendiagnosis Penyakit Daun Jeruk

Nama : Astri Yohana Sidauruk  
NPM : 218160034  
Fakultas : Teknik



Tanggal Lulus: 14 Maret 2025

UNIVERSITAS MEDAN AREA

## HALAMAN PERNYATAAN

Saya menyatakan bahwa skripsi yang saya susun, sebagai syarat memperoleh gelar sarjana merupakan hasil karya tulis saya sendiri. Adapun bagian-bagian tertentu dalam penulisan skripsi ini yang saya kutip dari hasil karya orang lain telah dituliskan sumbernya secara jelas sesuai dengan norma, kaidah, dan etika penulisan ilmiah.

Saya bersedia menerima sanksi pencabutan gelar akademik yang saya peroleh dan sanksi-sanksi lainnya dengan peraturan yang berlaku, apabila di kemudian hari ditemukan adanya plagiat dalam skripsi ini.



**HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI  
TUGAS AKHIR/SKRIPSI/TESIS UNTUK KEPENTINGAN AKADEMIS**

Sebagai sivitas akademik Universitas Medan Area, saya yang bertanda tangan di bawah ini:

Nama : Astri Yohana Sidauruk  
NPM : 218160034  
Program Studi : Teknik Informatika  
Fakultas : Teknik  
Jenis Karya : Skripsi

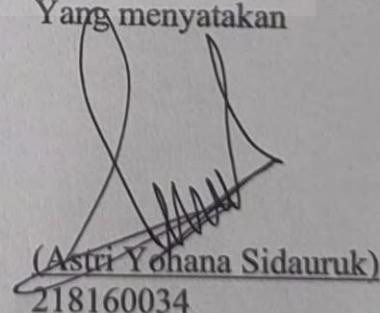
Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Medan Area **Hak Bebas Royalti Noneksklusif (Non-exclusive Royalty-Free Right)** atas karya ilmiah saya yang berjudul :

**Optimalisasi Arsitektu INCEPTIONV4 dengan Mekanisme Perhatian CBAM dalam Mendiagnosis Penyakit Daun Jeruk.**

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Noneksklusif ini Universitas Medan Area berhak menyimpan, mengalihmedia/format-kan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan memublikasikan Skripsi saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Medan  
Pada tanggal : 14 Maret 2025  
Yang menyatakan

  
(Astri Yohana Sidauruk)  
218160034

## RIWAYAT HIDUP

Penulis, Astri Yohana Sidauruk, lahir di Medan, pada tanggal 24 Juli 2003. Penulis menempuh pendidikan dasar di SDN 016528 Bandar Pasir Mandoge dan lulus pada tahun 2015. Pendidikan menengah dilanjutkan di SMP Negri 3 Bandar Pasir Mandoge dan SMAS Katolik Trisakti Medan masing-masing lulus pada tahun 2018 dan 2021. Pada tahun 2021, penulis diterima di Program Studi Teknik Informatika, Fakultas Teknik, Universitas Medan Area.

Selama masa studinya, penulis aktif dalam berbagai kegiatan organisasi seperti Himpunan Mahasiswa Informatika, dan Badan Eksekutif Mahasiswa. Saat ini, penulis menyelesaikan pendidikan strata satu dengan menyusun skripsi berjudul “Optimalisasi Arsitektur *INCEPTIONV4* dengan Mekanisme Perhatian *CBAM* dalam Mendiagnosis Penyakit Daun Jeruk.”.



## KATA PENGANTAR

Puji syukur Kepada Tuhan yang Maha Esa atas berkat dan anugerah-Nya sehingga penulis dapat menyelesaikan Skripsi yang berjudul "**Optimalisasi Arsitektur INCEPTIONV4 dengan Mekanisme Perhatian CBAM dalam Mendiagnosis Penyakit Daun Jeruk**" ini dengan baik. Skripsi ini disusun guna memenuhi salah satu syarat untuk memperoleh gelar Sarjana di Tenik Informatika, Fakultas Teknik, Universitas Medan Area.

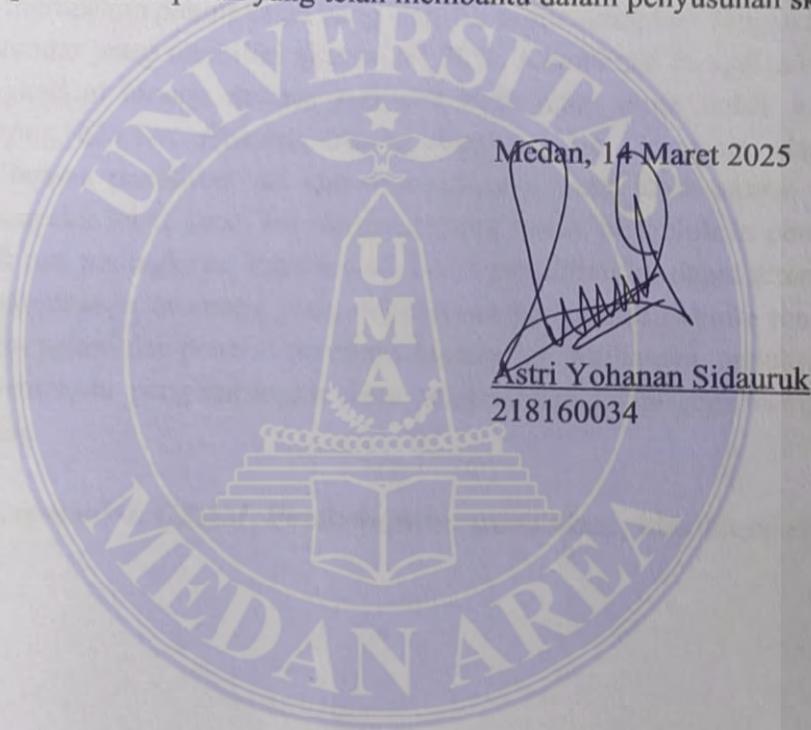
Dalam proses pembuatan skripsi ini penulis banyak mendapatkan bimbingan, arahan, dukungan doa dan juga kritik dari banyak pihak yang telah membantu dalam hal meningkatkan kualitas skripsi yang di buat. Oleh sebab itu Saya mengucapkan terimakasih sebesar-besarnya kepada:

1. Bapak Prof. Dr. Dadan Ramdan, M.Eng, M.Sc. Selaku Rektor Universitas Medan Area.
2. Bapak Dr. Eng. Supriatno, ST., MT selaku Dekan Fakultas Teknik Universitas Medan Area
3. Bapak Rizki Muliono, S.kom, M.kom. Selaku Kepala Program Studi Teknik Informatika.
4. Bapak Muhamathir, S.T, M.kom. Selaku Dosen pembimbing yang telah Sabar, memberikan perhatian penuh, Banyak Meluangkan Waktu dan juga selalu memberikan arahan serta bimbingan yang sangat berarti Untuk penulis. Karena dukungan yang sangat baik dari bapak penulis dapat menyelesaikan Skripsi ini Dengan Sangat Baik.
5. Seluruh Dosen Teknik Informatika Universitas Medan Area, yang telah berjasa dalam membagi ilmu, pengalaman dan wawasan yang sangat luar biasa selama masa perkuliahan. Di setiap pertemuan dalam mata kuliah memberikan nasehat dan dukungan terhadap penulis yang menjadi kekuatan tersendiri bagi penulis dalam menyelesaikan skripsi ini.
6. Abang Robby Kurniawan Sari Damanik, S.T., Sebagai IT Support Program studi Teknik Informatika, yang selalu menolong dan memberikan dukungan teknis selama penulis berkuliahan. Terimakasih atas kesabaran membantu penulis dalam menjawab pertanyaan dan juga membantu dalam berbagai kendala teknis yang saya hadapi selama masa perkuliahan.
7. Ibu tercinta, yang memberikan doa yang tiada henti, cinta kasih dan juga dukungan moril serta materi kepada penulis Sehingga penulis dapat menyelesaikan skripsi sampai akhir dengan baik. Tanpa restu, semangat yang tulus dari ibu, penulis tidak akan mampu sampai pada titik ini. Skripsi ini penulis persembahkan sebagai bentuk kecil dari rasa terimakasih atas segala yang telah diberikan kepada penulis.

8. Tarsius Tulus Hati Buulolo selaku partner spesial yang selalu memberikan kesabaran yang lebih dan dukungan yang luar biasa kepada penulis selama proses penyusunan skripsi ini sampai akhir sehingga menjadikan kekuatan tersendiri dalam menyelesaikan skripsi ini.
9. Gurlly sebagai sahabat-sahabat terbaik yang selalu memberikan dukungan, semangat, dan suka cita selama proses penyusunan skripsi ini.
10. Semua pihak yang tidak dapat di sebutkan satu persatu yang telah terlibat dalam penyelesaian skripsi ini sehingga dapat diselesaikan dengan baik.

Penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan. Oleh karena itu, kritik dan saran yang membangun sangat diharapkan demi perbaikan di masa depan. Semoga skripsi ini dapat memberikan manfaat bagi pembaca serta dapat menjadi referensi dalam penelitian lebih lanjut.

Akhir kata, Semoga Tuhan yang Maha Esa senantiasa melimpahkan berkat dan karunia-Nya kepada semua pihak yang telah membantu dalam penyusunan skripsi ini.



## UNIVERSITAS MEDAN AREA

## ABSTRAK

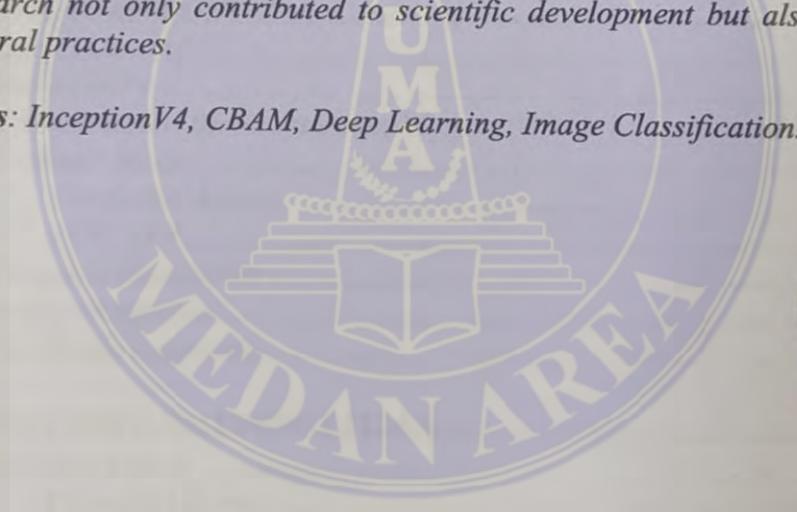
penelitian ini menggunakan arsitektur *InceptionV4* dan *Convolutional Block Attention Module (CBAM)* untuk mengoptimalkan diagnosis penyakit pada daun jeruk. *InceptionV4* adalah arsitektur jaringan saraf konvolusional yang dimaksudkan untuk menangkap elemen visual dari gambar melalui modul-modul inception, sementara *CBAM* berfungsi untuk meningkatkan pemfokusan model pada fitur penting melalui mekanisme perhatian spasial dan kanal. penelitian ini melibatkan penggunaan *InceptionV4* standar dan *InceptionV4* yang diintegrasikan dengan *CBAM* dimana *CBAM* diterapkan setelah modul *InceptionA* dan *InceptionB*. Hasilnya menunjukkan bahwa model *InceptionV4* yang diintegrasikan dengan *CBAM* mencapai akurasi 95,60%, presisi 95,91%, recall 95,60%, dan *F1-Score* 95,57%, yang merupakan peningkatan yang signifikan dibandingkan dengan model *InceptionV4* standar yang memiliki akurasi 91,80%. Kombinasi *InceptionV4* dan *CBAM* meningkatkan kinerja deteksi penyakit pada daun jeruk untuk kondisi seperti *Blackspot*, *Canker*, *Healthy*, *Young Healthy*, dan *Greening*. Hasilnya menunjukkan bahwa penelitian ini menawarkan cara yang lebih akurat untuk menemukan penyakit lebih awal. Ini sangat penting untuk pengelolaan pertanian yang lebih baik dan peningkatan hasil panen. Hasil penelitian ini dapat diterapkan pada sistem pemantauan otomatis yang melibatkan penggunaan drone real-time untuk membantu petani dan peneliti membuat keputusan. Akibatnya, penelitian ini tidak hanya membantu pengembangan ilmu pengetahuan tetapi juga membantu praktik pertanian.

**kata kunci:** *InceptionV4*, *CBAM*, Pembelajaran mendalam, klasifikasi citra.

## ABSTRACT

This research aimed to optimize the InceptionV4 model with Convolutional Block Attention Module (CBAM) for disease diagnosis on citrus leaves. InceptionV4 is a convolutional neural network architecture designed to capture visual elements from images through inception modules, while CBAM functioned to enhance the model's focus on important features through spatial and channel attention mechanisms. This research involved the use of standard InceptionV4 and InceptionV4 integrated with CBAM, where CBAM was applied after InceptionA and InceptionB modules. The results showed that the InceptionV4 model integrated with CBAM achieved 95.60% accuracy, 95.91% precision, 95.60% recall, and 95.57% F1-Score, which was a significant improvement compared to the standard InceptionV4 model with 91.80% accuracy. The combination of InceptionV4 and CBAM improved the performance of disease detection on citrus leaves for conditions such as Blackspot, Canker, Healthy, Young Healthy, and Greening. The results showed that this research offered a more accurate way to detect diseases early. This was very important for better agricultural management and increased crop yields. The research results could be applied to automated monitoring systems involving real-time drone use to assist farmers and researchers in making decisions. As a result, this research not only contributed to scientific development but also supported agricultural practices.

**Keywords:** InceptionV4, CBAM, Deep Learning, Image Classification.



## DAFTAR ISI

<b>HALAMAN PENGESAHAN.....</b>	<b>iii</b>
<b>HALAMAN PERNYATAAN.....</b>	<b>iv</b>
<b>RIWAYAT HIDUP .....</b>	<b>vi</b>
<b>KATA PENGANTAR.....</b>	<b>vii</b>
<b>ABSTRAK .....</b>	<b>viii</b>
<b>ABSTRACT .....</b>	<b>x</b>
<b>DAFTAR ISI.....</b>	<b>xi</b>
<b>DAFTAR TABEL .....</b>	<b>xiii</b>
<b>DAFTAR GAMBAR.....</b>	<b>xiv</b>
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1. Latar Belakang .....	1
1.2. Rumusan Masalah .....	3
1.3. Batasan Masalah.....	3
1.4. Tujuan Penelitian.....	4
1.5. Manfaat Penelitian.....	4
<b>BAB II TINJAUAN PUSTAKA.....</b>	<b>5</b>
2.1. <i>Deep Learning</i> .....	5
2.2. <i>InceptionV4</i> .....	6
2.3. <i>Convolutional Block Attention Module (CBAM)</i> .....	6
2.4. Evaluasi Model.....	7
2.4.1. <i>Confusion Matrix</i> .....	8
2.4.2. <i>ROC AUC</i> .....	10
2.5. Penyakit Daun Jeruk.....	11
2.6. Kasus Penelitian .....	12
2.7. Penelitian Terdahulu.....	13
<b>BAB III METODOLOGI PENELITIAN .....</b>	<b>17</b>
3.1. Alat dan Bahan .....	17
3.1.1. Perangkat Keras .....	17
3.1.2. Perangkat Lunak.....	17
3.2. Prosedur Kerja .....	18
3.2.1. Dataset.....	18
3.2.2. Pembagian Data .....	19
3.2.3. Augmentasi Data.....	19
3.2.4. Membangun Model .....	20
3.2.5. <i>Training Model</i> .....	26
3.2.6. Evaluasi Model.....	27
3.2.7. <i>Deploy Model (Web App)</i> .....	27
<b>BAB IV HASIL DAN PEMBAHASAN .....</b>	<b>28</b>
4.1. Hasil.....	28
4.1.1. Sampel Data .....	28

4.1.2.	Augmentasi Data .....	29
4.1.3.	Implementasi Model.....	31
4.1.4.	Hasil <i>Training Model InceptionV4</i> .....	31
4.1.5.	Hasil <i>Training Model InceptionV4 + CBAM</i> .....	35
4.1.6.	Implementasi <i>WEB</i> .....	38
4.1.7.	Implementasi <i>Mobile App</i> .....	40
4.2.	Pembahasan .....	46
<b>BAB V KESIMPULAN DAN SARAN .....</b>		<b>51</b>
5.1.	Kesimpulan.....	51
5.2.	Saran .....	51
<b>DAFTAR PUSTAKA .....</b>		<b>52</b>



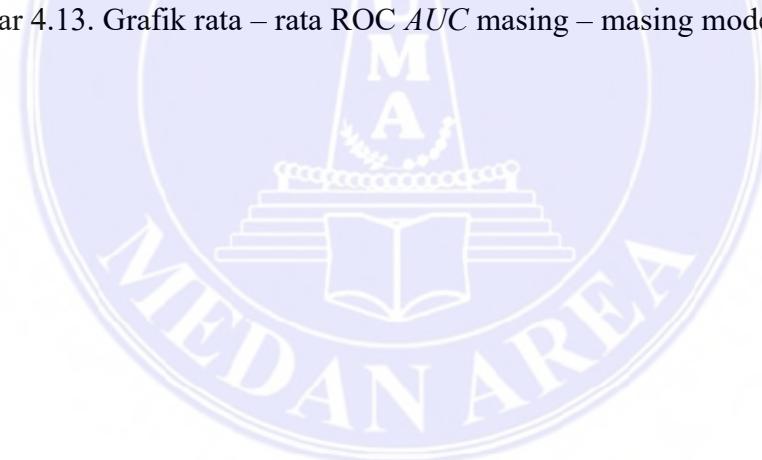
## DAFTAR TABEL

	Halaman
Tabel 2.1. Jenis Penyakit Daun Jeruk .....	11
Tabel 2.2. Kasus Penelitian .....	12
Tabel 2.3. Penelitian terdahulu .....	13
Tabel 3.1. Perangkat Keras .....	17
Tabel 3.2. Perangkat Lunak .....	17
Tabel 3.3. Pembagian Dataset .....	19
Tabel 3.4. <i>Hyperparameter</i> .....	26
Tabel 4.1. Model Skenario Penelitian .....	31
Tabel 4.2. <i>Classification report</i> model <i>InceptionV4</i> .....	33
Tabel 4.3. <i>Classification report</i> model <i>InceptionV4 + CBAM</i> .....	37
Tabel 4.4. Hasil Uji <i>Deploy Web</i> .....	42
Tabel 4.5. Hasil evaluasi semua model .....	46
Tabel 4.6. Hasil evaluasi penelitian terdahulu dan hasil penelitian ini .....	49



## DAFTAR GAMBAR

	Halaman
Gambar 2.1. <i>Confusion Matrix</i> .....	8
Gambar 3.1. Prosedur Kerja .....	18
Gambar 3.2. Arsitektur <i>InceptionV4</i> .....	22
Gambar 3.3. Arsitektur <i>CBAM</i> .....	22
Gambar 3.4. Arsitektur <i>InceptionV4</i> dengan <i>CBAM</i> .....	24
Gambar 4.1. Visualisasi sampel data daun jeruk .....	28
Gambar 4.2. Visualisasi data sebelum dan sesudah di augmentasi.....	29
Gambar 4.3. Grafik pelatihan model <i>InceptionV4</i> .....	31
Gambar 4.4. Hasil <i>Confusion Matrix</i> model <i>InceptionV4</i> .....	32
Gambar 4.5. Grafik <i>ROC AUC</i> model <i>InceptionV4</i> .....	34
Gambar 4.6. Grafik pelatihan model <i>InceptionV4 + CBAM</i> .....	35
Gambar 4.7. Hasil <i>Confusion Matrix</i> model <i>InceptionV4 + CBAM</i> .....	36
Gambar 4.8. Grafik <i>ROC AUC</i> <i>InceptionV4 + CBAM</i> .....	37
Gambar 4.9. Tampilan <i>Home Website</i> .....	39
Gambar 4.10. Tampilan halaman menu klasifikasi .....	39
Gambar 4.11. Tampilan Halaman Utama Aplikasi .....	40
Gambar 4.12. Tampilan Hasil Klasifikasi Aplikasi .....	41
Gambar 4.13. Grafik rata – rata <i>ROC AUC</i> masing – masing model .....	48



## BAB I

### PENDAHULUAN

#### 1.1. Latar Belakang

*InceptionV4* adalah sebuah arsitektur jaringan saraf konvolusional (CNN) yang merupakan bagian dari keluarga model *Inception*, yang dikembangkan oleh Google (Wirasto & Baballe Ahmad, 2024). Menurut (Pan, dkk, 2021) *InceptionV4* adalah jaringan saraf konvolusional (CNN) yang digunakan untuk mengambil elemen visual dari gambar. *InceptionV4* terdiri dari sejumlah modul *Inception* yang dimaksudkan untuk memanfaatkan fitur multi-skala gambar (D. Wang & Yan, 2024).

Dalam perkembangannya *InceptionV4* adalah generasi ke 4 dari keluarga *Inception*. *Inception* pertama kali di perkenalkan oleh tim dari *google research* pada tahun 2015 dalam paper mereka yang berjudul *Going Deeper with Convolutions* di konferensi *CVPR 2015* (Szegedy, Liu, dkk, 2015). Kasus yang dibahas adalah bagaimana arsitektur jaringan saraf dalam, khususnya arsitektur *Inception*, dapat meningkatkan kinerja pengenalan gambar dan deteksi objek (Szegedy dkk., 2014).

Setelah keberhasilan *Inceptionv1*, fokus pengembangan berikutnya adalah meningkatkan arsitektur ini. Dalam artikel yang ditulis oleh (Szegedy, Vanhoucke, dkk., 2015) di akhir 2015, *Inceptionv2* diperkenalkan. Dipresentasikan dalam artikel yang sama dengan *Inceptionv2*, *Inceptionv3* merupakan peningkatan arsitektur *Inceptionv2*. Selanjutnya *InceptionV4* memperkenalkan inovasi dengan menggabungkan struktur *ResNet* dengan arsitektur *Inception* yang ada,

menghasilkan dua varian utama: *InceptionV4* dan *Inception-ResNet-v2* (Szegedy dkk., 2016).

Penelitian yang menerapkan metode *InceptionV4* telah banyak di guankan sebelumnya dalam berbagai kasus, seperti: Pemakaian masker (H. Zhang dkk., 2022), diagnosis otomatis batu ginjal dari gambar CT (L. Zhang dkk., 2024), Penyakit Pankreas (Gao & Wang, 2020) , deteksi kebakaran (Sun dkk., 2021), infeksi Covid-19 (Tahir dkk., 2021), faringitis, tonsilitis dan kanker mulut (Swathi & Regunathan, 2024), Identifikasi pasien yang sulit diintubasi(Tavolara dkk., 2021), tumor otak (Bibi dkk., 2024), bahasa insyarat (Kothadiya dkk., 2024), kromosom pewarnaan Giemsa(Wei dkk., 2022).

Walaupun hasil dari berbagai penelitian sudah mencapai hasil yang memuaskan akan tetapi *InceptionV4* masih perlu dimodifikasi untuk mencapai hasil yang lebih maksimal dikarenakan model ini masih memiliki beberapa kelemahan dalam menangani kompleksitas data pada tingkat yang lebih tinggi. salah satu caranya adalah dengan menambahkan modul perhatian dalam *InceptionV4*, modul perhatian juga telah banyak diteliti sebelumnya seperti, *spatial attention modul* (Fu dkk., 2021), *channel attention module* (J. Zhang, Yi, dkk., 2023), *temporal attention module* (S. Liu dkk., 2020) dan *Convolutional Block Attention Module (CBAM)*. dalam penelitian ini *CBAM* menjadi pilihan sebagai modul perhatian yang ditambahkan kedalam arsitektur *InceptionV4* dengan alasan kemampuan untuk menerapkan mekanisme perhatian *channel* dan spasial serta belajar mendistribusikan bobot fitur secara adaptif, yang meningkatkan kemampuan model untuk mengekstrak informasi yang relevan dari data masukan(B. Chen dkk., 2020).

*CBAM* juga telah banyak diteliti sebelumnya dengan menerapkan pada metode seperti *CNN* dalam bidang biometrik (Z. Zhang & Wang, 2022a), *DenseNet* dalam kasus Klasifikasi Keparahan Otomatis Penderita Diabetes Retinopati (Farag dkk., 2022), *DeepConvLSTM* dalam Pembelajaran Mendalam dengan Sensor Gerak (Agac & Durmaz Incel, 2023), *CapsNet* dalam Prediksi Deteksi Peptida (M. Yu dkk., 2021) dengan hasil akurasi yang tinggi. Berdasarkan keunggulan arsitektur *InceptionV4*, yang memiliki kemampuan ekstraksi fitur yang mendalam dan efisien melalui penggunaan modul-modul *inception* yang terstruktur, serta ketangguhan *CBAM* dalam memberikan mekanisme perhatian spasial dan kanal yang efektif untuk meningkatkan fokus model pada fitur penting, maka dalam penelitian ini akan dilakukan uji coba menyisipkan *CBAM* ke dalam *InceptionV4* untuk mendiagnosis penyakit pada daun jeruk.

## 1.2. Rumusan Masalah

Bagaimana kinerja metode *InceptionV4* dengan integrasi *CBAM* dalam mendeteksi penyakit pada daun Jeruk.

## 1.3. Batasan Masalah

Batasan masalah yang dapat diterapkan pada penelitian ini adalah sebagai berikut:

1. Data citra daun tanaman jeruk yang digunakan dalam penelitian ini berjenis data sekunder yang berasal dari situs repositori data gratis yaitu *kaggle* dan *mendeley* data.

2. Dalam penelitian ini terdapat 5 jenis citra penyakit daun yang gunakan yaitu:, *Black spot, canker, greening,, young healthy* dan *healthy*.
3. Arsitektur yang digunakan adalah *InceptionV4* yang dioptimalkan dengan *CBAM*.

#### **1.4. Tujuan Penelitian**

Adapun tujuan penelitian ini adalah:

1. Menghasilkan model diagnosis yang tepat dengan menggunakan arsitektur *InceptionV4* yang dioptimalkan dengan *CBAM*.
2. mengevaluasi bagaimana mekanisme perhatian *CBAM* mempengaruhi kinerja *InceptionV4* yang lebih baik.

#### **1.5. Manfaat Penelitian**

Adapun manfaat penelitian ini untuk:

1. Dengan menghasilkan model diagnosis berbasis arsitektur *InceptionV4* yang dioptimalkan dengan mekanisme perhatian *CBAM*, penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam meningkatkan akurasi dan ketepatan diagnosis penyakit pada daun jeruk.
2. Penelitian ini dapat memberikan pemahaman yang lebih baik mengenai bagaimana mekanisme perhatian *CBAM* mempengaruhi performa model *InceptionV4*, khususnya dalam konteks deteksi penyakit tanaman daun jeruk.

## BAB II

### TINJAUAN PUSTAKA

#### 2.1. *Deep Learning*

*Deep learning* adalah salah satu bagian dari *mechine learning* dengan menggunakan jaringan saraf yang dikenal juga sebagai *neural networks* bertujuan menyelesaikan masalah yang kompleks (Sharifani & Amini, 2023). *Neural networks* merupakan sistem komputasi yang terdiri dari banyak neuron yang saling terhubung, yang belajar dengan mengadaptasi kekuatan antar neuron berdasarkan data yang diberikan (Bengio dkk., 2021). Dalam *Deep learning*, lapisan merujuk pada struktur yang membentuk jaringan saraf, di mana setiap lapisan melakukan tugas khusus untuk memproses data dan Secara umum, ada tiga jenis lapisan utama: lapisan input, lapisan tersembunyi, dan lapisan output (Strubell dkk., 2020).

Di berbagai bidang, seperti pengolahan gambar digital atau yang juga disebut *image processing*, *deep learning* banyak digunakan. *Deep learning* dalam pengelolaan citra mencakup penggunaan algoritma canggih untuk menganalisis dan memproses gambar untuk meningkatkan efisiensi dan akurasi diagnosis dalam berbagai aplikasi (Chauhan dkk., 2023). Salah satu algoritma *deep learning* yang paling populer untuk di gunakan dalam kasus deteksi atau klasifikasi gambar yaitu CNN (Sarvamangala & Kulkarni, 2022). *CNN* telah digunakan untuk klasifikasi data gambar dan deret waktu karena kemampuan ekstraksi fitur dan pengenalan yang luar biasa (J. Zhang, Ye, dkk., 2023). Banyak metode *CNN* untuk deteksi gambar, termasuk arsitektur seperti *AlexNet*, *GoogLeNet*, *VGGNet*, *Residual Network (ResNet)*, dan *InceptionV4* (Lu dkk., 2021).

## 2.2. *InceptionV4*

*InceptionV4* adalah arsitektur *CNN* yang bertujuan untuk meningkatkan kemampuan pemrosesan gambar. Ini mengadopsi modul *inception* yang baru, yang menggabungkan berbagai ukuran filter untuk mendapatkan fitur pada berbagai skala (Mishra dkk., 2024). Tiga komponen utama yang membentuk struktur jaringan dalam arsitektur *InceptionV4* adalah *Stem*, *Inception Blocks*, dan *Reduction Blocks*. Masing-masing komponen memiliki tugas khusus untuk memproses dan mengekstrak fitur dari gambar, yang memungkinkan jaringan untuk melakukan klasifikasi yang akurat (Z. Li dkk., 2022). Sebelum dipindahkan ke *Inception blocks*, tujuan *stem* adalah untuk menghilangkan fitur dasar dari gambar input dan mengurangi ukurannya (Alqahtani dkk., 2023).

## 2.3. *Convolutional Block Attention Module (CBAM)*

*Convolutional Block Attention Module (CBAM)* menggabungkan mekanisme perhatian untuk meningkatkan kinerja jaringan saraf konvolusional (*CNN*) (Y. Zhang dkk., 2021). Di dalam *CBAM* terdapat dua komponen utama yaitu *Channel Attention Module (CAM)* dan *Spatial Attention Module (SAM)* (Z. Zhang & Wang, 2022). *Channel Attention Module (CAM)* menggunakan relevansi setiap saluran dari keluaran layer sebelumnya untuk mendapatkan informasi penting antar-saluran fitur Untuk menghasilkan bobot perhatian, *Global Average Pooling* dan *Global Max Pooling* digunakan untuk mengumpulkan data penting dari seluruh saluran (L. Li & Yao, 2023). Setelah itu, operasi sigmoid digunakan untuk menggabungkan hasil,

yang menghasilkan peta perhatian *channel* yang digunakan untuk mengubah fitur asli, memfokuskan lebih pada saluran yang relevan (*Ju & Wang, 2022*).

Dan *Spatial Attention Module (SAM)* menggunakan *Global Average Pooling* dan *Global Max Pooling* untuk mengumpulkan informasi penting tentang dimensi spasial (*Xin & Li, 2023*). Setelah kedua peta digabungkan, mereka diproses melalui konvolusi 2D dan sigmoid untuk menghasilkan peta perhatian spasial. Peta ini digunakan untuk memperkuat area spasial yang lebih relevan dengan fitur input(Y. Wang dkk., 2024). Dengan menggabungkan perhatian *Channel Attention* dan *spatial attention*, *CBAM* memungkinkan model untuk berkonsentrasi pada informasi yang benar-benar penting untuk tugas tertentu, seperti pengenalan objek atau klasifikasi gambar (*Ju & Wang, 2022*). Pada *CBAM*, fitur input pertama melewati Modul Perhatian Saluran untuk mengubah bobot saluran yang penting. Kemudian, fitur input masuk ke Modul Perhatian Spasial untuk memberikan perhatian pada lokasi penting dalam gambar. Pada akhirnya, kedua modul ini menghasilkan fitur yang ditingkatkan pada level saluran dan spasial.

#### 2.4. Evaluasi Model

Dalam algoritma *Deep Learning*, proses evaluasi model adalah proses mengevaluasi kinerja model untuk mengetahui seberapa baik model tersebut dalam membuat prediksi atau mengklasifikasikan data(Yacoub Amazon Alexa & Axman Amazon Alexa, 2020). Untuk mengetahui apakah model sudah cukup akurat dan efisien untuk digunakan dalam aplikasi nyata, evaluasi ini sangat penting (Orozco-Arias dkk., 2020). Berikut Beberapa metrik umum yang digunakan dalam evaluasi model:

### 2.4.1. *Confusion Matrix*

*Confusion Matrix* merupakan tabel yang general digunakan untuk menyajikan empat nilai utama dalam evaluasi model klasifikasi, yaitu *true positives*, *false positives*, *true negatives*, dan *false negatives* (Erickson & Kitamura, 2021). Dibawah ini adalah gambar model *Confusion Matrix*.

		<b>Actual values</b>	
		+	-
<b>Predicted values</b>	+	<b>True positive(TP)</b>	<b>False positive(FP)</b>
	-	<b>False negative(FN)</b>	<b>True negative (TN)</b>

**Gambar 2.1. *Confusion Matrix***  
(Valero-Carreras dkk, 2023)

Seperti yang ditunjukkan pada gambar 2.1 *matrix confusion* terdiri dari empat komponen utama yang digunakan untuk mengevaluasi kinerja model klasifikasi. *Positive True (TP)* adalah ketika model memprediksi positif dan hasil aktualnya juga positif, *False Positive (FP)* adalah ketika model memprediksi positif, tetapi hasil aktualnya negatif. *False Negative (FN)* adalah kasus di mana model memprediksi negatif, namun hasil aktualnya positif. *True Negative (TN)* adalah ketika model memprediksi negatif, tetapi hasil aktualnya juga negatif.

*Confusion Matrix* digunakan untuk menghitung berbagai metrik kinerja lainnya seperti *accuracy*, *positive predictive value (precision)*, *sensitivitas (recall)* dan *F1 score* (Vakili dkk., 2020). parameter tersebut dapat dirumuskan sebagai berikut:

a. Accuracy

*Accuracy* adalah metrik yang digunakan untuk mengukur kemampuan model untuk mengklasifikasikan data (Ramli dkk., 2022). Rumus *accuracy*-nya adalah:

$$ACC = \frac{TP + TN}{TP + TN + FN + FP} = \frac{TP + TN}{P + N} \quad 2.1$$

b. Precision

*Precision* adalah rasio antara total prediksi positif model dan jumlah *true positives (TP)* (Markoulidakis dkk., 2021). Rumus *precision*-nya adalah:

$$PREC = \frac{TP}{TP + FP} \quad 2.2$$

c. Recall (Sensitivity)

*Recall* adalah Kemampuan model untuk menemukan semua contoh positif yang sebenarnya dari suatu kelas (Wu, 2022). Rumus *recall*-nya adalah:

$$SN = \frac{TP}{TP + FN} = \frac{TP}{P} \quad 2.3$$

d. F1 Score

*F1 Score* adalah metrik yang digunakan untuk menilai kinerja model klasifikasi, terutama dalam analisis data yang tidak seimbang. Rumus *F1 Score*-nya adalah:

$$F1 = 2 \times \frac{T(Precision \times Recall)}{T(Precision \times Recall)} \quad 2.4$$

### 2.4.2. ROC AUC

*ROC (Receiver Operating Characteristic) curve* adalah grafik yang menunjukkan kinerja model klasifikasi pada berbagai ambang batas (*threshold*) (Carrington et al., 2023). Grafik ini memplot *True Positive Rate* (TPR) di sumbu Y dan *False Positive Rate* (FPR) di sumbu X(Verbakel et al., 2020a). TPR, yang juga dikenal sebagai sensitivitas, mengukur proporsi positif yang terdeteksi dengan benar, sedangkan FPR merupakan proporsi negatif yang salah terklasifikasi sebagai positif (Chicco & Jurman, 2023). Dengan demikian, *ROC curve* membantu dalam memahami *trade-off* antara sensitivitas dan spesifitas model (Verbakel et al., 2020b). *AUC (Area Under the Curve)* adalah ukuran yang menggambarkan seberapa baik model dapat membedakan antara dua kelas. Nilai *AUC* berkisar antara 0 hingga 1;  $AUC = 0.5$  menunjukkan bahwa model tidak lebih baik dari tebakan acak, sementara  $AUC = 1$  menunjukkan bahwa model tersebut sempurna dalam membedakan antara kelas positif dan negatif (Carrington et al., 2020). Oleh karena itu, nilai *AUC* yang lebih tinggi menunjukkan kinerja model yang lebih baik (Gajowniczek & Ząbkowski, 2021). maka rumusnya adalah:

$$AUC = \int_0^1 TPR(FPR)dFPR \quad 2.5$$

a. *TPR (True Positive Rate)*

$$TPR = \frac{TP}{TP+FN} \quad 2.6$$

b. *FPR (False Positive Rate)*

$$FPR = \frac{FP}{FP+TN} \quad 2.7$$

## 2.5. Penyakit Daun Jeruk

Salah satu jenis tanaman yang paling banyak diproduksi adalah jeruk, dan beberapa penyakit memengaruhi daun pada tanaman jeruk (Luaibi dkk., 2021). Penyakit daun jeruk adalah masalah besar yang dapat mengurangi produktivitas tanaman jeruk di seluruh negara (Khattak dkk., 2021). Mengidentifikasi jenis penyakit yang menyerang daun jeruk melalui gejala visual seperti perubahan warna, bentuk, atau tekstur sering menjadi fokus utama dalam penelitian, terutama yang berkaitan dengan pengenalan penyakit (Barman dkk., 2020). Jenis - jenis penyakit pada daun jeruk dapat dilihat pada tabel 2.1 berikut:

**Tabel 2.1.** Jenis Penyakit Daun Jeruk.

Gambar	Nama penyakit	Deskripsi
 A photograph of an orange leaf showing several dark, circular spots (black spots) on its surface, characteristic of the Black Spot disease.	<i>Black Spot</i>	Muncul bercak hitam atau coklat dengan tepi yang tajam pada daun, dan bisa menyebar ke buah.
 A photograph of an orange leaf showing multiple reddish-brown spots and some tissue damage, characteristic of Canker disease.	Canker	Terdapat bercak berair berwarna coklat kemerahan, bercak yang berkembang menjadi luka terbuka, nekrosis di sekitar bercak.

	Greening	daun kecil dan menyempit, dengan bercak-bercak hijau gelap atau kuning di permukaannya, dan perubahan warna menjadi kuning tidak merata. Selain itu, daun sering kali keriting.
	Young healthy	Terlihat dari penampilan fisik daun yang masih muda berwarna hijau segar dan memiliki permukaan yang lebih halus serta cenderung lebih tipis.
	Healthy	Daun jeruk dewasa yang sehat memiliki warna hijau yang gelap dan pekat, permukaan lebih kasar dan tidak berlubang, bentuk yang utuh dan tidak keriput, dan ukuran yang normal.

## 2.6. Kasus Penelitian

Beberapa Penelitian yang sudah pernah dilakukan sebelumnya terkait deteksi penyakit daun jeruk dapat dilihat pada table 2.2 berikut.

**Tabel 2.2. Kasus Penelitian**

No	Penulis	Metode	Akurasi
1.	(Song et al., 2020)	YoloV4	Hasil penelitian ini menunjukkan bahwa algoritma YOLOv4 memiliki akurasi sebesar 95,4 persen pada set pengujian.
2.	(Kukreja & Dhiman, 2020)	Dense CNN	Setelah menerapkan teknik <i>augmentation</i> data dan <i>preprocessing</i> , hasil

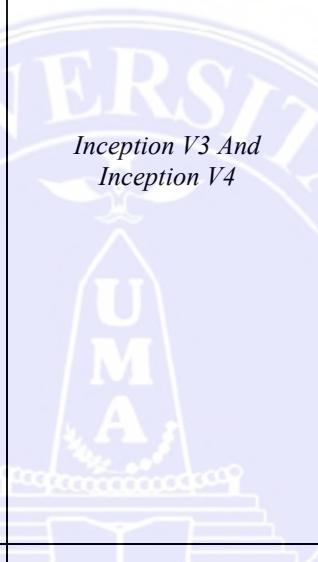
			akurasi model yang diusulkan dalam penelitian ini adalah 89,1%.
3.	(Q. Zeng dkk., 2020)	InceptionV3	Akurasi meningkat menjadi 92,60% setelah menerapkan augmentasi data berbasis <i>GAN</i> ( <i>DCGANs</i> ), yang menggandakan dataset pelatihan, sekitar 20% lebih tinggi daripada model <i>Inception_v3</i> , yang dilatih hanya dengan dataset pelatihan asli.
4.	(Elaraby dkk., 2022)	Alexnet	Dengan menggunakan model <i>AlexNet</i> dengan optimizers <i>SGDM</i> , metode yang disarankan dalam penelitian ini mencapai akurasi 94,3%.

## 2.7. Penelitian Terdahulu

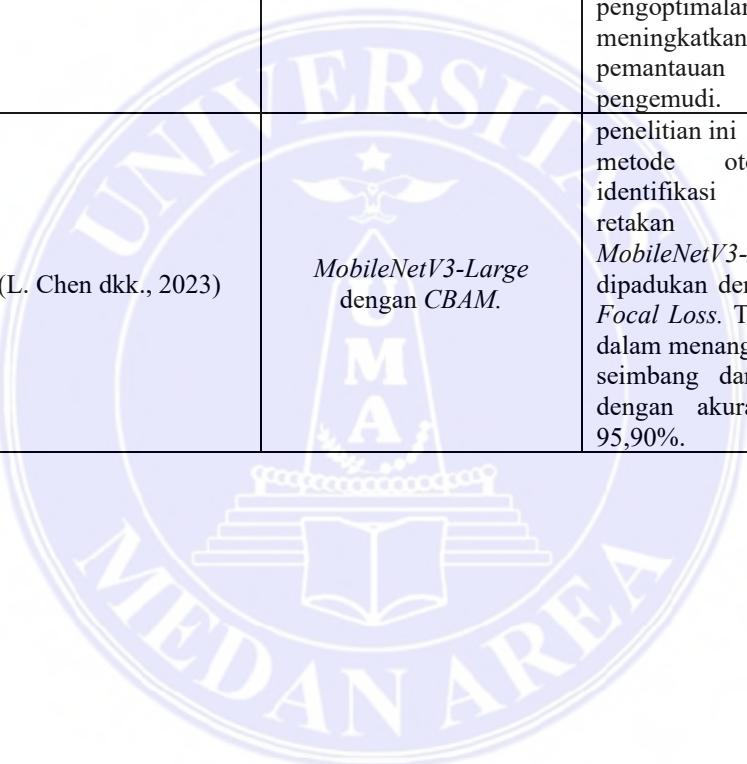
Penelitian sebelumnya menunjukkan penelitian sebelumnya oleh peneliti lain tentang masalah yang terkait dengan penelitian saat ini. Untuk menjadi referensi, penelitian sebelumnya digunakan. penelitian sebelumnya tentang diagnosis dan klasifikasi gambar menggunakan arsitektur *InceptionV4* dan *CBAM* dapat dilihat pada tabel 2.3 berikut:

**Tabel 2.3.** Penelitian terdahulu

No	Penulis	Metode	Keterangan
1.	(Nazir dkk., 2022)	<i>Inception-V4</i>	Dalam artikel ini, pendekatan hibrida baru untuk klasifikasi kanker payudara berdasarkan gambar mamografi yang menggabungkan <i>CNN</i> dan <i>Inception-V4</i> . Penelitian ini menganalisis 450 gambar tumor jinak dan 450 gambar tumor ganas dengan menggunakan dataset <i>CBIS-DDSM</i> . Model ini mencapai akurasi 99,2%, sensitivitas 99,8%, dan spesifitas 96,3%

			setelah <i>preprocessing</i> untuk meningkatkan kualitas gambar. Hasilnya menunjukkan bahwa ada potensi besar untuk meningkatkan deteksi kanker payudara pada tahap awal, yang penting untuk pengobatan yang efektif.
2.	(Nandini & Puviarasi, 2021)		Penelitian yang dilakukan tentang algoritma <i>Convolutional Neural Network (CNN)</i> yang digunakan untuk mendeteksi kanker kulit, terutama <i>Inception V3</i> dan <i>Inception V4</i> . Tujuan dari penelitian ini adalah untuk meningkatkan akurasi deteksi otomatis gambar sel dermal dengan menggunakan dataset yang terdiri dari 1200 gambar. Hasilnya menunjukkan bahwa <i>Inception V4</i> lebih baik dari <i>Inception V3</i> dalam akurasi diagnosis. Selain itu, penelitian ini menggunakan analisis statistik untuk mengevaluasi hasil algoritma <i>neural network clustering (CNN)</i> yang digunakan. Penulis berharap temuan ini dapat membantu dalam pengembangan teknik medis untuk mendeteksi kanker kulit yang lebih baik.
3.	(Anwar dkk., 2022)		Dalam artikel ini, kami menggunakan model <i>CNN</i> berbasis <i>Inception V4</i> untuk mendeteksi penyakit pada tanaman kapas, khususnya bakteri <i>blight</i> dan virus <i>leaf curl</i> kapas (CLCV). Studi ini menunjukkan bahwa pencegahan penyakit sangat penting untuk hasil panen kapas yang baik. Sistem sebelumnya tidak memiliki akurasi 98,26%, tetapi model baru mencapainya. Penelitian ini dapat membantu petani mengidentifikasi penyakit secara otomatis, mengurangi biaya dan waktu pemantauan, dan meningkatkan keberlanjutan pertanian dengan menggunakan teknik pembelajaran mendalam.

4.	(Raza dkk., 2021)	<i>Digital Fundus Imaging (DFI) and Inception-V4</i>	Penggunaan <i>model Deep Learning Inception-V4</i> untuk klasifikasi penyakit mata dan deteksi katarak melalui <i>Digital Fundus Imaging (DFI)</i> dibahas dalam artikel ini. Penelitian ini melibatkan pelatihan model dengan berbagai tingkat pembelajaran dan dataset yang diperbesar. Dataset yang diperbesar menunjukkan akurasi hingga 96,66%. <i>Inception-V4</i> meningkatkan kemampuan diagnosis otomatis penyakit mata dengan mengekstraksi fitur dari gambar fundus melalui arsitektur yang dalam dan kompleks.
5.	(B. Liu dkk., 2023)	<i>CBAM Faster R-CNN</i>	Penelitian ini bertujuan untuk meningkatkan akurasi deteksi melalui citra <i>barium meal</i> karena insiden kanker esofagus meningkat di China, dan penelitian ini membahas pengembangan sistem deteksi kanker esofagus menggunakan model <i>CBAM Faster R-CNN</i> . Penulis menunjukkan peningkatan kinerja dalam metrik <i>Recall</i> , <i>Precision</i> , dan <i>Average Precision (AP)</i> berkat integrasi modul perhatian saluran ( <i>CBAM</i> ) ke dalam <i>Faster R-CNN</i> . Penelitian ini menekankan bahwa teknologi pembelajaran mesin sangat penting untuk diagnosis medis karena dapat mengurangi beban kerja dokter.
6.	(W. Wang dkk., 2022)	<i>MTCNet dengan CBAM.</i>	Dalam artikel ini, model <i>MTCNet</i> untuk deteksi perubahan citra penginderaan jauh yang menggabungkan <i>transformer</i> multiskala dan modul perhatian blok konvolusional ( <i>CBAM</i> ) diperkenalkan. Hasil eksperimen menunjukkan bahwa <i>MTCNet</i> dapat mendeteksi perubahan pada dataset <i>LEVIR-CD</i> dan <i>WHU-CD</i> dengan efektif, menjadikannya metode yang inovatif di bidang ini.
7.	(Praharsha & Poulose, 2024)	<i>CBAM VGG16</i>	Dalam penelitian ini, membahas pengembangan

			<p>model <i>CBAM VGG16</i>, yang dirancang untuk klasifikasi gangguan pengemudi dalam upaya meningkatkan keselamatan jalan, yang mengintegrasikan modul perhatian untuk meningkatkan akurasi identifikasi gangguan yang mengalihkan perhatian pengemudi. Hasil penelitian menunjukkan bahwa kinerjanya lebih baik daripada model <i>VGG16</i> standar. Selain itu, penelitian ini menekankan betapa pentingnya data yang beragam dan metode pengoptimalan untuk meningkatkan kinerja sistem pemantauan gangguan pengemudi.</p>
8.	(L. Chen dkk., 2023)	 <i>MobileNetV3-Large</i> dengan <i>CBAM</i> .	<p>penelitian ini membahas metode otomatis untuk identifikasi dan klasifikasi retakan menggunakan <i>MobileNetV3-Large</i> yang dipadukan dengan <i>CBAM</i> dan <i>Focal Loss</i>. Teknik ini efektif dalam menangani dataset tidak seimbang dan sampel sulit, dengan akurasi keseluruhan 95,90%.</p>

## **BAB III**

### **METODOLOGI PENELITIAN**

#### **3.1. Alat dan Bahan**

Agar penelitian ini berhasil, diperlukan bahan dan peralatan pendukung.

Perangkat keras dan perangkat lunak yang digunakan termasuk:

##### **3.1.1. Perangkat Keras**

Adapun perangkat keras yang digunakan dalam proses penelitian ini dapat dilihat pada tabel 3.1 berikut.

**Tabel 3.1. Perangkat Keras**

No	Perangkat Keras	Deskripsi
1	<i>Device</i>	<i>Macbook Air</i>
2	<i>Processor</i>	M1
3	<i>SSD</i>	256 GB
4	<i>RAM</i>	8 GB

##### **3.1.2. Perangkat Lunak**

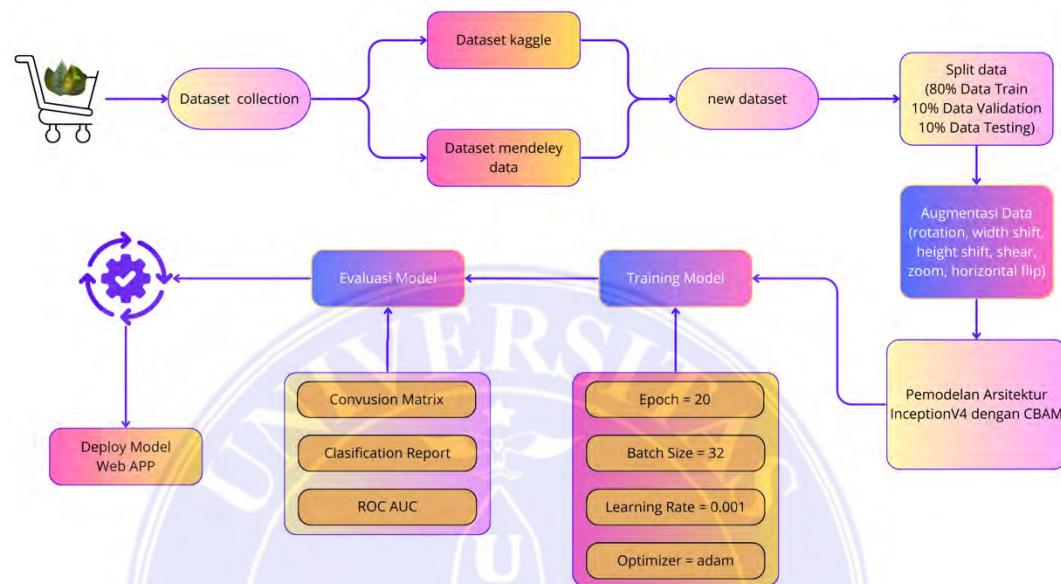
Adapun perangkat keras yang digunakan dalam proses penelitian ini dapat dilihat pada tabel 3.1 berikut.

**Tabel 3.2. Perangkat Lunak**

No	Perangkat Lunak	Deskripsi
1	<i>MacOS Sonoma 14.5</i>	Sistem Operasi
2	<i>Anaconda</i>	<i>Command Line</i>
3	<i>Jupyter Notebook</i>	<i>Text editor</i>
4	<i>Python 3.11.6</i>	Bahasa Pemrograman

### 3.2. Prosedur Kerja

Adapun prosedur kerja yang akan dilakukan pada penelitian ini dapat di lihat pada gambar 3.1 berikut.



**Gambar 3.1.** Prosedur Kerja

Berdasarkan Gambar 3.1. di atas, ada beberapa tahap prosedur kerja yang akan dilakukan yang akan di jelaskan secara rinci sebagai berikut:

#### 3.2.1. Dataset

Terdapat dua Dataset yang berjenis sekunder yang digunakan dalam penelitian ini, dalam bentuk gambar diperoleh melalui website *Kaggle* dan website *mendeley data*. *Kaggle* dan *mendeley data* menawarkan platform online untuk mengelola, menyimpan, dan membagikan data penelitian. Kemudian kedua dataset tersebut disatukan menjadi satu folder dataset baru yang akan digunakan untuk penelitian ini. Data set penelitian ini terbagi atas 5 jenis kategori daun yaitu dengan kategori *Black spot*, daun dengan kategori *canker*, daun dengan kategori *greening*, daun

dengan kategori *young healthy*, dan terakhir daun dengan kategori *healthy* dan masing – masing citra menggunakan format warna *RGB*. Data semua citra berukuran 256 x 256 piksel dengan format gambar jpg.

### 3.2.2. Pembagian Data

Dataset yang sudah dibersihkan dan diubah selanjutnya akan dibagi. Data dibagi menjadi tiga kategori: data latihan (data instruksi), data validasi (data validasi), dan data uji. Data latihan digunakan untuk melatih model, dan data validasi untuk mengoptimasi proses instruksi model. sementara data uji untuk mengevaluasi kinerja model yang dibuat. 80% dari dataset merupakan data latih, 10% merupakan data validasi, dan 10% terakhir merupakan data uji. Berikut tabel pembagian data berdasarkan masing kelas.

**Tabel 3.3.** Pembagian Dataset

Kelas	Data Training	Data Validation	Data Testing	Jumlah
<i>Black Spot</i>	800	100	100	1000
<i>Canker</i>	800	100	100	1000
<i>Greening</i>	800	100	100	1000
<i>Young healthy</i>	800	100	100	1000
<i>healthy</i>	800	100	100	1000
<b>Total</b>	<b>4000</b>	<b>500</b>	<b>500</b>	<b>5000</b>
<b>Presentase</b>	<b>80%</b>	<b>10%</b>	<b>10%</b>	<b>100%</b>

### 3.2.3. Augmentasi Data

Augmentasi data adalah teknik yang digunakan untuk meningkatkan jumlah dan keragaman data pelatihan dengan menerapkan berbagai transformasi pada gambar. Beberapa metode augmentasi yang umum digunakan meliputi rotation, yang memutar gambar pada sudut tertentu untuk memberikan variasi sudut pandang; width shift dan height shift, yang menggeser gambar secara horizontal

dan vertikal untuk mensimulasikan pergeseran objek dalam gambar; shear, yang mengubah bentuk gambar dengan memiringkan sudut; zoom, yang memperbesar atau memperkecil gambar untuk menambah variasi skala; dan horizontal flip, yang membalik gambar secara horizontal untuk menciptakan variasi dalam orientasi objek. Dengan menerapkan teknik-teknik ini, model dapat belajar dari data yang lebih beragam, sehingga meningkatkan generalisasi dan kinerja dalam pengenalan pola.

### **3.2.4. Membangun Model.**

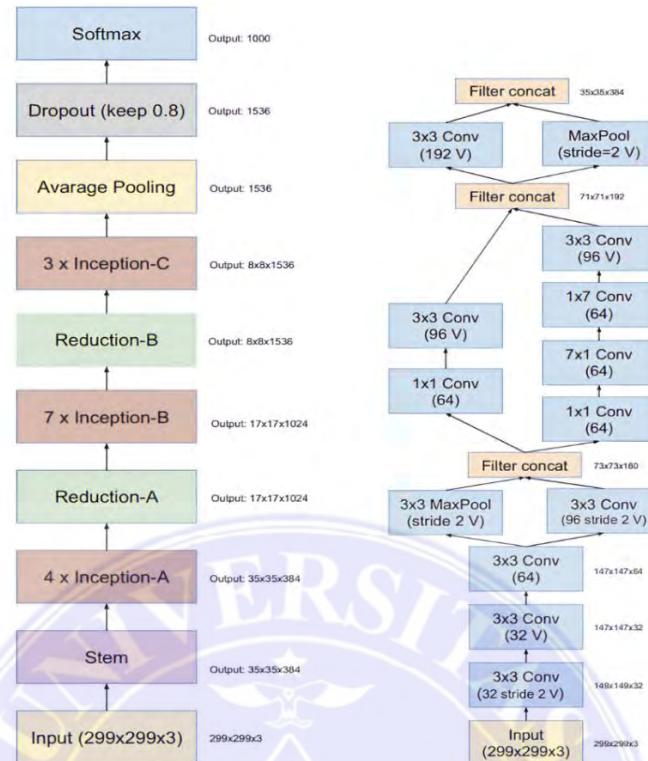
Pengembangan model *CNN* dengan arsitektur *InceptionV4* yang dipadukan dengan *CBAM* sedang dilakukan. Untuk mengidentifikasi penyakit pada daun jeruk, model pre-trained yang menggunakan teknik *transfer learning* digunakan.

#### **3.2.4.1. Arsitektur *InceptionV4***

Didalam arsitektur *InceptionV4* terdapat beberapa tahap, dimulai dari tahap *stem*, gambar dimasukkan ke dalam beberapa lapisan konvolusi dan penggabungan, seperti *max-pooling* atau *average-pooling*. Ini membantu mengurangi resolusi gambar secara cepat dan membuat lapisan-lapisan berikutnya lebih mudah mengelola data (Karthick Raghunath dkk., 2022). Pada bagian *Stem* dari *InceptionV4*, urutan pemrosesan dimulai dengan konvolusi 1x1 yang bertujuan untuk mengurangi dimensi data; diikuti oleh konvolusi 3x3 untuk mengumpulkan detail yang lebih rinci; dan akhirnya, lapisan pemotongan, seperti *max-pooling*, digunakan untuk mengurangi ukuran input secara efektif (Alom dkk., 2021).

Bagian inti dari arsitektur *InceptionV4* adalah *Inception blocks*, yang berfungsi untuk mengekstrak fitur pada berbagai skala dengan menggunakan berbagai filter convolusi yang bekerja secara paralel. Setiap blok *Inception* memiliki filter convolusi dengan ukuran kernel yang berbeda, misalnya 1x1, 3x3, atau 5x5 (Al Husaini dkk., 2022). Tiga jenis blok *Inception*, *Inception-A*, *Inception-B*, dan *Inception-C* dibuat untuk secara bertahap mengurangi ukuran input gambar sambil mengekstrak fitur yang semakin kompleks seiring perkembangan jaringan (Nazir dkk., 2022). Kemudian Untuk secara bertahap mengurangi ukuran resolusi gambar, *Reduction Blocks* digunakan untuk mengurangi ukuran spasial fitur yang diekstrak sambil mempertahankan kedalaman fitur yang telah dipelajari (ANAND dkk., 2021).

Dua jenis *Reduction Blocks* tersedia dalam *InceptionV4* yaitu *Reduction-A* mengurangi ukuran gambar dengan menggunakan konvolusi 3x3 dan *pooling*; *Reduction-B* mengurangi ukuran gambar lebih jauh dengan menggabungkan beberapa ukuran filter konvolusi dan *pooling* (Tekchandani dkk., 2020). Selain itu, *InceptionV4* menggunakan ide koneksi residual, yang pertama kali muncul dalam arsitektur *ResNet*, Koneksi residual memungkinkan gradien dari lapisan-lapisan sebelumnya untuk mengalir langsung ke lapisan akhir, yang menghasilkan pelatihan jaringan yang lebih stabil dan efektif (Meirelles dkk., 2022). Lapisan terakhir *InceptionV4* terdiri dari lapisan *pooling* global yang bertujuan untuk menggabungkan informasi dari seluruh gambar menjadi satu vektor fitur kemudian dikirim ke lapisan *fully connected (FC)* dan akhirnya ke *softmax* untuk menghasilkan probabilitas dari setiap kelas pada gambar input (N. Zeng dkk., 2023). Arsitektur *InceptionV4* dapat dilihat pada gambar 3. 2 sebagai berikut.

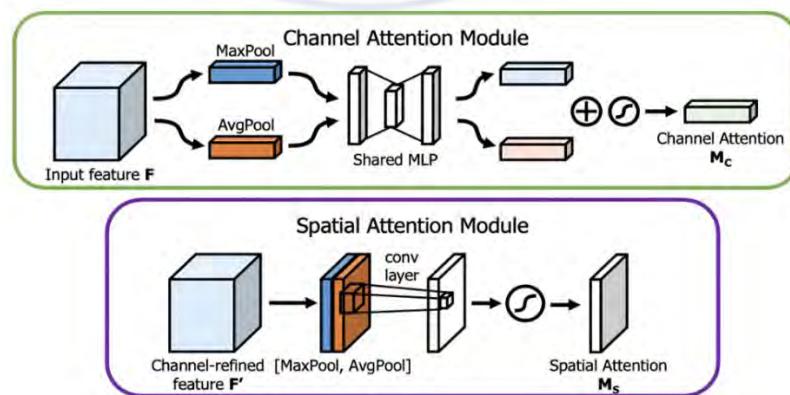


**Gambar 3.2.** Arsitektur *InceptionV4*.

(Szegedy dkk., 2016)

### 3.2.4.2. Arsitektur CBAM

Rangkaian arsitektur *CBAM* dapat dilihat pada gambar 3.3 sebagai berikut:



**Gambar 3.3.** Arsitektur *CBAM*

(Woo dkk., 2018)

Sesuai pada gambar arsitektur *CBAM* diatas, *CBAM* terdiri dari dua bagian utama: *Channel Attention Module* dan *Spatial Attention Module*. Berikut penjelasan prosesnya:

### 1. *Channel Attention Module*

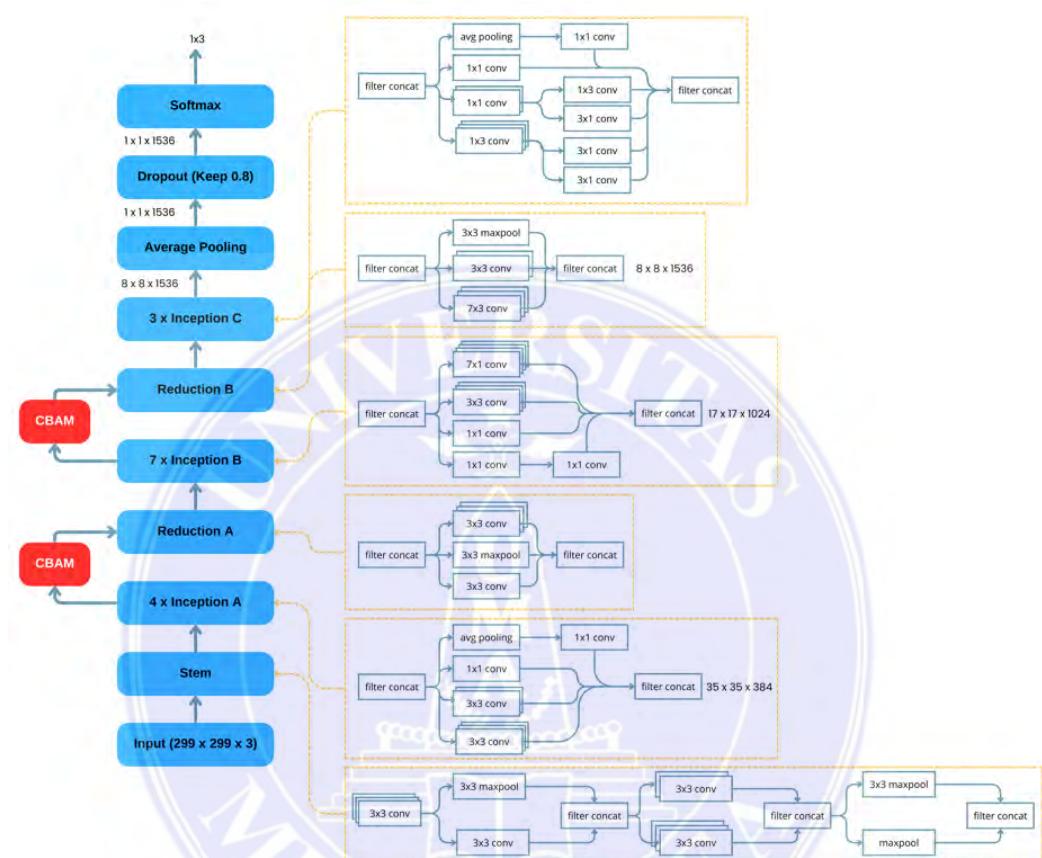
Modul ini bertujuan untuk menghasilkan perhatian (attenzi) berdasarkan saluran (*channel*) fitur input Untuk memproses fitur input  $F$ , *Max Pooling* dan *Average Pooling* digunakan. Ini menghasilkan dua representasi berbeda dari fitur tersebut. Setelah itu, kedua hasil *pooling* dilewatkan ke *Multilayer Perceptron (MLP)* yang digunakan bersama (*shared MLP*), biasanya dengan satu lapisan tersembunyi dan aktivasi *nonlinear* seperti *ReLU*. Kemudian, kedua jalur *pooling* digabungkan dengan penjumlahan elemen-wise. Output perhatian kanal  $M_C$  dihasilkan dari penggabungan ini melalui fungsi aktivasi sigmoid. Output ini kemudian diterapkan kembali ke fitur input  $F$  untuk menghasilkan fitur yang diperhatikan berdasarkan kanal.

### 2. *Spatial Attention Module*

Modul ini bertujuan untuk menghasilkan perhatian berdasarkan ruang (*spatial*) dari fitur. Untuk memperbaiki fitur kanalnya  $F'$ , *Max Pooling* dan *Average Pooling* digunakan di sepanjang dimensi kanal. Ini menghasilkan dua peta fitur dua dimensi. Kedua peta hasil *pooling* ini kemudian digabungkan (*concatenate*) di sepanjang dimensi kanal. Untuk mengumpulkan atensi spasial, hasil penggabungan ini ditransmisikan ke lapisan konvolusi dengan kernel berukuran 7 kali 7. Output lapisan konvolusi ini kemudian diproses melalui fungsi aktivasi sigmoid untuk menghasilkan peta atensi spasial  $M_S$ . Peta ini kemudian diterapkan ke fitur input  $F'$  untuk menghasilkan fitur dengan perhatian spasial.

### 3.2.4.3. Arsitektur *InceptionV4* dengan *CBAM*

Berikut adalah gambar arsitektur *InceptionV4* setelah di integrasikan dengan *CBAM*.



**Gambar 3.4.** Arsitektur *InceptionV4* dengan *CBAM*

Proses dimulai dengan *Stem Module*, yang merupakan tahap awal dari arsitektur ini. Modul ini bertugas mengekstraksi fitur dasar dari citra input menggunakan beberapa lapisan konvolusi dengan ukuran kernel 3 X 3 dan operasi *MaxPooling* untuk memperkecil dimensi spasial. Dari sini, jaringan mulai memperoleh representasi awal fitur yang nantinya akan diproses lebih lanjut oleh modul-modul *Inception*. Dalam arsitektur *Inception-v4*, terdapat beberapa modul *Inception*, yaitu *Inception-A*, *Inception-B*, dan *Inception-C*. Pada masing-masing modul ini, fitur diproses melalui beberapa jalur paralel yang masing-masing

menggunakan filter dengan ukuran kernel yang berbeda, seperti  $1 \times 1$ ,  $3 \times 3$ , dan  $5 \times 5$ . Setiap filter ini berfungsi untuk menangkap informasi dari berbagai skala dan bagian yang berbeda dari citra. Selain filter konvolusi, operasi *pooling*, seperti *MaxPooling* dan *Average Pooling*, juga digunakan untuk menambah variasi fitur yang dihasilkan. Hasil dari setiap jalur ini kemudian digabungkan (*concatenation*), menciptakan fitur yang lebih kaya dengan informasi dari berbagai skala.

Pada saat yang sama, modul *Reduction-A* dan *Reduction-B* digunakan untuk melakukan *downsampling* atau pengurangan dimensi spasial dari fitur yang dihasilkan oleh modul *Inception*. Tujuan dari pengurangan dimensi ini adalah untuk mengurangi kompleksitas komputasi jaringan tanpa menghilangkan informasi penting. Pada saat ini, jaringan masih memiliki fitur yang relevan melalui operasi konvolusi dan *pooling*, tetapi ukuran fitur diperkecil. Untuk memperkuat proses ini, *CBAM* dimasukkan setelah beberapa modul *Inception*, seperti *Inception-A* dan *Inception-B*. *CBAM* terdiri dari dua komponen utama: *Channel Attention Module* dan *Spatial Attention Module*. Pertama, *Channel Attention Module* berfungsi untuk memberikan perhatian pada kanal (*channel*) yang paling relevan. Fitur yang dihasilkan oleh modul *Inception* diproses melalui *pooling*, baik *MaxPooling* maupun *Average Pooling*, untuk menghasilkan representasi saluran yang diperkaya. Kedua hasil *pooling* ini digabungkan dan diproses oleh *Multilayer Perceptron* (MLP) yang menghasilkan peta perhatian kanal. Peta ini kemudian diterapkan kembali ke fitur input, yang memungkinkan jaringan untuk fokus pada saluran yang memiliki informasi paling penting. Setelah menerapkan perhatian kanal, *CBAM* kemudian menggunakan *Spatial Attention Module* untuk memperhatikan area spasial yang penting. Fitur yang telah diperbaiki oleh *Channel*

*Attention CBAM* diproses lebih lanjut melalui *pooling* di sepanjang dimensi spasial. Peta perhatian spasial dibuat dengan menggabungkan dan melewatkannya *pooling* ini melalui lapisan konvolusi. Peta ini digunakan untuk menonjolkan area tertentu dalam gambar yang mengandung informasi spasial yang lebih penting. Pada bagian akhir arsitektur, setelah modul *Inception* dan *CBAM* menyelesaikan ekstraksi fitur, operasi *Average Pooling* digunakan untuk meringkas fitur. Untuk memulai proses klasifikasi, fitur yang sudah diringkas ini kemudian dimasukkan ke lapisan *Softmax*. Kemudian *Lapisan Softmax* bertanggung jawab untuk menghasilkan *output* probabilitas kelas yang akan digunakan untuk menentukan klasifikasi akhir gambar.

### 3.2.5. Training Model

Setelah arsitektur model selesai dibangun, data yang sudah diaugmentasi digunakan untuk melatih model. Pada tahap ini, model belajar mengenali pola dan fitur yang ada pada citra untuk melakukan klasifikasi. Di dalam *training* model terdapat *hyperparameter* yang digunakan, dapat dilihat pada tabel 3.3 dibawah ini.

**Tabel 3.4. Hyperparameter**

No	Parameter	Value
1	<i>Epoch</i>	20
2	<i>Batch Size</i>	32
3	<i>Optimizer</i>	Adam
4	<i>Learning Rate</i>	0,001

Saat melatih model pembelajaran mesin, *epoch* mengacu pada satu siklus penuh melalui seluruh dataset dan *Batch size* merupakan jumlah sampel yang digunakan dalam satu iterasi pembaruan parameter selama pelatihan model. *Optimizer* adalah algoritma pembelajaran mesin dan pembelajaran mendalam yang mengubah bobot model untuk memaksimalkan atau meminimalkan fungsi yang

dimaksudkan, seperti fungsi kerugian. Dalam pembelajaran mesin, *learning rate* adalah parameter yang menentukan seberapa besar perubahan atau pembaruan bobot model pada setiap iterasi selama proses pelatihan.

### 3.2.6. Evaluasi Model

Setelah pelatihan selesai, model diuji menggunakan data testing untuk mengevaluasi kinerjanya. Evaluasi model dilakukan menggunakan beberapa metrik:

1. *Confusion Matrix*: Matriks yang menggambarkan performa model dalam hal prediksi benar dan salah untuk setiap kelas. (lihat bab 2 poin 2.4.1)
2. *Classification Report*: Laporan ini mencakup metrik evaluasi seperti *precision*, *recall*, *F1-score*, dan *accuracy*. (lihat bab 2 poin 2.4)
3. *ROC AUC*: metrik evaluasi model klasifikasi yang mengukur kemampuan model dalam membedakan kelas melalui luas di bawah kurva *ROC*, dengan nilai mendekati 1 menunjukkan performa yang lebih baik.

### 3.2.7. Deploy Model (Web App)

Setelah model dilatih dan dievaluasi, model yang sudah siap di-deploy ke dalam bentuk aplikasi *web*. Aplikasi ini memungkinkan pengguna untuk mengupload citra daun jeruk, lalu model akan melakukan klasifikasi apakah daun tersebut terinfeksi penyakit atau tidak.

## **BAB V**

### **KESIMPULAN DAN SARAN**

#### **5.1. Kesimpulan**

Penelitian ini bertujuan untuk mengevaluasi kinerja model *InceptionV4* yang dipadukan dengan *CBAM* dalam mendeteksi berbagai penyakit pada daun jeruk, seperti *Blackspot*, *Canker*, *Greening*, *Healthy* dan *Young Healthy*. Hasil yang diperoleh menunjukkan bahwa model ini mencapai akurasi 95,60%, presisi 95,91%, *recall* 95,60%, dan *F1-Score* 95,57%. Angka-angka ini menunjukkan peningkatan signifikan dibandingkan dengan penelitian terdahulu, yang mengindikasikan bahwa kombinasi *InceptionV4* dan *CBAM* efektif dalam meningkatkan kinerja deteksi penyakit tanaman. Manfaat dari penelitian ini meliputi penyediaan metode yang lebih akurat untuk identifikasi dini penyakit pada daun jeruk, yang penting untuk pengelolaan pertanian yang lebih baik dan peningkatan hasil panen.

#### **5.2. Saran**

Penelitian ini bermanfaat dalam manajemen kesehatan tanaman dan memiliki akurasi yang tinggi dalam mengidentifikasi penyakit daun jeruk, yang dapat mendukung pengambilan keputusan petani. Namun, keterbatasannya terletak pada jumlah kelas penyakit yang diuji, sehingga perlu untuk memperluas kelas penyakit dan kumpulan data guna meningkatkan akurasi dan kemampuan adaptasi model. Lebih jauh, disarankan agar model ini dapat disematkan dalam sistem tertanam untuk kontrol otomatis seperti implementasi pada teknologi drone, yang memungkinkan pemantauan dan respons penyakit secara *real-time*.

## DAFTAR PUSTAKA

- Agac, S., & Durmaz Incel, O. (2023). On the Use of a Convolutional Block Attention Module in Deep Learning-Based Human Activity Recognition with Motion Sensors. *Diagnostics*, 13(11). <https://doi.org/10.3390/diagnostics13111861>
- Al Husaini, M. A. S., Habaebi, M. H., Gunawan, T. S., Islam, M. R., Elsheikh, E. A. A., & Suliman, F. M. (2022). Thermal-based early breast cancer detection using inception V3, inception V4 and modified inception MV4. *Neural Computing and Applications*, 34(1), 333–348. <https://doi.org/10.1007/s00521-021-06372-1>
- Alom, M. Z., Hasan, M., Yakopcic, C., Taha, T. M., & Asari, V. K. (2021). Inception recurrent convolutional neural network for object recognition. *Machine Vision and Applications*, 32(1). <https://doi.org/10.1007/s00138-020-01157-3>
- Alqahtani, A., Akram, S., Ramzan, M., Nawaz, F., Khan, H. U., Alhashlan, E., Alqhtani, S. M., Waris, A., & Ali, Z. (2023). A Transfer Learning Based Approach for COVID-19 Detection Using Inception-v4 Model. *Intelligent Automation and Soft Computing*, 35(2), 1721–1736. <https://doi.org/10.32604/iasc.2023.025597>
- ANAND, R., SOWMYA, V., VIJAYKRISHNAMENON, GOPALAKRISHNAN, E. A., & SOMAN, K. P. (2021). Modified Vgg Deep Learning Architecture For Covid-19 Classification Using Bio-Medical Images. *IOP Conference Series: Materials Science and Engineering*, 1084(1), 012001. <https://doi.org/10.1088/1757-899x/1084/1/012001>

Anwar, S., Kolachi, A. R., Baloch, S. K., & Soomro, S. R. (2022). Bacterial Blight and Cotton Leaf Curl Virus Detection Using Inception V4 Based CNN Model for Cotton Crops. *5th IEEE International Image Processing, Applications and Systems Conference*, *IPAS 2022*.  
<https://doi.org/10.1109/IPAS55744.2022.10052835>

Barman, U., Choudhury, R. D., Sahu, D., & Barman, G. G. (2020). Comparison of convolution neural networks for smartphone image based real time classification of citrus leaf disease. *Computers and Electronics in Agriculture*, 177. <https://doi.org/10.1016/j.compag.2020.105661>

Bengio, Y., Lecun, Y., & Hinton, G. (2021). Deep learning for AI. *Communications of the ACM*, 64(7), 58–65. <https://doi.org/10.1145/3448250>

Bibi, N., Wahid, F., Ma, Y., Ali, S., Abbasi, I. A., Alkhayyat, A., & Khyber. (2024). A Transfer Learning-Based Approach for Brain Tumor Classification. *IEEE Access*, 12, 111218–111238. <https://doi.org/10.1109/ACCESS.2024.3425469>

Bischl, B., Binder, M., Lang, M., Pielok, T., Richter, J., Coors, S., Thomas, J., Ullmann, T., Becker, M., Boulesteix, A. L., Deng, D., & Lindauer, M. (2023). Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges. In *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* (Vol. 13, Issue 2). John Wiley and Sons Inc.  
<https://doi.org/10.1002/widm.1484>

Carrington, A. M., Fieguth, P. W., Qazi, H., Holzinger, A., Chen, H. H., Mayr, F., & Manuel, D. G. (2020). A new concordant partial AUC and partial c statistic for imbalanced data in the evaluation of machine learning algorithms. *BMC*

*Medical Informatics and Decision Making*, 20(1).

<https://doi.org/10.1186/s12911-019-1014-6>

Carrington, A. M., Manuel, D. G., Fieguth, P. W., Ramsay, T., Osmani, V., Wernly, B., Bennett, C., Hawken, S., Magwood, O., Sheikh, Y., McInnes, M., & Holzinger, A. (2023). Deep ROC Analysis and AUC as Balanced Average Accuracy, for Improved Classifier Selection, Audit and Explanation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(1), 329–341.

<https://doi.org/10.1109/TPAMI.2022.3145392>

Chauhan, R. B., Shah, T. V., Shah, D. H., Gohil, T. J., Oza, A. D., Jajal, B., & Saxena, K. K. (2023). An overview of image processing for dental diagnosis.

*Innovation and Emerging Technologies*, 10.

<https://doi.org/10.1142/s2737599423300015>

Chen, B., Zhang, Z., Liu, N., Tan, Y., Liu, X., & Chen, T. (2020). Spatiotemporal convolutional neural network with convolutional block attention module for micro-expression recognition. *Information (Switzerland)*, 11(8).

<https://doi.org/10.3390/INFO11080380>

Chen, L., Yao, H., Fu, J., & Tai Ng, C. (2023). The classification and localization of crack using lightweight convolutional neural network with CBAM. *Engineering Structures*, 275. <https://doi.org/10.1016/j.engstruct.2022.115291>

Chicco, D., & Jurman, G. (2023). The Matthews correlation coefficient (MCC) should replace the ROC AUC as the standard metric for assessing binary classification. *BioData Mining*, 16(1). <https://doi.org/10.1186/s13040-023-00322-4>

- Elaraby, A., Hamdy, W., & Alanazi, S. (2022). Classification of Citrus Diseases Using Optimization Deep Learning Approach. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/9153207>
- Elgeldawi, E., Sayed, A., Galal, A. R., & Zaki, A. M. (2021). Hyperparameter tuning for machine learning algorithms used for arabic sentiment analysis. *Informatics*, 8(4). <https://doi.org/10.3390/informatics8040079>
- Erickson, B. J., & Kitamura, F. (2021). Magician's corner: 9. performance metrics for machine learning models. In *Radiology: Artificial Intelligence* (Vol. 3, Issue 3). Radiological Society of North America Inc. <https://doi.org/10.1148/ryai.2021200126>
- Farag, M. M., Fouad, M., & Abdel-Hamid, A. T. (2022). Automatic Severity Classification of Diabetic Retinopathy Based on DenseNet and Convolutional Block Attention Module. *IEEE Access*, 10, 38299–38308. <https://doi.org/10.1109/ACCESS.2022.3165193>
- Fu, X., Bi, L., Kumar, A., Fulham, M., & Kim, J. (2021). Multimodal Spatial Attention Module for Targeting Multimodal PET-CT Lung Tumor Segmentation. *IEEE Journal of Biomedical and Health Informatics*, 25(9), 3507–3516. <https://doi.org/10.1109/JBHI.2021.3059453>
- Gajowniczek, K., & Ząbkowski, T. (2021). ImbTreeAUC: An R package for building classification trees using the area under the ROC curve (AUC) on imbalanced datasets. *SoftwareX*, 15. <https://doi.org/10.1016/j.softx.2021.100755>
- Gao, X., & Wang, X. (2020). Performance of deep learning for differentiating pancreatic diseases on contrast-enhanced magnetic resonance imaging: A

- preliminary study. *Diagnostic and Interventional Imaging*, 101(2), 91–100.  
<https://doi.org/10.1016/j.diii.2019.07.002>
- Ju, A., & Wang, Z. (2022). Convolutional block attention module based on visual mechanism for robot image edge detection. *EAI Endorsed Transactions on Scalable Information Systems*, 9(36). <https://doi.org/10.4108/eai.19-11-2021.172214>
- Karthick Raghunath, K. M., Vinoth Kumar, V., Venkatesan, M., Singh, K. K., Mahesh, T. R., & Singh, A. (2022). XGBoost Regression Classifier (XRC) Model for Cyber Attack Detection and Classification Using Inception V4. *Journal of Web Engineering*, 21(4), 1295–1322.  
<https://doi.org/10.13052/jwe1540-9589.21413>
- Khattak, A., Asghar, M. U., Batool, U., Asghar, M. Z., Ullah, H., Al-Rakhami, M., & Gumaei, A. (2021). Automatic Detection of Citrus Fruit and Leaves Diseases Using Deep Neural Network Model. *IEEE Access*, 9, 112942–112954. <https://doi.org/10.1109/ACCESS.2021.3096895>
- Kothadiya, D. R., Bhatt, C. M., Kharwa, H., & Albu, F. (2024). Hybrid InceptionNet Based Enhanced Architecture for Isolated Sign Language Recognition. *IEEE Access*, 12, 90889–90899.  
<https://doi.org/10.1109/ACCESS.2024.3420776>
- Kukreja, V., & Dhiman, P. (2020). *2020 International Conference on Smart Electronics and Communication (ICOSEC) : 10-12, September 2020*. IEEE.
- Li, L., & Yao, D. (2023). Emotion Recognition in Complex Classroom Scenes Based on Improved Convolutional Block Attention Module Algorithm. *IEEE Access*, 11, 143050–143059. <https://doi.org/10.1109/ACCESS.2023.3340510>

- Li, Z., Li, C., Deng, L., Fan, Y., Xiao, X., Ma, H., Qin, J., & Zhu, L. (2022). Improved AlexNet with Inception-V4 for Plant Disease Diagnosis. *Computational Intelligence and Neuroscience*, 2022.
- <https://doi.org/10.1155/2022/5862600>
- Liu, B., Zhao, X., Hu, H., Lin, Q., & Huang, J. (2023). Detection of Esophageal Cancer Lesions Based on CBAM Faster R-CNN. *Journal of Theory and Practice of Engineering Science*, 3(12), 36–42.
- [https://doi.org/10.53469/jtpes.2023.03\(12\).06](https://doi.org/10.53469/jtpes.2023.03(12).06)
- Liu, S., Ma, X., Wu, H., & Li, Y. (2020). An End to End Framework with Adaptive Spatio-Temporal Attention Module for Human Action Recognition. *IEEE Access*, 8, 47220–47231. <https://doi.org/10.1109/ACCESS.2020.2979549>
- Lu, J., Tan, L., & Jiang, H. (2021). Review on convolutional neural network (CNN) applied to plant leaf disease classification. In *Agriculture (Switzerland)* (Vol. 11, Issue 8). MDPI AG. <https://doi.org/10.3390/agriculture11080707>
- Luaibi, A. R., Salman, T. M., & Miry, A. H. (2021). Detection of citrus leaf diseases using a deep learning technique. *International Journal of Electrical and Computer Engineering*, 11(2), 1719–1727.
- <https://doi.org/10.11591/ijece.v11i2.pp1719-1727>
- Markoulidakis, I., Kopsiaftis, G., Rallis, I., & Georgoulas, I. (2021). Multi-Class Confusion Matrix Reduction method and its application on Net Promoter Score classification problem. *ACM International Conference Proceeding Series*, 412–419. <https://doi.org/10.1145/3453892.3461323>
- Song, C.-Chung., Wang, C.-Lun., & Yang, Y.-F. (2020). *IOT, Communication and Engineering : 2nd IEEE Eurasia Conference on IOT, Communication and*

- Engineering 2020 (IEEE ECICE 2020) : Yunlin, Taiwan, October 23-25, 2020.* International Institute of Knowledge Innovation and Invention (IIKII).
- Meirelles, A. L. S., Kurc, T., Kong, J., Ferreira, R., Saltz, J. H., & Teodoro, G. (2022). Building Efficient CNN Architectures for Histopathology Images Analysis: A Case-Study in Tumor-Infiltrating Lymphocytes Classification. *Frontiers in Medicine*, 9. <https://doi.org/10.3389/fmed.2022.894430>
- Mishra, G., Gupta, P., & Tanwar, R. (2024). Target Recognition Using Pre-Trained Convolutional Neural Networks and Transfer Learning. *Procedia Computer Science*, 235, 1445–1454. <https://doi.org/10.1016/j.procs.2024.04.136>
- Nandini, B., & Puviarasi, R. (2021). *Detection of Skin Cancer using Inception V3 And Inception V4 Convolutional Neural Network (CNN) For Accuracy Improvement* (Vol. 11, Issue 4).
- Nazir, M. S., Khan, U. G., Mohiyuddin, A., Al Reshan, M. S., Shaikh, A., Rizwan, M., & Davidekova, M. (2022). A Novel CNN-Inception-V4-Based Hybrid Approach for Classification of Breast Cancer in Mammogram Images. *Wireless Communications and Mobile Computing*, 2022. <https://doi.org/10.1155/2022/5089078>
- Orozco-Arias, S., Piña, J. S., Tabares-Soto, R., Castillo-Ossa, L. F., Guyot, R., & Isaza, G. (2020). Measuring performance metrics of machine learning algorithms for detecting and classifying transposable elements. *Processes*, 8(6). <https://doi.org/10.3390/PR8060638>
- Pan, Y., Wang, L., Duan, S., Gan, X., & Hong, L. (2021). Chinese image caption of *InceptionV4* and double-layer GRUs based on attention mechanism.

*Journal of Physics: Conference Series*, 1861(1). <https://doi.org/10.1088/1742-6596/1861/1/012044>

Praharsha, C. H., & Poulose, A. (2024). CBAM VGG16: An efficient driver distraction classification using CBAM embedded VGG16 architecture. *Computers in Biology and Medicine*, 180. <https://doi.org/10.1016/j.combiomed.2024.108945>

Ramli, N. E., Yahya, Z. R., & Said, N. A. (2022). Confusion Matrix as Performance Measure for Corner Detectors. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, 29(1), 256–265. <https://doi.org/10.37934/araset.29.1.256265>

Raza, A., Khan, M. U., Saeed, Z., Samer, S., Mobeen, A., & Samer, A. (2021). Classification of Eye Diseases and Detection of Cataract using Digital Fundus Imaging (DFI) and Inception-V4 Deep Learning Model. *Proceedings - 2021 International Conference on Frontiers of Information Technology, FIT 2021*, 137–142. <https://doi.org/10.1109/FIT53504.2021.00034>

Sarvamangala, D. R., & Kulkarni, R. V. (2022). Convolutional neural networks in medical image understanding: a survey. In *Evolutionary Intelligence* (Vol. 15, Issue 1). Springer Science and Business Media Deutschland GmbH. <https://doi.org/10.1007/s12065-020-00540-3>

Sharifani, K., & Amini, M. (2023). Machine Learning and Deep Learning: A Review of Methods and Applications. In *World Information Technology and Engineering Journal* (Vol. 10). <https://ssrn.com/abstract=4458723>

Strubell, E., Ganesh, A., & McCallum, A. (2020). Energy and Policy Considerations for Modern Deep Learning Research. [www.aaai.org](http://www.aaai.org)

- Sun, K., Zhao, Q., & Wang, X. (2021). Using knowledge inference to suppress the lamp disturbance for fire detection. *Journal of Safety Science and Resilience*, 2(3), 124–130. <https://doi.org/10.1016/j.jnlssr.2021.07.002>
- Swathi, M., & Regunathan, R. (2024). A multi-fusion approach to classify pharyngitis, tonsillitis and oral cancer with iterative relief feature weighting. *Alexandria Engineering Journal*, 104, 359–370. <https://doi.org/10.1016/j.aej.2024.06.027>
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2016a). *Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning*.
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2016b). *Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning*. <http://arxiv.org/abs/1602.07261>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). *Going Deeper with Convolutions*.
- Szegedy, C., Liu, W., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2014). *Going deeper with convolutions*.
- Szegedy, C., Vanhoucke, V., Ioffe, S., & Shlens, J. (2015). *Rethinking the Inception Architecture for Computer Vision*.
- Tahir, A. M., Chowdhury, M. E. H., Khandakar, A., Rahman, T., Qiblawey, Y., Khurshid, U., Kiranyaz, S., Ibtehaz, N., Rahman, M. S., Al-Maadeed, S., Mahmud, S., Ezeddin, M., Hameed, K., & Hamid, T. (2021). COVID-19 infection localization and severity grading from chest X-ray images. *Computers in Biology and Medicine*, 139. <https://doi.org/10.1016/j.combiomed.2021.105002>

- Tavolara, T. E., Gurcan, M. N., Segal, S., & Niazi, M. K. K. (2021). Identification of difficult to intubate patients from frontal face images using an ensemble of deep learning models. *Computers in Biology and Medicine*, 136. <https://doi.org/10.1016/j.combiomed.2021.104737>
- Tekchandani, H., Verma, S., & Londhe, N. (2020). Performance improvement of mediastinal lymph node severity detection using GAN and Inception network. *Computer Methods and Programs in Biomedicine*, 194. <https://doi.org/10.1016/j.cmpb.2020.105478>
- Vakili, M., Ghamsari, M., & Rezaei, M. (2020). *Performance Analysis and Comparison of Machine and Deep Learning Algorithms for IoT Data Classification*.
- Valero-Carreras, D., Alcaraz, J., & Landete, M. (2023). Comparing two SVM models through different metrics based on the confusion matrix. *Computers and Operations Research*, 152. <https://doi.org/10.1016/j.cor.2022.106131>
- Verbakel, J. Y., Steyerberg, E. W., Uno, H., De Cock, B., Wynants, L., Collins, G. S., & Van Calster, B. (2020a). ROC curves for clinical prediction models part 1. ROC plots showed no added value above the AUC when evaluating the performance of clinical prediction models. *Journal of Clinical Epidemiology*, 126, 207–216. <https://doi.org/10.1016/j.jclinepi.2020.01.028>
- Verbakel, J. Y., Steyerberg, E. W., Uno, H., De Cock, B., Wynants, L., Collins, G. S., & Van Calster, B. (2020b). ROC curves for clinical prediction models part 1. ROC plots showed no added value above the AUC when evaluating the performance of clinical prediction models. *Journal of Clinical Epidemiology*, 126, 207–216. <https://doi.org/10.1016/j.jclinepi.2020.01.028>

- Wang, D., & Yan, Y. (2024). Improving *InceptionV4* model based on fractional-order snow leopard optimization algorithm for diagnosing of ACL tears. *Scientific Reports*, 14(1), 1–19. <https://doi.org/10.1038/s41598-024-60419-6>
- Wang, W., Tan, X., Zhang, P., & Wang, X. (2022). A CBAM Based Multiscale Transformer Fusion Approach for Remote Sensing Image Change Detection. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 6817–6825. <https://doi.org/10.1109/JSTARS.2022.3198517>
- Wang, Y., Chen, X., Li, J., & Lu, Z. (2024). Convolutional Block Attention Module—Multimodal Feature-Fusion Action Recognition: Enabling Miner Unsafe Action Recognition. *Sensors*, 24(14). <https://doi.org/10.3390/s24144557>
- Wei, H., Gao, W., Nie, H., Sun, J., & Zhu, M. (2022). Classification of Giemsa staining chromosome using input-aware deep convolutional neural network with integrated uncertainty estimates. *Biomedical Signal Processing and Control*, 71. <https://doi.org/10.1016/j.bspc.2021.103120>
- Wirasto, A., & Baballe Ahmad, M. (2024). Implementation of Intelligent Pneumonia Detection Model, Using Convolutional Neural Network (CNN) and *InceptionV4* Transfer Learning Fine Tuning. *Journal of Advanced Health Informatics Research (JAHIR)*, 2(1), 1–11. <https://doi.org/10.59247/jahir.v2i1.180>
- Woo, S., Park, J., Lee, J.-Y., & Kweon, I. S. (2018). CBAM: Convolutional Block Attention Module. <http://arxiv.org/abs/1807.06521>

- Wu, M. Te. (2022). Confusion matrix and minimum cross-entropy metrics based motion recognition system in the classroom. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-07137-z>
- Xin, H., & Li, L. (2023). Arbitrary Style Transfer With Fused Convolutional Block Attention Modules. *IEEE Access*, 11, 44977–44988. <https://doi.org/10.1109/ACCESS.2023.3273949>
- Yacoubi Amazon Alexa, R., & Axman Amazon Alexa, D. (2020). *Probabilistic Extension of Precision, Recall, and F1 Score for More Thorough Evaluation of Classification Models*.
- Yu, M., Duan, Y., Li, Z., & Zhang, Y. (2021). Prediction of peptide detectability based on capsnet and convolutional block attention module. *International Journal of Molecular Sciences*, 22(21). <https://doi.org/10.3390/ijms222112080>
- Yu, T., & Zhu, H. (2020). *Hyper-Parameter Optimization: A Review of Algorithms and Applications*. <http://arxiv.org/abs/2003.05689>
- Zeng, N., Gong, G., Zhou, G., & Hu, C. (2023). An Accurate Classification of Rice Diseases Based on ICAI-V4. *Plants*, 12(11). <https://doi.org/10.3390/plants12112225>
- Zeng, Q., Ma, X., Cheng, B., Zhou, E., & Pang, W. (2020). GANS-based data augmentation for citrus disease severity detection using deep learning. *IEEE Access*, 8, 172882–172891. <https://doi.org/10.1109/ACCESS.2020.3025196>
- Zhang, B., Rajan, R., Pineda, L., Lambert, N., Biedenkapp, A., Chua, K., Hutter, F., & Calandra, R. (2021). *On the Importance of Hyperparameter Optimization for Model-based Reinforcement Learning* (Vol. 130).

Zhang, H., Liu, C., Ho, J., & Zhang, Z. (2022). Mask Wearing Detection Based on *InceptionV4* and Multi-Scale Retinex Image Enhancement Algorithm. *Journal of Physics: Conference Series*, 2289(1). <https://doi.org/10.1088/1742-6596/2289/1/012021>

Zhang, J., Ye, L., & Lai, Y. (2023). Stock Price Prediction Using CNN-BiLSTM-Attention Model. *Mathematics*, 11(9). <https://doi.org/10.3390/math11091985>

Zhang, J., Yi, Q., Huang, L., Yang, Z., Cheng, J., & Zhang, H. (2023). Research on None-Line-of-Sight/Line-of-Sight Identification Method Based on Convolutional Neural Network-Channel Attention Module. *Sensors (Basel, Switzerland)*, 23(20). <https://doi.org/10.3390/s23208552>

Zhang, L., Zhang, J., Gao, W., Bai, F., Li, N., & Rashid Sheykhhahmad, F. (2024). A novel approach for automated diagnosis of kidney stones from CT images using optimized *InceptionV4* based on combined dwarf mongoose optimizer. *Biomedical Signal Processing and Control*, 94, 106356. <https://doi.org/https://doi.org/10.1016/j.bspc.2024.106356>

Zhang, Y., Zhang, X., & Zhu, W. (2021). ANC: Attention network for COVID-19 explainable diagnosis based on convolutional block attention module. *CMES - Computer Modeling in Engineering and Sciences*, 127(3), 1037–1058. <https://doi.org/10.32604/cmes.2021.015807>

Zhang, Z., & Wang, M. (2022a). *Convolutional Neural Network with Convolutional Block Attention Module for Finger Vein Recognition*. <http://arxiv.org/abs/2202.06673>

Zhang, Z., & Wang, M. (2022b). *Convolutional Neural Network with Convolutional Block Attention Module for Finger Vein Recognition.*

<http://arxiv.org/abs/2202.06673>



PAPER NAME

ASTRI YOHANA SIDAURUK.pdf

AUTHOR

ASTRI YOHANA SIDAURUK

WORD COUNT

12918 Words

CHARACTER COUNT

83669 Characters

PAGE COUNT

81 Pages

FILE SIZE

2.1MB

SUBMISSION DATE

May 16, 2025 3:42 PM GMT+7

REPORT DATE

May 16, 2025 3:43 PM GMT+7

- 13% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

- 6% Internet database
  - Crossref database
  - 13% Submitted Works database
  - 2% Publications database
  - Crossref Posted Content database
- 
- Excluded from Similarity Report
- Bibliographic material
  - Abstract
  - Cited material
  - Small Matches (Less than 15 words)



Nomor : 2629/FT/01.10/IX/2024

18 September 2024

Lampiran :-

Hal : **Pembimbing Tugas Akhir**

Yth. Pembimbing Tugas Akhir

**Muhathir S.T, M.Kom ( Sebagai Pembimbing )**

di Tempat

Dengan hormat, sehubungan telah dipenuhinya persyaratan untuk memperoleh Tugas Akhir dari mahasiswa atas :

Nama : ASTRI YOHANA SIDAURUK

NIM : 218160034

Jurusan : TEKNIK INFORMATIKA

Maka dengan hormat kami mengharapkan kesediaan saudara :

**Muhathir S.T, M.Kom ( Sebagai Pembimbing )**

Adapun Tugas Akhir Skripsi berjudul :

**Optimisasi Diagnosis Penyakit Daun Jeruk dengan InceptionV4 dan Mekanisme Perhatian CBAM**

SK Pembimbing ini berlaku selama enam bulan terhitung sejak SK ini diterbitkan. Jika proses pembimbing melebihi batas waktu yang telah ditetapkan, SK ini dapat ditinjau ulang.

Demikian kami sampaikan, atas kesediaan saudara diucapkan terima kasih.

Dekan,



Dr Eng. Supriyatno, ST, MT.



# UNIVERSITAS MEDAN AREA

## FAKULTAS TEKNIK

Kampus I : Jalan Kolam Nomor 1 Medan Estate (061) 7360168, Medan, 20223

Kampus II : Jalan Setia Budi Nomor 79 / Jalan Sei Serayu Nomor 70 A (061) 42402994, Medan, 20122

Website: [www.teknik.uma.ac.id](http://www.teknik.uma.ac.id) E-mail: [univ\\_medanarea@uma.ac.id](mailto:univ_medanarea@uma.ac.id)

Nomor : 445 /FT.6/01.10/XI/2024  
 Lamp : -  
 Hal : **Penelitian Dan Pengambilan Data Tugas Akhir**

18 November 2024

Yth. Wakil Rektor Bidang Mutu Sumber Daya Manusia dan Perekonomian  
 Jln. Kolam No.1  
 Di  
 Medan

Dengan hormat, kami mohon kesediaan bapak kiranya berkenan untuk memberikan izin dan kesempatan kepada mahasiswa kami tersebut dibawah ini :

NO	NAMA	NPM	PRODI
1	Astri Yohana Sidauruk	218160034	Teknik Informatika

Untuk melaksanakan Penelitian dan Pengambilan Data Tugas Akhir di Laboratorium Komputer Program Studi Teknik Informatika Fakultas Teknik Universitas Medan Area.

Perlu kami jelaskan bahwa Pengambilan Data tersebut adalah semata-mata untuk tujuan Ilmiah dan Skripsi, yang merupakan salah satu syarat bagi mahasiswa tersebut untuk mengikuti ujian sarjana pada Fakultas Teknik Universitas Medan Area dan tidak untuk dipublikasikan, dengan judul :

**Optimasi Diagnosis Penyakit Daun Jeruk dengan Inception-V4 dan Mekanisme Perhatian CBAM.**

Mohon kiranya tanggal Surat Izin Pengambilan Data Tugas Akhir agar disesuaikan dengan tanggal Terbitnya Surat ini.

Atas perhatian dan kerja sama yang baik diucapkan terima kasih.

Dekan  
  
**Dr. Eng. Supriatno, ST, MT**

Tembusan :  
 1. Ka. BPMPP  
 2. Mahasiswa  
 3. File

**UNIVERSITAS MEDAN AREA**

© Hak Cipta Di Lindungi Undang-Undang

Document Accepted 1/8/25

- Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
- Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
- Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Access From ([repository.uma.ac.id](http://repository.uma.ac.id)) 1/8/25



## SURAT KETERANGAN

Nomor : 1897/UMA/B/01.7/XII/2024

Rektor Universitas Medan Area dengan ini menerangkan bahwa :

Nama	:	Astri Yohana Sidauruk
No.Pokok Mahasiswa	:	218160034
Program Studi	:	Teknik Informatika
Fakultas	:	Teknik

Benar telah selesai Pengambilan Data di Laboratorium Komputer Program Studi Teknik Informatika Fakultas Teknik Universitas Medan Area dengan Judul Skripsi "Optimasi Diagnosis Penyakit Daun Jeruk dengan *InceptionV4* dan Mekanisme Perhatian CBAM". Dan kami harapkan Data tersebut kiranya dapat membantu yang bersangkutan dalam penyusunan skripsi dan dapat bermanfaat bagi mahasiswa khususnya Fakultas Teknik Informatika Universitas Medan Area.

Demikian surat ini diterbitkan untuk dapat digunakan seperlunya

Medan, 23 Desember 2024.

an Rektor

Wakil Rektor Bidang Mutu SDM & Perkonomian

Dr. Gedi Sahputra, S.Sos, MA

CC :

- Arsip