

**Penerapan *CBAM* Pada *Xception* Untuk
Klasifikasi Penyakit Daun Tebu**

SKRIPSI

OLEH:

SISILIA DEODORA SITEPU

218160017



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

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

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

Document Accepted 8/5/25

Access From (repository.uma.ac.id)8/5/25

Penerapan *CBAM* Pada *Xception* Untuk Klasifikasi Penyakit Daun Tebu

SKRIPSI

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

Oleh:

SISILIA DEODORA SITEPU

218160017

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

UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

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

Document Accepted 8/5/25

Access From (repository.uma.ac.id)8/5/25

HALAMAN PENGESAHAN

Judul Skripsi : Penerapan *CBAM* Pada *Xception* Untuk Klasifikasi Penyakit Daun Tebu

Nama : Sisilia Deodora Sitepu
NPM : 218160017
Fakultas : Teknik

Disetujui Oleh
Pembimbing

Muhathir, S.T, M.Kom



Dekan Fakultas Teknik



Kaprodi

Rizki M. Nono, ST, MT.

Rizki M. Nono, S.Kom, M.Kom

Disetujui Oleh 12 Maret 2025

HALAMAN PERNYATAAN

Saya menyatakan bahwa skripsi yang saya susun, sebagai syarat memperoleh gelar serjana 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 : Sisilia Deodora Sitepu
NPM : 218160017
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 :

Penerapan CBAM pada Xception untuk Klasifikasi Penyakit Daun Tebu

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 : 12 Maret 2025

Yang menyatakan




Sisilia Deodora Sitepu
218160017

RIWAYAT HIDUP

Sisilia Deodora Sitepu lahir pada tanggal 25 November 2002 di Biru Biru dari bapak Agen Sitepu dan ibu April Yani Purba S.Th, M.Pd.K. Penulis merupakan anak ketiga dari lima bersaudara. Pada tahun 2020 penulis lulus dari SMAS RK Deli Murni Deli Tua dan mendaftar pada tahun 2021 menjadi mahasiswa di Fakultas Teknik Universitas Medan Area dengan jurusan Teknik Informatika.

Selama kuliah penulis aktif mengikuti kegiatan diluar kampus seperti Bootcamp atau program gratis secara daring, dan menghasilkan sertifikat untuk menambahkan skill penulis yang dicantumkan pada LinkedIn. Selain diluar kampus penulis juga mengikuti organisasi jurusan yaitu Himpunan Mahasiswa Informatika (HMIF) sebagai Ketua Divisi Public Relation periode 2023-2024.



KATA PENGANTAR

Dengan penuh rasa syukur kepada Tuhan Yang Maha Esa atas berkat dan rahmat-Nya, penulis akhirnya dapat menyelesaikan skripsi dengan judul **“Penerapan *CBAM* pada *Xception* untuk Klasifikasi Penyakit Daun Tebu”**. Skripsi ini disusun sebagai salah satu syarat untuk menyelesaikan pendidikan Program Strata-1 pada Fakultas Teknik Program Studi Teknik Informatika di Universitas Medan Area. Penulis menyadari bahwa meskipun skripsi ini telah disusun dengan sebaik – baiknya, masih terdapat banyak kekurangan dan jauh dari kata kesempurnaan. Oleh karena itu, penulis sangat mengharapkan kritik dan saran yang bersifat konstruktif dari para pembaca untuk perbaikan di masa yang akan datang. Penulis juga ingin menyampaikan rasa terima kasih yang sebesar – besarnya kepada :

1. Yesus Kristus yang selalu menyertai hidup penulis sehingga penulis masih bisa menjalankan hidup dengan baik dan selalu memberikan penulis perlindungan dan kekuatan.
2. Bapak Prof. Dr. Dadan Ramdan, M.Eng., M.Sc., selaku Rektor Universitas Medan Area.
3. Bapak Dr. Eng. Supriatno, S.T., M.T. selaku Dekan Fakultas Teknik Universitas Medan Area.
4. Bapak Rizki Muliono, S.Kom, M.Kom., selaku Kepala Program Studi Teknik Informatika.
5. Bapak Muhathir S.T, M.Kom., selaku dosen pembimbing yang telah membimbing, mengarahkan dan memberikan motivasi kepada penulis dalam proses menyelesaikan skripsi ini.

KATA PENGANTAR

Dengan penuh rasa syukur kepada Tuhan Yang Maha Esa atas berkat dan rahmat-Nya, penulis akhirnya dapat menyelesaikan skripsi dengan judul **“Penerapan *CBAM* pada *Xception* untuk Klasifikasi Penyakit Daun Tebu”**.

Skripsi ini disusun sebagai salah satu syarat untuk menyelesaikan pendidikan Program Strata-1 pada Fakultas Teknik Program Studi Teknik Informatika di Universitas Medan Area. Penulis menyadari bahwa meskipun skripsi ini telah disusun dengan sebaik – baiknya, masih terdapat banyak kekurangan dan jauh dari kata kesempurnaan. Oleh karena itu, penulis sangat mengharapkan kritik dan saran yang bersifat konstruktif dari para pembaca untuk perbaikan di masa yang akan datang. Penulis juga ingin menyampaikan rasa terima kasih yang sebesar – besarnya kepada :

1. Yesus Kristus yang selalu menyertai hidup penulis sehingga penulis masih bisa menjalankan hidup dengan baik dan selalu memberikan penulis perlindungan dan kekuatan.
2. Bapak Prof. Dr. Dadan Ramdan, M.Eng., M.Sc., selaku Rektor Universitas Medan Area.
3. Bapak Dr. Eng. Supriatno, S.T., M.T. selaku Dekan Fakultas Teknik Universitas Medan Area.
4. Bapak Rizki Muliono, S.Kom, M.Kom., selaku Kepala Program Studi Teknik Informatika.
5. Bapak Muhathir S.T, M.Kom., selaku dosen pembimbing yang telah membimbing, mengarahkan dan memberikan motivasi kepada penulis dalam proses menyelesaikan skripsi ini.

6. Seluruh Dosen Teknik Informatika Universitas Medan Area yang telah membekali penulis dengan ilmu yang sangat bermanfaat.
7. Bapak Robby Kurniawan Sari Damanik, ST., selaku IT Support Teknik Informatika yang selalu mengarahkan penulis dalam administrasi.
8. Yang sangat teristimewa kedua orang tua penulis, Alm. Bapak Agen Sitepu dan Ibu April Yani Purba S.Th, M.Pd.K., yang selalu mendukung dan mendoakan penulis sehingga penulis menyelesaikan pendidikan hingga perguruan tinggi.
9. Kepada saudara kandung penulis yang turut selalu mendukung segala kegiatan penulis hingga berhasil menyelesaikan pendidikan ini.
10. Dan paling penulis cintai dan banggakan, yaitu diri penulis sendiri yaitu Sisilia Deodora Sitepu S.Kom yang telah berusaha melewati segala jenis badai hidup untuk bisa dapat berdiri tegap sampai detik ini dan berjuang sejauh ini. Semoga kedepannya menjadi seorang yang sukses dan berguna bagi orang lain.

Medan , 12, Maret 2025



Sisilia Deodora Sitepu
218160017

ABSTRAK

Penelitian ini mengkaji penerapan *Convolutional Block Attention Module (CBAM)* pada arsitektur *Xception* untuk klasifikasi daun tebu. *CBAM* dirancang untuk meningkatkan kemampuan model dalam memfokuskan perhatian pada fitur relevan dalam gambar, dan telah terbukti meningkatkan akurasi pada pengenalan objek dan klasifikasi citra. Penelitian ini bertujuan untuk mengukur peningkatan akurasi dan kinerja model *Xception* setelah integrasi *CBAM* dalam klasifikasi lima kategori daun tebu : *Healthy*, *Mosaic*, *RedRot*, *Rust* dan *Yellow*. Pendekatan eksperimen dilakukan dengan membandingkan performa model *Xception* tanpa *CBAM* dan *Xception* dengan *CBAM*. Hasil yang diperoleh menunjukkan bahwa penerapan *CBAM* meningkatkan akurasi model dari 88.33% menjadi 92.89%, dengan peningkatan signifikan pada *precision*, *recall* dan *F1-Score*, terutama pada kategori *Rust* yang mencatatkan *F1-Score* tertinggi 98.90%. Namun, kategori *Yellow* masih menunjukkan *precision* yang lebih rendah, yang menunjukkan potensi untuk perbaikan lebih lanjut dalam mengenali fitur yang lebih kompleks atau mirip antar kategori. Meskipun *CBAM* terbukti efektif dalam meningkatkan kinerja klasifikasi, proses pelatihan memerlukan waktu yang cukup lama akibat kompleksitas perhitungan pada setiap lapisan konvolusi. Mengoptimalkan penerapan *CBAM* dapat dilakukan dengan menggunakan *group convolution* pada saat lapisan konvolusi dalam arsitektur *Xception* untuk mempercepat waktu komputasi.

Kata Kunci: *CBAM*, *Xception*, Klasifikasi daun tebu, Presisi, *Recall*, *F1-Score*, akurasi.

ABSTRACT

This study examines the application of the Convolutional Block Attention Module (CBAM) in the Xception architecture for sugarcane leaf classification. CBAM is designed to enhance a model’s ability to focus on relevant image features and has been proven to improve accuracy in object recognition and image classification. This research aims to measure the improvement in accuracy and performance of the Xception model after integrating CBAM for classifying five categories of sugarcane leaves: Healthy, Mosaic, RedRot, Rust, and Yellow. An experimental approach was conducted by comparing the performance of the Xception model with and without CBAM. The results show that implementing CBAM increased the model’s accuracy from 88.33% to 92.89%, with significant improvements in precision, recall, and F1-score, particularly in the Rust category, which achieved the highest F1-score of 98.90%. However, the Yellow category still exhibited lower precision, suggesting potential improvements in recognizing complex or visually similar features between categories. Although CBAM effectively enhances classification performance, the training process requires a longer time due to increased computational complexity in each convolutional layer. Optimizing CBAM implementation can be achieved by using group convolution within the Xception architecture to accelerate computation time.

Keywords: CBAM, Xception, Sugarcane Leaf Classification, Precision, Recall, F1-Score, Accuracy

DAFTAR ISI

HALAMAN PENGESAHAN	i
HALAMAN PERNYATAAN	ii
RIWAYAT HIDUP	iv
KATA PENGANTAR	v
ABSTRAK	vii
ABSTRACT	viii
DAFTAR ISI	ix
DAFTAR TABEL	xi
DAFTAR GAMBAR	xii

BAB I PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Rumusan Masalah	5
1.3. Tujuan Penelitian.....	5
1.4. Batasan Masalah.....	5
1.5. Manfaat Penelitian.....	5


BAB II TINJAUAN PUSTAKA	7
2.1. Penyakit Daun Tebu	7
2.2. <i>Deep Learning</i>	7
2.3. <i>Convolution Neural Network (CNN)</i>	8
2.4. <i>Xception</i>	8
2.5. <i>CBAM (Convolution block attention module)</i>	9
2.6. <i>Optimizer</i>	9
2.7. Parameter.....	9
2.8. Kasus Penelitian	10
2.9. Penelitian Terdahulu.....	11

BAB III METODOLOGI PENELITIAN	12
3.1. Alat dan Bahan Penelitian	12
3.1.1. Perangkat Keras	12
3.1.2. Perangkat Lunak.....	12
3.2. Diagram Alur Penelitian.....	13
3.3. Metode Pengumpulan Data	14
3.4. Rancangan Arsitektur	16
3.4.1. <i>Xception</i>	16
3.4.2. <i>CBAM</i>	17
3.5. Integrasi <i>CBAM</i> pada <i>Xception</i>	18

3.6.	Pembagian Data.....	19
3.7.	<i>Hyperparameter</i>	20
3.8.	Metode Evaluasi	20
3.8.1.	<i>Confusion Matrix</i>	20
3.8.2	<i>Classification Report</i>	21
3.8.3	<i>ROC Curve</i>	23
BAB IV HASIL DAN PEMBAHASAN.....		24
4.1	Hasil.....	24
4.1.1	Visualisasi Data.....	24
4.1.2	Implementasi Model <i>Xception</i>	25
4.1.3	Integrasi <i>CBAM</i> dalam Model <i>Xception</i>	31
4.1.4	Implementasi WEB	36
4.1.5	Implementasi Mobile	39
4.1.6	Klasifikasi Daun Tebu.....	40
4.2	Pembahasan	47
BAB V KESIMPULAN DAN SARAN		50
5.1	Kesimpulan.....	50
5.2	Saran	50
DAFTAR PUSTAKA.....		52

DAFTAR TABEL

	Halaman
Tabel 2.1. Kasus Penelitian.....	10
Tabel 2.2. Penelitian Terdahulu	11
Tabel 3.1. Perangkat Keras	12
Tabel 3.2. Perangkat Lunak	13
Tabel 3.3. Pembagian Proporsi Data.....	20
Tabel 3.4. <i>Hyperparameter</i>	20
Tabel 4.1. <i>Classification Report Xception</i>	29
Tabel 4.2. <i>Classification Report Integrasi CBAM</i>	34
Tabel 4.3. Klasifikasi Daun Tebu	40
Tabel 4.4. <i>Classification Report</i> Pengujian Pada Daun Diluar Dataset Menggunakan Deploy WEB dan Mobile.....	46
Tabel 4.5. <i>Classification Report Xception dan Integrasi CBAM</i>	48
Tabel 4.6. Perbandingan dengan Penelitian Terdahulu.....	48



DAFTAR GAMBAR

	Halaman
Gambar 3.1. Alur Penelitian	13
Gambar 3.2. Dataset Daun Tebu	15
Gambar 3.3. Arsitektur <i>Xception</i>	16
Gambar 3.4. Arsitektur <i>CBAM</i>	17
Gambar 3.5. Arsitektur Integrasi <i>CBAM</i> pada <i>Xception</i>	18
Gambar 4.1. Dataset Daun Tebu	25
Gambar 4.2. Akurasi <i>Training vs Validation</i> pada <i>Xception</i>	26
Gambar 4.3. <i>Loss Training vs Validation</i> pada <i>Xception</i>	27
Gambar 4.4. <i>Confusion Matrix</i> pada <i>Xception</i>	28
Gambar 4.5. <i>ROC AUC Xception</i>	30
Gambar 4.6. Akurasi <i>Training vs Validation</i> pada Integrasi <i>CBAM</i>	31
Gambar 4.7. <i>Loss Training vs Validation</i> pada Integrasi <i>CBAM</i>	32
Gambar 4.8. <i>Confusion Matrix</i> pada Integrasi <i>CBAM</i>	33
Gambar 4.9. <i>ROC AUC Integrasi CBAM</i>	35
Gambar 4.10. <i>Loss Training vs Validation</i> pada <i>Xception</i> dan Integrasi <i>CBAM</i>	36
Gambar 4.11. Upload Gambar Daun Tebu	37
Gambar 4.12. Klasifikasi Jenis Sehat.....	37
Gambar 4.13. Klasifikasi Jenis <i>Mosaic</i>	38
Gambar 4.14. Klasifikasi Jenis <i>RedRot</i>	38
Gambar 4.15. Klasifikasi Jenis <i>Rust</i>	38
Gambar 4.16. Klasifikasi Jenis <i>Yellow</i>	39
Gambar 4.17. Klasifikasi 5 Jenis Daun Tebu.....	40
Gambar 4.18. <i>Confusion Matrix</i> Pengujian Pada Daun Diluar Dataset Menggunakan Deploy WEB dan Mobile.....	46
Gambar 4.19. <i>ROC AUC Xception</i> dan Integrasi <i>CBAM</i>	47

BAB I

PENDAHULUAN

1.1. Latar Belakang

Produksi gula mengalami penurunan sementara konsumsi terus meningkat, salah satu penyebabnya adalah tanaman tebu yang rentan terhadap faktor biotik dan abiotik. Beberapa penyakit seperti luka api, blendok dan mosaik bergaris dapat berdampak pada penurunan pada penurunan hasil panen dan kadar gula tebu (Fitriya dkk., 2024). Penyakit seperti sereh, pokkah boeng, luka api dan mosaik bergaris dapat mengurangi produksi hingga 0,85% per 1% kejadian (Yulianti dkk., 2020). Tebu merupakan tanaman musiman yang mengandung gula dalam batangnya dan memerlukan waktu satu tahun untuk dipanen. Sebagai komoditas penting di Indonesia, khususnya di Jawa dan Sumatra, tebu menjadi sumber penghidupan petani (Antika dkk., 2020). Selain gula, tebu menghasilkan biomassa seperti serat, *lignin* dan pentosan, yang dapat diolah menjadi produk bernilai tambah melalui proses kimia dan biologis. Produk sampingan seperti bagas dan molase juga dapat diubah menjadi bioenergi, bioelektrik dan bioetanol (Hidayah, 2020).

Karena sulitnya mengidentifikasi penyakit secara visual, penelitian ini bertujuan menggunakan *Convolution Neural Network (CNN)* untuk mengenali penyakit daun tebu dari gejala pada bentuk, warna dan tekstur daun, sehingga membantu peneliti dan petani melakukan pencegahan atau pengobatan tepat (Syech Ahmad & Sugiarto, 2023). Perkembangan teknologi pengolahan citra dan

kecerdasan buatan telah membuka peluang baru dalam mendeteksi penyakit tanaman secara otomatis. Salah satu teknik yang populer digunakan adalah *Convolution Neural Network (CNN)*, yang mampu mempelajari pola dari gambar tanpa perlu segmentasi dan ekstraksi fitur manual. *Xception*, sebagai salah satu arsitektur *CNN* yang canggih, telah terbukti efektif dalam berbagi tugas klasifikasi citra, termasuk deteksi penyakit tanaman (Amrulloh dkk., 2024). Dibandingkan dengan model lainnya, *Xception* berhasil mencapai akurasi pengujian tertinggi sebesar 94,13% dengan gambar CXR paru paru polos (Kumara dkk., 2023). *Xception* digunakan sebagai model dasar untuk klasifikasi penyakit daun tebu dan kinerjanya ditingkatkan dengan mengurangi kedalaman serta memperluas keluasan arsitekturnya (Mehmood dkk., 2023).

Penelitian sebelumnya telah banyak membahas penerapan teknik berbasis citra dan metode pembelajaran mesin untuk identifikasi penyakit tanaman (Wahid dkk., 2022) Wahid dan timnya melakukan studi tentang klasifikasi penyakit daun tomat dengan membandingkan kinerja beberapa model *ensambled transfer learning*, yaitu *InceptionV3*, *Xception* dan *VGG16*. Hasilnya menunjukkan bahwa *Xception* memiliki performa yang unggul, mencapai akurasi 99% pada data pelatihan dan 95% pada data validasi (Amrulloh dkk., 2024). *Xception* merupakan arsitektur jaringan saraf konvolusional dengan konvolusi terpisah yang terdiri dari 36 lapisan untuk ekstraksi fitur, dan meskipun memiliki jumlah parameter yang sama dengan *InceptionV3*, kinerjanya lebih baik. Pada penelitian lain seperti kumbang kentang, *Xception* mencapai akurasi tertinggi 99,95% pada satu kumpulan data, sedangkan *DenseNet121* hanya mencapai 92,95% pada kumpulan data lain, dengan rata – rata akurasi 96,30% (Karakan, 2024).

Xception, dikembangkan oleh Chollet, adalah arsitektur jaringan saraf konvolusional yang dirancang untuk melampaui arsitektur lain dalam tugas – tugas visi komputer (Davis & Shekaramiz, 2023). Sebagai varian *Convolution Neural Network (CNN)*, *Xception* dipilih karena kemampuannya yang baik dalam mencapai kinerja tinggi dengan efisiensi parameter yang sangat baik. Seperti yang ditunjukkan dalam pelatihan daun kopi, *Xception* menduduki peringkat keempat dalam kinerja, dengan akurasi pelatihan mencapai sekitar 99,40% (Hitimana dkk., 2024). *Xception* menggantikan modul *inception* di jaringan *Inception* dengan *Depthwise Separable Convolution (DWSC)* yang dimodifikasi, di mana *DWSC* terdiri dari konvolusi *depthwise* diikuti oleh konvolusi *pointwise*, dan banyak digunakan di *MobileNets* karena efisiensinya dalam mengurangi kompleksitas komputasi tanpa mengorbankan kinerja (Islam dkk., 2023).

Memodifikasi arsitektur *Xception* dengan menyisipkan *Convolution Block Attention Module (CBAM)* dapat meningkatkan kinerja deteksi penyakit daun tebu. *CBAM* mudah diintegrasikan ke jaringan saraf dalam dan terbukti signifikan meningkatkan kinerja pada tugas klasifikasi gambar, deteksi objek dan segmentasi (He dkk., 2024). Modul ini memanfaatkan informasi fitur dari blok latar belakang untuk mengisi bagian yang hilang dengan mensimulasikan hubungan jangka panjang, meskipun hasil pengisian tersebut bisa kurang akurat jika konteksnya lemah atau ada perubahan tekstur yang rumit (Gong dkk., 2024). *CBAM* ini juga membantu fokus pada area penting gambar sambil mengabaikan *noise* latar belakang (H. Liu dkk., 2024).

Jaringan saraf ringan seperti *Xception* dipilih sebagai model utama, dengan *CBAM* yang digunakan untuk menekankan informasi penting terkait kesalahan

motorik, sehingga memungkinkan identifikasi yang lebih akurat. *Xception*, sebagai tipe jaringan saraf konvolusional, memiliki desain efisien yang menjaga kinerja optimal sambil mengurangi ukuran model secara signifikan. Tanpa mengorbankan akurasi atau kompleksitas komputasi, mekanisme *CBAM* ditambahkan, di mana sudut Gram juga diintegrasikan ke dalam jaringan yang dioptimalkan (Xie dkk., 2024). *Convolutional Block Attention Module (CBAM)* dirancang untuk meningkatkan kemampuan jaringan dalam menangkap fitur penting dengan fokus pada saluran atau area spesifik yang relevan. Setelah proses fusi, penting untuk memastikan integrasi fitur yang dihasilkan oleh berbagai cabang jaringan agar menghasilkan input fitur yang lebih akurat untuk tugas klasifikasi yang melibatkan lapisan-lapisan terhubung sepenuhnya (Luo dkk., 2024). Dengan demikian, diusulkan metode Fusi Fitur Ringan berbasis modul perhatian blok konvolusional (*CBAM*) yang ditingkatkan untuk operasi pemilihan fitur (Tan dkk., 2024).

Integrasi *Convolutional Block Attention Module (CBAM)* pada arsitektur *Xception* memberikan peningkatan signifikan dalam kemampuan model untuk fokus pada fitur-fitur penting dari gambar, yang sangat krusial dalam klasifikasi. Dengan menambahkan perhatian kontekstual pada setiap blok konvolusi, *CBAM* membantu model dalam mengekstraksi informasi lebih relevan dengan menekankan bagian-bagian gambar yang lebih informatif dan mengabaikan informasi yang kurang penting. Maka dari itu penelitian ini akan membangun model *Xception* yang telah diintegrasikan *CBAM* didalamnya untuk menguji kinerjanya, yang diterapkan pada pengenalan/klasifikasi penyakit pada daun tebu.

1.2. Rumusan Masalah

Permasalahan yang dihadapi adalah bagaimana kinerja atau pengaruh *CBAM* ketika diterapkan pada arsitektur *Xception* untuk mendeteksi penyakit daun tebu.

1.3. Tujuan Penelitian

Tujuan dari penelitian ini untuk mendeteksi penyakit daun tebu dengan menggunakan arsitektur *Xception* dengan menyisipkan *CBAM* dan menunjukkan arsitektur ini menghasilkan klasifikasi penyakit daun tebu yang lebih efektif.

1.4. Batasan Masalah

Adapun batasan masalah dalam penelitian ini adalah sebagai berikut :

1. Penelitian ini menggunakan daun tebu yang sehat dan daun tebu yang terkena penyakit hingga warna daun berubah.
2. Data yang digunakan pada penelitian ini merupakan data sekunder yang diambil dari sumber terbuka, yaitu kaggle. Dataset yang didapat dari *website kaggle* bernama *sugarcane leaf disease dataset*.
3. Citra yang diinput adalah tekstur permukaan daun.

1.5. Manfaat Penelitian

Manfaat dari penelitian ini adalah memberikan kontribusi dalam pengembangan model deteksi penyakit daun tebu yang lebih akurat dan efisien dengan mengintegrasikan *CBAM* pada arsitektur *Xception*, sehingga dapat

membantu dalam upaya peningkatan hasil pertanian melalui deteksi penyakit yang lebih dini dan tepat.



BAB II

TINJAUAN PUSTAKA

2.1. Penyakit Daun Tebu

Penyakit daun tebu sering menjadi masalah utama dalam budidaya tanaman ini, berpotensi mempengaruhi hasil panen secara signifikan. Salah satu faktor yang mempengaruhi kerentanan terhadap penyakit tersebut adalah akumulasi silikon (Si) dalam jaringan daun. Tebu, yang termasuk dalam keluarga *gramineae* seperti padi dan jagung, mampu mengakumulasi silikon yang sebaiknya mencapai setidaknya 1,5% dari berat kering tanaman. Namun, kadar silika pada daun tebu dapat menurun jika tanaman tumbuh di media yang miskin *silika*. Faktor-faktor lain, seperti kandungan *nitrogen*, *pH*, *salinitas*, ketersediaan air tanah, tekstur media, serta rendahnya penggunaan pupuk berbasis *silika*, juga berkontribusi terhadap penurunan ini. Penurunan kadar *silika* dapat berdampak negatif pada kesehatan tanaman dan meningkatkan kerentanan terhadap penyakit daun (Soeroso dkk., 2021)

2.2. Deep Learning

Menurut Hatcher & Yu, (2018) dalam Liu dkk., (2023) *deep learning* adalah algoritma yang memanfaatkan struktur kompleks atau berbagai jaringan saraf non-linier untuk merepresentasikan serta mempelajari data yang diberikan. Dengan menggunakan perceptron yang memiliki sejumlah lapisan tersembunyi yang bervariasi, algoritma ini secara otomatis menentukan bobot tautan yang sesuai dan

menggunakannya untuk mengklasifikasikan serta mengenali data asli. Dengan cara ini, komputer mampu meniru fungsi otak manusia dalam memproses dan memahami data secara bertingkat. Istilah ‘kedalaman’ dalam pembelajaran mendalam mengacu pada metode ini dibandingkan dengan metode ‘dangkal’ seperti *support vector machine*, *lifting method*, dan *maximum entropy method*.

2.3. *Convolution Neural Network (CNN)*

Convolution Neural Network (CNN) merupakan varian dari *Multi-Layer Perception (MPL)* yang memiliki jumlah parameter bebas lebih sedikit. Hal ini dikarenakan *CNN* tidak memerlukan *pre-processing*, segmentasi, maupun ekstraksi fitur secara manual. Selain itu, *CNN* juga mampu mengurangi jumlah parameter bebas dan tetap dapat menangani perubahan pada gambar input, seperti translasi, rotasi dan skala (Irfansyah dkk., 2021).

2.4. *Xception*

Menurut (Chollet, 2017) pada (Amrulloh dkk., 2024) *Xception*, adalah sebuah arsitektur yang menawarkan kinerja yang sangat baik dalam tugas klasifikasi gambar. Arsitektur ini mampu mencapai performa unggul dengan memanfaatkan teknik *depthwise separable convolution*. Teknik ini digunakan untuk meningkatkan efisiensi dan akurasi model dalam mengenali serta mengklasifikasikan gambar. Urutan konvolusi pada model *Xception* menggunakan konvolusi titik terlebih dahulu sebelum konvolusi berdasarkan kedalaman, *Xception* terdiri dari tiga bagian utama : aliran masuk, tengah dan keluar (Abdelmula dkk., 2024).

2.5. CBAM (Convolution block attention module)

CBAM (Convolution block attention module) merupakan modul perhatian yang sederhana namun efektif untuk jaringan saraf konvolusional umpan maju. Modul ini dapat memfokuskan perhatian pada informasi penting dalam saluran dan ruang secara terpisah, yang tidak hanya menghemat jumlah parameter dan daya komputasi, tetapi juga memudahkan integrasinya ke dalam arsitektur jaringan yang sudah ada sebagai modul yang dapat langsung digunakan (Zhang & Wang, 2022)

2.6. Optimizer

Optimizer adalah algoritma yang digunakan untuk memperbaharui bobot dalam model pembelajaran mesin, dengan tujuan meminimalkan fungsi loss dan meningkatkan akurasi. Dalam integrasi model *Xception* yang di Integrasikan CBAM (Convolutional Block Attention Module), *optimizer* yang tepat, seperti *Adam*, sangat penting untuk mengoptimalkan kinerja model. *Adam* dapat menyesuaikan laju pembelajaran adaptif, membantu model yang kompleks seperti *Xception* Integrasi CBAM untuk mengatasi permukaan *loss* yang rumit dan mencapai konvergensi lebih cepat, sehingga meningkatkan akurasi dalam tugas – tugas pengolahan gambar (Z. Liu dkk., 2021).

2.7. Parameter

Parameter dalam konteks pelatihan model merujuk pada nilai – nilai yang digunakan untuk mengatur proses optimasi dan pembelajaran model. Beberapa parameter yang umum digunakan termasuk *optimizer*, yang mengontrol bagaimana

bobot model diperbarui, *learning rate* yang menentukan seberapa besar langkah yang diambil dalam pembaharuan bobot, *batch size* yang mengatur jumlah sampel yang diproses sebelum pembaruan dilakukan, dan epoch yang mengacu pada jumlah iterasi model melihat seluruh data pelatihan. Parameter – parameter ini sangat penting untuk mencapai pelatihan yang efisien dan meningkatkan kinerja model pada tugas tertentu (Anang dkk., 2023).

2.8. Kasus Penelitian

Tabel 2.1. Kasus Penelitian

No	Penulis	Hasil
1	(Sun dkk., 2023)	Beberapa teknik pemrosesan gambar, termasuk K-means, ambang batas dan SVM diuji untuk meningkatkan akurasi model dalam mengenali gambar dan menghilangkan latar belakang yang kompleks. Hasil eksperimen menunjukkan bahwa algoritma SVM mampu menghasilkan wilayah ROI yang lebih luas dibandingkan dengan K-Means dan ambang batas. Oleh karena itu, kombinasi SVM dengan model SE-VIT yang diusulkan menghasilkan hasil yang paling optimal.
2	(Lebdo Pratitis dkk., 2023)	Meskipun penelitian in menggunakan sumber daya terbatas, model VGG-16 dengan pembelajaran transfer berhasil mengklasifikasikan penyakit daun tebu dengan akurasi 98%, <i>presisi</i> 100%, <i>recall</i> 97%, dan <i>F1-Score</i> 98% setelah 50 <i>epoch</i> .
3	(Ratnasari dkk., 2024)	Hasil uji coba menunjukkan bahwa kombinasi fitur <i>FDCM</i> dan <i>Lab* color moments</i> lebih unggul dengan akurasi 90% dalam mengidentifikasi tiga penyakit noda pada daun tebu, dibandingkan <i>GLCM</i> yang hanya mencapai 83%. Metode ini akurat mengenali noda cincin dan kuning (100%), namun akurasinya menurun untuk noda kuning (66%) dan non-noda (88%).

2.9. Penelitian Terdahulu

Tabel 2.2. Penelitian Terdahulu

No	Penulis	Judul	Hasil
1	(Amrulloh dkk., 2024)	Klasifikasi Penyakit Daun Bawang Menggunakan Algoritma CNN Xception	Model <i>CNN Xception</i> dalam klasifikasi penyakit daun bawang merah menunjukkan kemampuan prediksi selama tahap pelatihan model, yakni sebesar 100%, serta akurasi validasi yang mencapai 95%. Dengan demikian, dapat disimpulkan bahwa algoritma <i>CNN Xception</i> sangat efektif dan handal dalam menangani klasifikasi penyakit pada daun bawang merah.
2	(Hridoy dkk., 2021)	<i>An Efficient Computer Vision Approach for Rapid Recognition of Poisonous Plants by Classifying Leaf Image using Transfer Learning</i>	<i>Xception</i> telah menunjukkan kinerja yang sangat baik dalam studi ini dibandingkan dengan model lain, dengan akurasi pelatihan mencapai 99,71% dan akurasi pengujian sebesar 99,37%.
3	(Zhang & Wang, 2022)	<i>Convolutional Naural Network with Convolutional Block Attention Module for Finger Vein Recognition</i>	Penelitian ini menambahkan <i>CBAM</i> ke <i>CNN</i> untuk pengenalan urat jari, yang meningkatkan kualitas fitur yang diekstraksi dan menghasilkan akurasi lebih tinggi dibandingkan model klasik. Model ini menggunakan jaringan sederhana dengan fitur ringan, lebih sedikit komputasi, dan waktu pelatihan yang lebih cepat.
4	(Carnegie dkk., 2022)	<i>Essential Oil Plants Image Classification Using Xception Model</i>	Penelitian ini menggunakan <i>CNN Xception</i> dengan <i>transfer learning</i> untuk klasifikasi 10 tanaman minyak atsiri, menghasilkan akurasi tinggi tanpa <i>overfitting</i> atau <i>underfitting</i> .
5	(Syech Ahmad & Sugiarto, 2023)	Implementasi <i>Convolutional Neural Network (CNN)</i> untuk Klasifikasi Ikan Cupang Berbasis Mobile	Pengujian menunjukkan bahwa ikan cupang jenis <i>big ear</i> memiliki akurasi tertinggi sebesar 94,35%, diikuti oleh <i>Nemo</i> 86,24%, <i>Serit</i> 84,56% dan 78,85%, serta <i>Bluerim</i> dengan akurasi terendah 74,44%.

BAB III

METODOLOGI PENELITIAN

3.1. Alat dan Bahan Penelitian

Dalam penelitian ini, digunakan berbagai peralatan dan bahan pendukung untuk memastikan kelancaran pelaksanaan penelitian. Berikut adalah perangkat keras dan lunak yang dipakai dalam penelitian ini :

3.1.1. Perangkat Keras

Perangkat keras adalah bagian fisik dari komputer yang terdiri dari komponen – komponen elektronik yang dirakit menjadi sebuah modul. Spesifikasi perangkat keras yang digunakan dalam penelitian ini dapat dilihat pada tabel dibawah ini :

Tabel 3.1. Perangkat Keras

No	Perangkat Keras	Deskripsi
1	<i>Device</i>	Laptop Lenovo – 3KPO3370
2	<i>Processor</i>	Intel(R) Core(TM) i3-1005G1
3	<i>Hard Disk Drive</i>	124,13 NTFS
4	<i>Random Access Memory</i>	4096MB RAM

3.1.2. Perangkat Lunak


Perangkat lunak yang digunakan untuk menyelesaikan penelitian ini tercantum dalam tabel berikut :

Tabel 3.2. Perangkat Lunak

No	Perangkat Keras	Deskripsi
1	Sistem Operasi	<i>Windows 11 Home Single Language</i>
2	<i>Visual Studio Code</i>	<i>Code Editor</i>
3	Python	Bahasa Pemograman

3.2. Diagram Alur Penelitian

Ilustrasi alur penelitian ini ditampilkan pada gambar dibawah ini :



Gambar 3.1. Alur Penelitian

Penelitian ini dimulai dengan mengumpulkan sejumlah data gambar yang kemudian dikelompokkan berdasarkan kategori atau kelasnya. Gambar – gambar tersebut lalu dipersiapkan melalui pra-pemrosesan untuk disesuaikan dengan model yang akan digunakan. Dataset yang telah siap kemudian dibagi menjadi tiga bagian utama : data pelatihan untuk melatih model, data validasi untuk mengukur kinerja model selama pelatihan, dan data pengujian untuk mengevaluasi kinerja akhir model. Model yang digunakan dalam penelitian ini adalah arsitektur *Xception* yang dipadukan dengan modul *CBAM*. Setelah melalui tahap pelatihan dan pengujian yang berulang, diperoleh hasil akurasi model dalam mengklasifikasikan gambar – gambar baru.

3.3. Metode Pengumpulan Data

Penelitian ini menggunakan data sekunder yang diambil dan diunduh dari situs *Kaggle*, sebuah platform penyedia data *open source*. (<https://www.kaggle.com/datasets/nimalsankalana/sugarcane-leaf-disease-dataset/data>) sesuai dengan kriteria data yang dibutuhkan. Dataset yang digunakan dalam penelitian ini adalah *Sugarcane Leaf Disease Dataset*, yang terdiri dari lima kelas dengan rata – rata 450 file didalam perkelasnya.


Dataset tersebut berisi *Healthy* (daun sehat), *Mosaic* (daun bervirus) , *RedRot* (daun busuk merah), *Rust* (daun karat/coklat), dan *Yellow* (daun kuning).



Gambar 3.2. Dataset Daun Tebu (a) *Healthy* (b) *Mosaic* (c) *RedRot* (d) *Rust* (e) *Yellow*.

3.4. Rancangan Arsitektur

3.4.1. Xception




Gambar 3.3. Arsitektur Xception

Sumber : (Hridoy dkk., 2021)

Xception adalah model *deep learning* yang menggunakan lapisan *convolutional* yang dapat dipisahkan secara mendalam, dan merupakan versi ekstrim dari arsitektur *Inception*, di mana modul *Inception* standar digantikan oleh *depthwise separable convolution*. Ukuran gambar input untuk model ini adalah 299 x 299 piksel, dan lapisan terakhir arsitektur *Xception* yang terhubung penuh dihubungkan ke lapisan *Softmax* dengan 18 neuron untuk klasifikasi tanaman beracun. Arsitektur *Xception* terdiri dari tiga bagian utama: aliran masuk, aliran tengah, dan aliran keluar, dengan 36 lapisan konvolusi yang dibagi menjadi 14 modul. Data awalnya diproses melalui aliran masuk, kemudian melalui aliran tengah yang diulang delapan kali sebelum akhirnya melewati aliran keluar (Hridoy dkk., 2021).


3.4.2. CBAM



Gambar 3.4. Arsitektur CBAM

Gambar ini menunjukkan mekanisme *CBAM* (*Convolutional Block Attention Module*) yang terdiri dari *Channel Attention Module* dan *Spatial Attention Module*. Proses dimulai dengan peta fitur yang diproses oleh *Channel Attention Module*, di mana fitur penting dalam saluran tertentu diperkuat. Hasilnya kemudian di proses lebih lanjut oleh *Spatial Attention Module* untuk menyoroti bagian – bagian penting berdasarkan lokasi dalam ruang. Akhirnya, modul ini menghasilkan peta fitur yang lebih disempurnakan, memperkuat fitur yang relevan dan menekan yang tidak penting, sehingga menghasilkan output yang lebih akurat (Li dkk., 2023).

3.5. Integrasi *CBAM* pada *Xception*



Gambar 3.5. Arsitektur Integrasi *CBAM* pada *Xception*

Alur pada diagram ini menggambarkan modifikasi arsitektur *Xception* dengan menambahkan mekanisme *Convolutional Block Attention Module (CBAM)* untuk klasifikasi penyakit daun tebu. Secara keseluruhan, mekanisme *CBAM* ditambahkan diberbagai tahap arsitektur untuk meningkatkan perhatian terhadap fitur yang relevan dalam klasifikasi penyakit daun tebu. Model ini terbagi menjadi tiga bagian utama.

1. *Entry Flow* dengan *CBAM*

Gambar daun tebu masuk melalui beberapa lapisan konvolusi awal, dimulai dengan *Conv* 32, 64 dan *SeparableConv* 128. Setelah setiap *block* konvolusi, dilakukan proses *MaxPooling* dan *CBAM* diterapkan untuk menekan fitur penting pada gambar.

2. *Middle Flow Block* (Diulang sebanyak 8 kali)

Blok ini terdiri dari beberapa *SeparableConv* dengan ukuran kernel 728 dan fungsi aktivasi *ReLU*. Setelah setiap lapisan, *CBAM* kembali diterapkan untuk memperkuat fitur penting.

3. *Exit Flow* dengan *CBAM*

Pada tahap akhir, setelah serangkaian *SeparableConv* dengan ukuran kernel 1024, 1536 dan 2048, dilanjutkan dengan *Global Average Pooling* dan *Softmax* untuk melakukan klasifikasi. *CBAM* digunakan kembali untuk membantu proses ekstraksi fitur yang lebih akurat.

3.6. Pembagian Data

Penelitian ini menggunakan data berupa gambar atau citra daun tebu yang akan dibagi menjadi 80% untuk data pelatihan, 10% untuk data validasi, 10% untuk

data pengujian. Pembagian data ini didasarkan pada penelitian – penelitian sebelumnya.

Tabel 3.3. Pembagian Proporsi Data

Kategori	Training (80 %)	Validasi (10 %)	Test (10 %)	Total (100 %)
<i>Healthy</i> (Daun Sehat)	360	45	45	450
<i>Mosaic</i> (Daun Bervirus)	360	45	45	450
<i>RedRot</i> (Daun Busuk Merah)	360	45	45	450
<i>Rust</i> (Daun Karat/Coklat)	360	45	45	450
<i>Yellow</i> (Daun Kuning)	360	45	45	450

3.7. Hyperparameter

Tabel 3.4. Hyperparameter

No	Training (80 %)	Nilai
	<i>Optimizer</i>	Adam
	<i>Learning Rate</i>	0.0001
	<i>Batch Size</i>	32
	<i>Epoch</i>	20

3.8. Metode Evaluasi

Evaluasi performa model klasifikasi dilakukan untuk memastikan model dapat mengenali pola dalam data dengan baik. Dalam klasifikasi penyakit daun tebu, performa model dapat diukur menggunakan berbagai parameter, di antaranya *Confusion Matrix*, *Classification Report* dan *ROC Curve*. Berikut ini penjelasan detail dari masing – masing parameter tersebut.

3.8.1. Confusion Matrix

Confusion Matrix adalah sebuah tabel yang digunakan untuk menggambarkan performa model klasifikasi, dengan memperlihatkan jumlah presisi yang benar dan salah untuk masing – masing kelas. *Confusion Matrix*

memberikan informasi detail tentang kesalahan yang dibuat model pada tiap kelas dan menunjukkan bagaimana model mengklasifikasi data secara keseluruhan (Purwono dkk., 2021).

1. Defenisi Confusion Matrix

Confusion Matrix menampilkan matriks $N \times N$ untuk model klasifikasi dengan N kelas. Matriks ini terdiri dari empat nilai utama :

- a. *True Positives (TP)* : Jumlah sampel kelas positif yang diklasifikasi dengan benar.
- b. *True Negatives (TN)* : Jumlah sampel kelas negatif yang diklasifikasikan dengan benar.
- c. *False Positive (FP)* : Jumlah sampel kelas negatif yang diklasifikasikan sebagai positif secara salah (*error*).
- d. *False Negatives (FN)* : Jumlah sampel kelas positif yang diklasifikasikan sebagai negatif secara salah (*error*).

3.8.2 Classification Report

Classification Report memberikan ringkasan metrik performa untuk setiap kelas dalam model klasifikasi. Biasanya, *Classification Report* mencakup nilai *Precision*, *Recall*, *F1-Score* dan *Support* untuk masing – masing kelas (Irfansyah dkk., 2021).

1. Precision

Precision adalah proporsi prediksi positif yang benar dari semua prediksi positif yang dibuat oleh model. *Precision* tinggi menunjukkan bahwa model memiliki sedikit *False Positives*.

$$\text{Presisi} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{False Positives (FP)}} \quad (3.1)$$

2. Recall

Recall, juga dikenal sebagai *sensitivity* atau *True Positive Rate (TPR)*, mengukur proporsi sampel kelas positif yang diklasifikasikan dengan benar. *Recall* tinggi berarti sedikit *False Negatives*.

$$\text{Recall} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{False Negatives (FN)}} \quad (3.2)$$

3. F1-Score

F1-Score adalah rata – rata harmonik dari *Precision* dan *Recall*, memberikan keseimbangan antara kedua metrik ini. *F1-Score* sangat berguna ketika distribusi kelas tak seimbang.

$$F1 - \text{Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{recall}} \quad (3.3)$$

4. Support

Support adalah jumlah sampel aktual yang ada di setiap kelas. Ini digunakan untuk menunjukkan distribusi data dalam setiap kelas dan membantu dalam intepretasi metrik lainnya.

3.8.3 ROC Curve

ROC Curve (Receiver Operating Characteristic) adalah grafik yang menunjukkan kemampuan model klasifikasi dalam membedakan antara kelas positif dan negatif pada berbagai ambang keputusan. *ROC Curve* sangat berguna untuk evaluasi model biner atau multi-kelas (dengan perhitungan *One-vs-Rest* untuk setiap kelas) (Abdelmula dkk., 2024)

1. Defenisi ROC Curve

ROC Curve memplot *True Positive Rate (TPR)* (alias *recall* atau *Sensitivity*) melawan *False Positive Rate (FPR)* pada berbagai ambang keputusan. *FPR* dihitung sebagai berikut.

$$\text{False Positive Rate (FPR)} = \frac{\text{False Positives (FP)}}{\text{False positive (FP)} + \text{True Negatives (TN)}} \quad (3.4)$$

2. Area Under the Curve (AUC)

Salah satu indikator utama yang dihasilkan dari *ROC Curve* adalah *Area Under the Curve (AUC)*. *AUC* mengukur kemampuan model dalam membedakan antara kelas. Nilai *AUC* berkisar dari 0 hingga 1, dengan :

- $AUC = 1$: Model Sempurna
- $AUC = 0.5$: Model tidak lebih baik dari tebak – tebakan acak.
- $AUC < 0.5$: Model terbalik, di mana ia mengklasifikasikan positif

sebagai negatif dan sebaliknya.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini menunjukkan bahwa integrasi *CBAM* pada model *Xception* mampu meningkatkan akurasi dalam klasifikasi penyakit daun tebu. Hasil evaluasi menunjukkan akurasi validasi sebesar 92.89%, dengan nilai rata – rata *precision*, *recall* dan *f1-score* sebesar 93%. Model memiliki performa terbaik pada kategori *rust* dengan *precision* 98% dan *recall* sempurna 100%. Namun, pada kategori *yellow*, *precision* lebih rendah (83%), mengindikasikan bahwa model masih memerlukan peningkatan dalam mengenali fitur yang lebih kompleks atau mirip antar kategori. Disarankan untuk mengoptimalkan efisiensi komputasi dengan menerapkan group convolution pada setiap lapisan konvolusi dalam arsitektur *Xception* yang diintegrasikan *CBAM*. Penelitian ini memiliki manfaat signifikan dalam pengembangan sistem klasifikasi penyakit tanaman berbasis *CNN* yang dapat membantu petani mendeteksi penyakit secara otomatis dan lebih cepat. Sistem ini berpotensi meningkatkan efisiensi pengelolaan tanaman dan mengurangi kerugian akibat penyakit daun.

5.2 Saran

CBAM membutuhkan waktu yang relatif lama untuk memodelkan arsitektur *Xception*, terutama karena kompleksitas perhitungan pada setiap lapisan konvolusinya. Mengoptimalkan penerapan *CBAM* dengan menggunakan group convolution pada setiap lapisan konvolusi dalam arsitektur *Xception* dapat

meningkatkan efisiensi komputasi dan mempercepat waktu pelatihan. Pendekatan ini dapat mengurangi jumlah parameter yang dihitung sekaligus mempertahankan kemampuan ekstraksi fitur, sehingga mempercepat proses pemodelan tanpa mengorbankan kinerja model dalam tugas klasifikasi.



DAFTAR PUSTAKA

- Abdelmula, A. M., Mirzaei, O., Güler, E., & Süer, K. (2024). *Assessment of Deep Learning Models for Cutaneous Leishmania Parasite Diagnosis Using Microscopic Images*. *Diagnostics*, 14(1). <https://doi.org/10.3390/diagnostics14010012>
- Amrulloh, M. F., Pamungkas, D. P., & Xception. (2024). *Klasifikasi Penyakit Daun Bawang Menggunakan Algoritma CNN Xception* Penulis Korespondensi. Dalam Agustus (Vol. 8). Online.
- Anang, M., Rohman, F., Muhammad Akbar, H., Diastama, A., Firdaus, A., & Prasetyo, H. (2023). *AGU-NET: Attention Ghost U-Net Untuk Segmentasi Penyakit Polip Berbasis Citra Biomedis*.
- Antika, L., Siwi, P., & Ingesti, V. R. (2020). ANALISIS LAMA WAKTU PANGKAL BATANG TEBU (*Saccharum officinarum* L.) TERTINGGAL DI LAHAN TERHADAP NILAI RENDEMEN. Dalam *Jurnal Ilmu Pertanian Tropika dan Subtropika* (Vol. 5, Nomor 1).
- Carnegie, J. O., Prabowo, A. R., Budiana, E. P., & Singgih, I. K. (2022). Essential Oil Plants Image Classification Using Xception Model. *Procedia Computer Science*, 204, 395–402. <https://doi.org/10.1016/j.procs.2022.08.048>
- Chollet. (2017). *Xception: Deep Learning with Depthwise Separable Convolutions*.
- Davis, M., & Shekaramiz, M. (2023). Desert/Forest Fire Detection Using Machine/Deep Learning Techniques. *Fire*, 6(11). <https://doi.org/10.3390/fire6110418>
- Fitriya, Z. N., Budi, S., & Lailiyah, W. N. (2024). *KERAGAMAN PERTUMBUHAN DAN DAYA TAHAN SERANGAN LUKA API, BLENDOK DAN MOSAIK BERGARIS PADA BEBERAPA KLON UNGGUL HARAPAN TANAMAN TEBU DI MEDIA POLLYBAG DIVERSITY OF GROWTH AND RESISTANCE TO FIRE WOUND, BLEND AND STRIPED MOSAIC ON SOME SUPERIOR CLONES OF HOPE SUGAR SUGAR CANE IN POLLYBAG MEDIA*.
- Gong, J., Luo, S., Yu, W., & Nie, L. (2024). Structure-Guided Image Inpainting Based on Multi-Scale Attention Pyramid Network. *Applied Sciences (Switzerland)*, 14(18). <https://doi.org/10.3390/app14188325>
- Hatcher, W. G., & Yu, W. (2018). A Survey of Deep Learning: Platforms, Applications and Emerging Research Trends. *IEEE Access*, 6, 24411–24432. <https://doi.org/10.1109/ACCESS.2018.2830661>
- He, C., Yasenjiang, J., Lv, L., Xu, L., & Lan, Z. (2024). Gearbox Fault Diagnosis Based on MSCNN-LSTM-CBAM-SE. *Sensors*, 24(14). <https://doi.org/10.3390/s24144682>

- Hidayah, N. (2020). Peluang Pengembangan Pengendalian Penyakit Luka Api pada Tebu di Indonesia. *Buletin Tanaman Tembakau, Serat & Minyak Industri*, 12(2), 94. <https://doi.org/10.21082/btsm.v12n2.2020.94-108>
- Hitimana, E., Kuradusenge, M., Sinayobye, O. J., Ufitinema, C., Mukamugema, J., Murangira, T., Masabo, E., Rwibasira, P., Ingabire, D. A., Niyonzima, S., Bajpai, G., Mvuyekure, S. M., & Ngabonziza, J. (2024). Revolutionizing Coffee Farming: A Mobile App with GPS-Enabled Reporting for Rapid and Accurate On-Site Detection of Coffee Leaf Diseases Using Integrated Deep Learning. *Software*, 3(2), 146–168. <https://doi.org/10.3390/software3020007>
- Hridoy, R. H., Akter, F., & Afroz, M. (2021). An Efficient Computer Vision Approach for Rapid Recognition of Poisonous Plants by Classifying Leaf Images using Transfer Learning. *2021 12th International Conference on Computing Communication and Networking Technologies, ICCCNT 2021*. <https://doi.org/10.1109/ICCCNT51525.2021.9580011>
- Irfansyah, D., Mustikasari, M., Suroso, A., Sistem Informasi Bisnis, J., Ilmu Komputer dan Teknologi Informasi, F., Gunadarma, U., Sistem Informasi, J., Bani Saleh, S., Margonda Raya No, J., Depok, B., & Hasibuan No, J. M. (2021). *Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi*. 6(2). <https://data.mendeley.com/datasets/c5yvn32dzg/2>.
- Islam, N., Jony, M. M. H., Hasan, E., Sutradhar, S., Rahman, A., & Islam, M. M. (2023). Toward Lightweight Diabetic Retinopathy Classification: A Knowledge Distillation Approach for Resource-Constrained Settings. *Applied Sciences (Switzerland)*, 13(22). <https://doi.org/10.3390/app132212397>
- Karakan, A. (2024). Potato Beetle Detection with Real-Time and Deep Learning. *Processes*, 12(9). <https://doi.org/10.3390/pr12092038>
- Kumara, C. T., Pushpakumari, S. C., Udhyani, A. J., Aashiq, M., Rajendran, H., & Kumara, C. W. (2023). Image Enhancement CNN Approach to COVID-19 Detection Using Chest X-ray Images †. *Engineering Proceedings*, 55(1). <https://doi.org/10.3390/engproc2023055045>
- Lebdo Pratitis, W., Al Fata, H., & CNN; (2023). *Classification of Spotted Disease on Sugarcane Leaf Image Using Convolutional Neural Network Algorithm*. <https://doi.org/10.32503/jtecs.v3i1.3433>
- Li, S., Yu, J., & Wang, H. (2023). Damages Detection of Aeroengine Blades via Deep Learning Algorithms. *IEEE Transactions on Instrumentation and Measurement*, 72. <https://doi.org/10.1109/TIM.2023.3249247>
- Liu, H., Hu, Q., & Huang, D. (2024). Research on the Wild Mushroom Recognition Method Based on Transformer and the Multi-Scale Feature Fusion Compact Bilinear Neural Network. *Agriculture (Switzerland)*, 14(9). <https://doi.org/10.3390/agriculture14091618>

- Liu, Z. Q., Hu, Z. J., Wu, T. Q., Ye, G. X., Tang, Y. L., Zeng, Z. H., Ouyang, Z. M., & Li, Y. Z. (2023). Bone age recognition based on mask R-CNN using xception regression model. *Frontiers in Physiology*, 14. <https://doi.org/10.3389/fphys.2023.1062034>
- Liu, Z., Shen, Z., Li, S., Helwegen, K., Huang, D., & Cheng, K.-T. (2021). *How Do Adam and Training Strategies Help BNNs Optimization?*
- Luo, Y., Yang, Y., Kang, S., Tian, X., Liu, S., & Sun, F. (2024). Wind Turbine Bearing Failure Diagnosis Using Multi-Scale Feature Extraction and Residual Neural Networks with Block Attention. *Actuators*, 13(10), 401. <https://doi.org/10.3390/act13100401>
- Mehmood, A., Gulzar, Y., Ilyas, Q. M., Jabbari, A., Ahmad, M., & Iqbal, S. (2023). SBXception: A Shallower and Broader Xception Architecture for Efficient Classification of Skin Lesions. *Cancers*, 15(14). <https://doi.org/10.3390/cancers15143604>
- Purwono, P., Wirasto, A., & Nisa, K. (2021). Comparison of Machine Learning Algorithms for Classification of Drug Groups. *SISFOTENIKA*, 11(2), 196. <https://doi.org/10.30700/jst.v11i2.1134>
- Ratnasari, E. K., Ginardi, R. V. H., Fatichah, C., Teknologi, I., & Nopember, S. (2024). *PENGENALAN PENYAKIT NODA PADA CITRA DAUN TEBU BERDASARKAN CIRI TEKSTUR FRACTAL DIMENSION CO-OCCURRENCE MATRIX DAN $L^a * b^b$ COLOR MOMENTS*.
- Soeroso, N. N., Ananda, F. R., Samosir, G., Hariman, H., & Eyanoer, P. C. (2021). The correlation between hemostatic parameters and mortality rate in patients with non-small cell lung cancer. *Hematology Reports*, 13(3). <https://doi.org/10.4081/hr.2021.8361>
- Sun, C., Zhou, X., Zhang, M., & Qin, A. (2023). SE-VisionTransformer: Hybrid Network for Diagnosing Sugarcane Leaf Diseases Based on Attention Mechanism. *Sensors (Basel, Switzerland)*, 23(20). <https://doi.org/10.3390/s23208529>
- Syech Ahmad, M. T. A., & Sugiarto, B. (2023). Implementasi Convolutional Neural Network (CNN) untuk Klasifikasi Ikan Cupang Berbasis Mobile. *Digital Transformation Technology*, 3(2), 712–723. <https://doi.org/10.47709/digitech.v3i2.3245>
- Tan, X., Wang, D., Xu, M., Chen, J., & Wu, S. (2024). Efficient Multi-View Graph Convolutional Network with Self-Attention for Multi-Class Motor Imagery Decoding. *Bioengineering*, 11(9). <https://doi.org/10.3390/bioengineering11090926>
- Topan Adib Amrulloh, I., Nurina Sari, B., Nur Padilah Informatika, T., Singaperbangsa Karawang, U., HSRonggo Waluyo, J., Telukjambe Timur, K.,


Karawang, K., & Barat, J. (2024). EVALUASI AUGMENTASI DATA PADA DETEKSI PENYAKIT DAUN TEBU DENGAN YOLOV8. Dalam *Jurnal Mahasiswa Teknik Informatika* (Vol. 8, Nomor 4).

Wahid, M. I., Lawi, A., Muh, D. A., & Siddik, A. (2022). Perbandingan Kinerja Model Ensembled Transfer Learning Pada Klasifikasi Penyakit Daun Tomat. *Prosiding Seminar Nasional Teknik Elektro dan Informatika (SNTEI) 2022 – Teknik Informatika*.

Xie, F., Fan, Q., Li, G., Wang, Y., Sun, E., & Zhou, S. (2024). Motor Fault Diagnosis Based on Convolutional Block Attention Module-Xception Lightweight Neural Network. *Entropy*, 26(9). <https://doi.org/10.3390/e26090810>

Yulianti, T., Penelitian, B., Pemanis, T., & Serat, D. (2020). *STATUS DAN STRATEGI TEKNOLOGI PENGENDALIAN PENYAKIT UTAMA TEBU DI INDONESIA Status and Control Strategy of Important Sugarcane Diseases In Indonesia*. 19(1), 1–16. <https://doi.org/10.21082/psp.v19n1.2020>

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





Sisilia_Deodora_Sitepu_Skripsi-1738384677384

ORIGINALITY REPORT

20%

SIMILARITY INDEX

15%

INTERNET SOURCES

11%

PUBLICATIONS

10%

STUDENT PAPERS

PRIMARY SOURCES

1

repositories.uma.ac.id

Internet Source

6%

2

ahmadprayudi.blog.uma.ac.id

Internet Source

1%

3

Monica Tiara Gunawan, Jeane Yosefa Tine, Chatarina Enny Murwaningtyas. "Model decision tree untuk prediksi prestasi akademik matematika siswa kelas VIII SMP Frater Don Bosco Manado", Jurnal Pendidikan Informatika dan Sains, 2024

Publication

1%

4

Submitted to Universitas Brawijaya

Student Paper

1%

5

jurnal.penerbitdaarulhuda.my.id

Internet Source

1%

6

sisformik.atim.ac.id

Internet Source

<1%

7

Submitted to Sriwijaya University

Student Paper

<1%

```

pip install tensorflow
pip show tensorflow
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.layers import Dense, GlobalAveragePooling2D, Conv2D, Multiply,
Reshape, GlobalMaxPooling2D, Input, Concatenate, Lambda
from tensorflow.keras.applications import Xception
from tensorflow.keras.models import Model
from tensorflow.keras.optimizers import Adam
from sklearn.metrics import classification_report, confusion_matrix,
precision_recall_fscore_support
import matplotlib.pyplot as plt
import numpy as np
import seaborn as sns
import time
# Fungsi Channel Attention
def channel_attention(input_feature, ratio=8):
    channel = input_feature.shape[-1]
    # Global Average Pooling
    avg_pool = GlobalAveragePooling2D()(input_feature)
    avg_pool = Dense(channel // ratio, activation='relu')(avg_pool)
    avg_pool = Dense(channel, activation='sigmoid')(avg_pool)
    # Global Max Pooling
    max_pool = GlobalMaxPooling2D()(input_feature)
    max_pool = Dense(channel // ratio, activation='relu')(max_pool)
    max_pool = Dense(channel, activation='sigmoid')(max_pool)
    # Menggabungkan hasil pooling
    combined = tf.keras.layers.Add()([avg_pool, max_pool])
    combined = Reshape((1, 1, channel))(combined)
    # Perkalian antara fitur input dan attention
    return Multiply()([input_feature, combined])
# Fungsi Spatial Attention
def spatial_attention(input_feature):
    avg_pool = Lambda(lambda x: tf.reduce_mean(x, axis=-1, keepdims=True))(input_feature)
    max_pool = Lambda(lambda x: tf.reduce_max(x, axis=-1, keepdims=True))(input_feature)
    concat = Concatenate(axis=-1)([avg_pool, max_pool])
    attention_feature = Conv2D(1, (7, 7), padding='same', activation='sigmoid')(concat)
    return Multiply()([input_feature, attention_feature])
# CBAM Block (Gabungan Channel dan Spatial Attention)
def cbam_block(input_feature):
    attention_feature = channel_attention(input_feature)
    attention_feature = spatial_attention(attention_feature)
    return attention_feature
# Konfigurasi direktori dataset
train_dir = 'D:/StudyOnline/SKSI/Coding/new/Dauntebu/train'
val_dir = 'D:/StudyOnline/SKSI/Coding/new/Dauntebu/validation'
test_dir = 'D:/StudyOnline/SKSI/Coding/new/Dauntebu/test'
# Parameter pelatihan
IMG_SIZE = (299, 299)
BATCH_SIZE = 32
EPOCHS = 20
NUM_CLASSES = 5
# Preprocessing dan augmentasi data
train_datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=20,
    width_shift_range=0.2,

```

```

        height_shift_range=0.2,
        shear_range=0.2,
        zoom_range=0.2,
        horizontal_flip=True,
        fill_mode='nearest'
    )
    val_test_datagen = ImageDataGenerator(rescale=1./255)
    train_generator = train_datagen.flow_from_directory(
        train_dir,
        target_size=IMG_SIZE,
        batch_size=BATCH_SIZE,
        class_mode='categorical'
    )
    val_generator = val_test_datagen.flow_from_directory(
        val_dir,
        target_size=IMG_SIZE,
        batch_size=BATCH_SIZE,
        class_mode='categorical'
    )
    test_generator = val_test_datagen.flow_from_directory(
        test_dir,
        target_size=IMG_SIZE,
        batch_size=BATCH_SIZE,
        class_mode='categorical',
        shuffle=False
    )
    # Load model Xception dengan pre-trained weights dari ImageNet
    base_model = Xception(weights='imagenet', include_top=False, input_shape=(299, 299, 3))
    # Membekukan sebagian layer awal
    for layer in base_model.layers[:60]: # Membekukan hanya layer awal
        layer.trainable = False
    # Menambahkan CBAM di Entry Flow, Middle Flow, dan Exit Flow
    def apply_cbam_block(input_tensor):
        x = channel_attention(input_tensor)
        x = spatial_attention(x)
        return x
    x = base_model.get_layer('block1_conv2_act').output
    x = apply_cbam_block(x)
    # Middle Flow dengan CBAM di titik tertentu
    for i in range(3, 11):
        layer_name = f'block{i}_sepconv2_act' # Penempatan CBAM pada layer ini
        x = base_model.get_layer(layer_name).output
        x = apply_cbam_block(x)
    # Exit Flow dengan CBAM
    x = base_model.get_layer('block14_sepconv2_act').output
    x = apply_cbam_block(x)
    # Tambahkan Global Average Pooling dan Dense layer
    x = GlobalAveragePooling2D()(x)
    x = Dense(1024, activation='relu')(x)
    predictions = Dense(NUM_CLASSES, activation='softmax')(x)
    # Membuat model akhir
    model = Model(inputs=base_model.input, outputs=predictions)
    # Compile model
    model.compile(optimizer=Adam(learning_rate=0.0001),
                  loss='categorical_crossentropy',
                  metrics=['accuracy'])

```



UNIVERSITAS MEDAN AREA

FAKULTAS TEKNIK

Kampus I : Jalan Kolam Nomor 1 Medan Estate / Jalan Gedung PBSI, Medan 20223

Kampus II : Jalan Sei Serayu Nomor 70 A / Jalan Setia Budi Nomor 79 B, Medan 20112 Telepon : (061) 8225602, 8201994

Fax : (061) 8226331 HP : 0811 607 259 website: www.uma.ac.id Email : univ_medanarea@uma.ac.id

Nomor : 2626/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 : SISILIA DEODORA SITEPU

NIM : 218160017

Jurusan : TEKNIK INFORMATIKA

Maka dengan hormat kami mengharapkan kesediaan saudara :

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

Adapun Tugas Akhir Skripsi berjudul :

Penerapan CBAM Pada Xception Untuk Klasifikasi Penyakit Daun Tebu

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. Supriatno.ST, MT.

Kampus I : Jalan Kolam Nomor 1 Medan Estate, Jalan PBSI Nomor 1 ☎ (061) 7366878, 7360168, 7364348, 7365781, Fax: (061) 7366908 Medan 20222
Kampus II : Jalan Setiabudi Nomor 79 / Jalan Sei Serayu Nomor 70 A, ☎ (061) 8225602, Fax: (061) 8226331 Medan 20122
Website: www.teknik.uma.ac.id E-mail: univ_medanarea@uma.ac.id

Nomor : 436 /FT.6/01.10/XI/2024
Lamp : -
Hal : **Penelitian Dan Pengambilan Data Tugas Akhir**

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

NO	N A M A	N P M	PRODI
1	Sisilia Deodora Sitepu	218160017	Teknik Informatika

Atas perhatian dan kerja sama yang baik diucapkan terima kasih.

Dr. Eng. Supriatno,

Tembusan :

1. Ka. BPMPP
2. Mahasiswa
3. File



UNIVERSITAS MEDAN AREA

Kampus I : Jalan Kolam Nomor 1 Medan Estate ☎ (061) 7360168, Medan 20223
Kampus II : Jalan Setiabudi Nomor 79 / Jalan Sei Serayu Nomor 70 A ☎ (061) 42402994, Medan 20122
Website: www.uma.ac.id E-Mail: univ_medanarea@uma.ac.id

SURAT KETERANGAN Nomor : 1831/UMA/B/01.7/X/2024

Rektor Universitas Medan Area dengan ini menerangkan bahwa :

Nama : Sisilia Deodora Sitepu
No Pokok Mahasiswa : 218160017
Program Studi : Teknik Informatika

Benar telah selesai Pengambilan Data di Laboratorium Komputer Program Studi Teknik Informatika Fakultas Teknik Universitas Medan Area dengan Judul Skripsi "**Penerapan CBAM pada Xception untuk Klasifikasi Penyakit Daun Tebu**".

Dan kami harapkan Data tersebut kiranya dapat membantu yang bersangkutan dalam penyusunan Skripsi dan dapat bermanfaat bagi mahasiswa khususnya Fakultas Psikologi Universitas Medan Area.

Demikian surat ini diterbitkan untuk dapat digunakan seperlunya

Medan, 11 Desember 2024
an R e k t o r
Wakil Rektor Bidang Mutu SDM &
Perekonomian


Dr. Badi Sahputra, S.Sos, MA

CC :
- Arsip