

Klasifikasi Penyakit Daun Kelapa Menggunakan Xception Pada Data Imbalanced Dengan Smote

Muhammad Totti Alfarabi¹, Daniel Udjulawa²

^{1,2}Program Studi Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

Email : tottialfarabi@mhs.mdp.ac.id, daniel@mdp.ac.id

Article Information

Article history

Received 3 April 2026

Revised 20 May 2026

Accepted 8 June 2026

Available 11 June 2026

Keywords

Xception

SMOTE

Coconut Leaf Disease

Image Classification

Imbalanced Data

Corresponding Author:

Muhammad Totti Alfarabi,
Universitas Multi Data Palembang,
Email :

tottialfarabi@mhs.mdp.ac.id

Abstract

The decline in coconut production due to Weligama Coconut Leaf Wilt Disease (WCLWD) and Coconut Caterpillar Infestation (CCI) can be detected using deep learning. However, previous studies have largely ignored extreme data imbalance ratios, leaving models vulnerable to pseudo-accuracy and failure in recognizing minority classes. Furthermore, no existing studies on coconut disease classification have specifically evaluated model robustness against visual anomalies and background bias. To fill this gap, this study not only integrates the Xception architecture with the SMOTE oversampling technique to overcome imbalanced data but also conducts comprehensive stress testing. Using 5,139 images distributed in a 70:15:15 ratio, SMOTE was specifically applied to the training data. The model was optimized using a 299x299 resolution, a learning rate of 0.00001, and a 0.5 Dropout layer. Testing demonstrated optimal results with an overall accuracy of 99%. The implementation of SMOTE successfully handled data imbalance without sacrificing the sensitivity of the minority class (healthy leaves), evidenced by a 0.95 Recall and 0.82 F1-Score. Moreover, as a novel evaluation, testing using anomalous Out-of-Distribution images revealed a background bias in the CCI class. Nevertheless, the low predictive confidence level (43.06%) confirms that the model's regularization effectively prevents overconfident predictions and optimally calibrates visual uncertainty.

Keywords : *Xception, SMOTE, Coconut Leaf Disease, Image Classification, Imbalanced Data*

Abstrak

Penurunan produksi kelapa akibat infeksi Weligama Coconut Leaf Wilt Disease (WCLWD) dan Coconut Caterpillar Infestation (CCI) dapat dideteksi menggunakan deep learning. Namun, berbagai penelitian terdahulu umumnya mengabaikan rasio ketimpangan data yang ekstrem, sehingga model rentan mengalami pseudo-accuracy dan gagal mengenali kelas minoritas. Selain itu, belum ada studi klasifikasi penyakit kelapa yang secara spesifik mengevaluasi batas ketahanan (robustness) model terhadap anomali visual. Untuk mengisi celah tersebut, penelitian ini tidak hanya mengintegrasikan arsitektur Xception dengan teknik oversampling SMOTE untuk mengatasi imbalanced data, tetapi juga melakukan pengujian stress-testing secara komprehensif. Menggunakan 5.139 citra dengan rasio 70:15:15, SMOTE diaplikasikan secara spesifik pada data latih. Model dioptimalkan dengan resolusi 299x299, learning rate 0.00001, dan Dropout 0.5. Pengujian menunjukkan hasil optimal dengan akurasi 99%. Implementasi SMOTE terbukti sukses menangani ketimpangan tanpa mengorbankan sensitivitas kelas minoritas (daun sehat), dibuktikan dari Recall 0.95 dan F1-Score 0.82. Lebih lanjut, sebagai evaluasi kebaruan, pengujian menggunakan citra anomali di luar distribusi (Out-of-Distribution) menyingkap adanya background bias pada kelas CCI. Kendati demikian, tingkat confidence yang rendah (43,06%) mengonfirmasi bahwa regularisasi model efektif mencegah prediksi yang overconfident dan mampu mengkalibrasi ketidakpastian visual secara optimal.

Kata Kunci : *Xception, SMOTE, Penyakit Daun Kelapa, Klasifikasi Citra, Imbalanced Data*

Copyright©2026 Muhammad Totti Alfarabi, Daniel Udjulawa
This is an open access article under the [CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/) license.



1. Pendahuluan

Permintaan global yang tinggi terhadap produk kelapa Indonesia menjadikan komoditas tersebut sebagai salah satu penyumbang devisa penting di mana kelapa menempati posisi keempat sebagai komoditas perkebunan penyumbang devisa terbesar, setelah kelapa sawit, karet dan kakao. Berdasarkan data Pusat Data dan Sistem Informasi Pertanian, Sekretariat Jenderal Kementerian Pertanian, produksi kelapa di Indonesia selama periode 2016 sampai 2025 terus mengalami penurunan sebesar 0,22% per tahunnya dan diperkirakan produksi kelapa di Indonesia diproyeksikan relatif stagnan hingga tahun 2028 (Wiratno, 2025). Menurunnya produksi kelapa dapat disebabkan oleh beberapa faktor, salah satunya adalah serangan hama dan penyakit pada tanaman kelapa, terutama pada bagian daunnya. Kerusakan signifikan pada pohon kelapa berdampak pada hasil panen dan finansial petani, sehingga deteksi dini berbasis teknologi sangat penting untuk penanggulangan (Gopalakrishna & Lingaraju, 2025).

Pada bidang *computer vision*, terdapat beberapa metode dapat digunakan untuk membantu dalam mendeteksi dini penyakit pada daun kelapa. *Computer Vision* adalah proses ekstraksi otomatis informasi dari gambar. Informasi ini dapat mencakup informasi tentang model 3D, posisi kamera, deteksi dan pengenalan objek, serta pengelompokan dan pencarian konten gambar. Bagaimana membuat komputer dapat memahami gambar digital dan data visual dari dunia nyata adalah inti dari fungsi *Computer Vision* (Arnita dkk., 2022). Salah satu metode *computer vision* adalah *Xception (Extreme version of Inception)*. *Xception* adalah arsitektur deep learning berbasis depthwise separable convolutions yang efektif untuk klasifikasi citra. Hal ini dibuktikan melalui studi yang dilakukan oleh Saleem dkk. (2020) dalam membandingkan 18 arsitektur *deep learning* (termasuk *Xception*) untuk klasifikasi penyakit pada beberapa tanaman, dan *Xception* menunjukkan performa terbaik dengan akurasi 99,9% dan *F1-score* sekitar 97,65% serta *precision* dan *recall* 97%. Penelitian ini juga membandingkan beberapa optimizer (*SGD*, *Adagrad*, *RMSProp*, *Adadelta*, *Adamax*, dan *Adam*) untuk *Xception* dan menemukan *Xception* dengan *Adam* memberikan performa terbaik dengan *F1-score* tertinggi (99,78%). *Adam* menggabungkan kekuatan *Adagrad* dan *RMSProp* dengan menghitung momen pertama dan kedua gradien serta memanfaatkan informasi gradien sebelumnya untuk mempercepat konvergensi (Saleem dkk., 2020). Penelitian tersebut membuktikan bahwa kombinasi *Xception* dengan optimizer *ADAM* sangat sesuai untuk tugas klasifikasi penyakit daun tanaman pada dataset besar seperti *PlantVillage*.

Dataset yang digunakan adalah dataset citra daun kelapa yang diperoleh melalui *Kaggle* dengan judul “*Coconut Diseases and Pest Infestations*” dengan total citra sebanyak 5139 dengan 3 kategori utama yaitu *WCLWD (Weligama Coconut Leaf Wilt Disease)*, *CCI (Coconut Caterpillar Infestation)*, dan sehat (*Healthy*). Namun, *dataset* citra penyakit daun kelapa yang digunakan tidak seimbang, di mana sebagian besar sampel didominasi oleh kelas *WCLWD* sementara kelas sehat dan *CCI* relatif minoritas. Di mana menurut

Kurniawan & Salam (2024), *imbalanced* ini berisiko membuat model mengalami bias ke kelas mayoritas sehingga menghasilkan prediksi yang *skewed* di mana Alih-alih mempertahankan distribusi ideal yang seragam pada setiap kelas, nilai target tertentu memiliki jumlah observasi yang jauh lebih sedikit sehingga menurunkan *recall* dan F1 pada kelas minoritas, serta memicu *overfitting* terhadap pola mayoritas (Kurniawan & Salam, 2024; Naik dkk., 2025).

Berdasarkan latar belakang tersebut, penelitian terdahulu umumnya mengabaikan rasio ketimpangan data yang ekstrem, sehingga model rentan mengalami pseudo-accuracy dan gagal mengenali kelas minoritas (Vidhanaarachchi dkk., 2025). Selain itu, belum ada studi klasifikasi penyakit kelapa yang secara spesifik mengevaluasi batas ketahanan (*robustness*) model terhadap anomali visual. Oleh karena itu, penelitian ini mengisi celah (*research gap*) tersebut dengan mengintegrasikan kekuatan arsitektur *Xception* dan teknik *oversampling SMOTE* untuk memastikan sistem klasifikasi *WCLWD* dan *CCI* yang dibangun tidak bias terhadap kelas mayoritas. Sehingga rumusan masalah yang dapat diangkat adalah bagaimana algoritma *Xception* dapat diterapkan untuk mengklasifikasikan penyakit daun kelapa pada dataset tidak seimbang dengan bantuan *SMOTE*. Dengan tujuan mengimplementasikan kombinasi *Xception* dan *SMOTE* untuk menghasilkan sistem klasifikasi *WCLWD* dan *CCI* yang lebih akurat dan tahan terhadap ketidakseimbangan data.

Dengan adanya penelitian ini, diharapkan memahami bagaimana cara menerapkan algoritma *Xception* (*Extreme version of Inception*) dalam mendeteksi penyakit pada daun kelapa. Kemudian dapat menyediakan bukti nyata tentang efektivitas performa algoritma *Xception* dalam klasifikasi citra penyakit pada daun kelapa serta, dapat berkontribusi sebagai referensi pada penelitian berbasis *Computer Vision* tentang klasifikasi jenis penyakit daun berdasarkan citra pada daun kelapa menggunakan algoritma *Xception*. Ruang lingkup penelitian difokuskan murni pada evaluasi kinerja model arsitektur (*backend*) tanpa pengembangan antarmuka aplikasi, dengan menggunakan 5.139 dataset citra dari platform *Kaggle* yang terdiri dari kelas *WCLWD*, *CCI*, dan Daun Sehat (*Healthy*). Metodologi yang digunakan disusun secara sistematis, meliputi tahapan *pre-processing* (penyesuaian ukuran citra menjadi 299x299 piksel dan augmentasi), pembagian rasio data latih, uji, dan validasi sebesar 70:15:15, penerapan *SMOTE* spesifik pada himpunan data latih, hingga proses pengujian performa. Hasil pengujian dievaluasi menggunakan instrumen confusion matrix melalui metrik akurasi, *precision*, *recall*, dan *F1-score*, dengan harapan penelitian ini dapat menjadi referensi yang valid dalam pengembangan sistem deteksi penyakit tanaman di masa depan.

2. Kajian Terdahulu

Berbagai penelitian terdahulu telah membuktikan keandalan *deep learning* dalam mendeteksi penyakit dan hama, khususnya pada tanaman kelapa. Pada tahap awal perkembangannya, Nesarajan dkk. (2020) mengombinasikan pemrosesan citra dengan *SVM* dan arsitektur *CNN* (*EfficientNetB0*) untuk membangun sistem prediksi penyakit kelapa, yang masing-masing mencapai akurasi 93,54% dan 93,72% (Nesarajan dkk., 2020). Pendekatan pemrosesan citra juga diterapkan oleh Kavithamani & UmaMaheswari (2023) yang memanfaatkan *VGG-16* dan *Deep Convolutional Neural Network* (*DCNN*) untuk mendeteksi hama kutu kebul (*whitefly*) menggunakan citra drone (Kavithamani & UmaMaheswari, 2023). Optimalisasi model kemudian terus dilakukan, seperti halnya penggunaan *EfficientNet-B7* oleh Kabir dkk. (2025) yang sukses mencapai akurasi 99,20%, serta pengembangan *Enhanced Visual Geometry Group 16* (*EVGG16*) oleh Huang dkk. (2025) yang dilengkapi dengan *Batch Normalization* dan *Global Average Pooling* untuk menembus akurasi 97,70% (Huang dkk., 2025; Kabir dkk., 2025). Secara lebih spesifik pada kasus *Weligama Coconut Leaf Wilt Disease* (*WCLWD*) dan *Coconut Caterpillar Infestation* (*CCI*), Vidhanaarachchi dkk. (2025) telah mengujikan berbagai model termasuk *Mask R-CNN* dan keluarga *YOLO*, di mana model *YOLOv5* terbukti memberikan hasil terbaik (*mAP* 96,87%) untuk perhitungan jumlah ulat (Vidhanaarachchi dkk., 2025).

Selain arsitektur di atas, salah satu arsitektur yang relevan untuk digunakan adalah *Xception*. *Xception* merupakan arsitektur *deep learning* yang memperkenalkan blok konvolusi yang lebih dalam bernama *separable convolutions*, yang secara signifikan mengurangi jumlah parameter yang harus dipelajari oleh model, sehingga mempercepat proses pelatihan dan inferensi (Arifin dkk., 2024). Arsitektur *Xception* memiliki 36 lapisan konvolusi yang berfungsi sebagai inti ekstraksi fitur jaringan. Dalam eksperimen klasifikasi gambar, pendekatan yang biasa digunakan adalah dengan memanfaatkan lapisan dasar konvolusi kemudian diikuti oleh *Logistic Regression*. Secara sederhana, arsitektur *Xception* dapat dipandang sebagai susunan linear dari lapisan *depth-separable convolution* yang saling terhubung melalui *residual connections*. Berbeda dengan arsitektur seperti *VGG-16* yang relatif ringkas, implementasi *Xception* melalui framework tingkat tinggi seperti *Keras* atau *TensorFlow-Slim* menawarkan fleksibilitas lebih besar untuk modifikasi arsitektur (Meena dkk., 2024).

Dalam konteks klasifikasi penyakit tanaman, arsitektur *Xception* secara konsisten terbukti superior dibandingkan model *CNN* lainnya. Sebuah studi evaluasi komparatif yang komprehensif oleh Saleem dkk. (2020) terhadap 18 arsitektur *CNN* membuktikan bahwa *Xception* mampu mengungguli model populer seperti *ResNet-50*, *AlexNet*, *VGG-16*, dan *MobileNet* dengan akurasi validasi mencapai 97,8% (Saleem dkk., 2020). Keunggulan kinerja *Xception* ini juga dikonfirmasi oleh Alam dkk. (2024) yang mencatatkan akurasi 99,9% pada penyakit daun tomat, dan oleh Pantha & Koju (2024)

yang mendeteksi penyakit daun apel dengan akurasi 98,3% (Alam dkk., 2024; Pantha & Koju, 2024). Model *Xception* juga sangat fleksibel untuk dikembangkan, Meena dkk. (2024) memodifikasinya menjadi *M-Xception* yang dipadukan dengan *ResNet* untuk mencapai akurasi 99,73% pada tanaman padi, sementara Arifin dkk. (2024) membuktikan efisiensinya menggunakan transfer learning standar untuk deteksi *blight* pada daun tomat (Arifin dkk., 2024; Meena dkk., 2024).


Selain pemeliharaan arsitektur penanganan *imbalance* class juga perlu dilakukan karena dataset yang tidak seimbang secara masif tidak hanya mendegradasi akurasi global, melainkan secara kritis memicu risiko *overfitting* yang parah. Kondisi ini terjadi karena model cenderung menghafal *noise* dan karakteristik dominan dari kelas mayoritas, sehingga gagal melakukan generalisasi saat diuji dengan data baru (Kurniawan & Salam, 2024). Salah satu penanganan data imbalance adalah dengan menggunakan *SMOTE*. *SMOTE* (*Synthetic Minority Over-sampling Technique*) merupakan metode *oversampling* yang digunakan untuk mengatasi masalah *Imbalanced* kelas dalam data. *Imbalanced* terjadi ketika jumlah sampel pada kelas mayoritas jauh lebih banyak dibanding kelas minoritas. Jika kondisi ini tidak ditangani, model akan cenderung bias terhadap kelas mayoritas sehingga kurang sensitif dalam mengenali kasus pada kelas minoritas yang sebenarnya memiliki nilai prediktif penting. Akibatnya, akurasi keseluruhan bisa tampak tinggi, tetapi performa pada kelas minoritas sangat rendah (Pulungan dkk., 2024)

Penelitian terkait penerapan teknik *SMOTE* data pernah dilakukan oleh Pulungan dkk. (2024) menerapkan teknik *SMOTE* untuk mengatasi masalah ketidakseimbangan kelas pada klasifikasi kepribadian *Myers-Briggs Type Indicator* (*MBTI*) berdasarkan data narasi *Twitter*. Hasil akhir menunjukkan bahwa model *Logistic Regression* menghasilkan tingkat akurasi tertinggi sebesar 80% setelah implementasi *SMOTE* (Pulungan dkk., 2024). Penelitian menggunakan *SMOTE* lainnya juga pernah dilakukan oleh Kurniawan & Salam (2024) pada klasifikasi citra medis (*CT-Scan*), mereka memanfaatkan *Feature Space SMOTE* untuk merekayasa keseimbangan distribusi kelas. Hasil pengujian membuktikan bahwa integrasi *SMOTE* mampu memitigasi bias *overfitting* secara signifikan, menghasilkan performa model yang jauh lebih stabil dengan raihan akurasi tertinggi (65,72%) dibandingkan model asli tanpa sampling (53,65%) maupun model yang sekadar mengandalkan augmentasi geometris manual (58,62%) (Kurniawan & Salam, 2024).

3. Metodologi Penelitian

Metode penelitian ini dilakukan melalui tahapan sistematis yang dimulai dari pengumpulan dataset, kemudian dilakukan preprocessing dan augmentasi untuk meningkatkan kualitas serta variasi data. Selanjutnya dataset dibagi menjadi data latih dan data uji agar proses evaluasi lebih objektif. Model *Xception* dipilih sebagai arsitektur utama dan dilatih menggunakan data latih, lalu diuji dengan data uji untuk mengukur

performa. Tahap akhir berupa evaluasi model dilakukan dengan menganalisis hasil pengujian, sehingga dapat menilai tingkat akurasi, generalisasi, serta efektivitas metode yang digunakan dalam mendeteksi pola sesuai tujuan penelitian. Tahapan penelitian secara garis besar dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Metodologi Penelitian

3.1. Pengumpulan Dataset

Pada penelitian ini data yang digunakan berasal dari Kaggle. Kaggle merupakan platform yang berfungsi untuk berbagi dan mengeksplorasi dataset secara open source. Dataset yang digunakan berupa citra daun kelapa yang dibuat oleh Vidhanaarachchi dkk. (2022). Dataset tersebut berisikan 5139 citra daun kelapa yang dibagi menjadi 3 label Besar yaitu, *Healthy*, *Weligama Coconut Leaf Wilt Disease (WCLWD)* dan *Coconut Caterpillar Infestation (CCI)*. Dengan pembagian 1.785 citra untuk kelas *CCI*, 123 citra untuk kelas *Healthy*, dan 3.231 citra untuk kelas *WCLWD*. Keseluruhan 5139 citra akan dibagi menjadi 3 bagian, untuk data latih sebanyak 70%, data uji sebanyak 15% dan data validasi sebanyak 15%.

3.2. Training Model

Pada penelitian ini proses preprocessing akan menggunakan resize dan oversampling dengan *SMOTE*. Resize digunakan untuk mengubah ukuran citra. Ukuran citra akan disesuaikan menjadi 299×299 piksel yang sebelumnya bervariasi. Hal ini

bertujuan untuk menyesuaikan citra dengan ukuran input gambar dari algoritma *Xception* yaitu 299×299 (Masaugi dkk., 2024). Augmentasi data akan dilakukan untuk meningkatkan variasi data yang ada. Dengan tujuan model akan terbiasa dalam mengenali objek dalam berbagai kondisi dan sudut pandang. Augmentasi yang akan dilakukan adalah *flip horizontal*, *flip vertical*, *rotation*, dan *shear*. Contoh hasil citra setelah proses augmentasi dapat dilihat pada Gambar 2.



Gambar 2. Hasil Citra Setelah Proses Augmentasi

3.3. Pembagian Dataset

Setelah tahap augmentasi selesai, data akan dibagi 3 skema percobaan. Data akan dibagi menjadi data latih, data uji dan data validasi dengan rasio pembagian untuk data latih sebanyak 70%, data uji sebanyak 15% dan data validasi sebanyak 15%. Namun pada dataset tersebut masih terjadi imbalanced dikarenakan jumlah data pada kelas *WCLWD*, kelas *CCI*, dan kelas *healthy* memiliki perbedaan yang sangat signifikan. Untuk menangani imbalanced antar kelas, dilakukan *oversampling* dengan menyintesis kelas minoritas agar seimbang dengan menggunakan *SMOTE* (*Synthetic Minority Oversampling Technique*). Pada metode *SMOTE* data yang *imbalanced* diatasi dengan menggunakan library *imbalanced-learn*. Distribusi data yang pada awalnya kelas *Healthy* berjumlah 123, kelas *WCLWD* berjumlah 3.231, dan *CCI* berjumlah 1.785 diseimbangkan menjadi 3.231 tiap kelasnya. Jumlah data training dari Tahap Pre-processing dan augmentasi dapat dilihat pada Tabel 1.

Tabel 1 Jumlah data setelah pre-processing dan augmentasi

	<i>Healthy</i>	<i>WCLWD</i>	<i>CCI</i>
Jumlah Citra	3.231	3.231	3.231
Total		9.693	

3.4. Training Model

Setelah tahap Tahap implementasi dilakukan menggunakan *Kaggle Notebook* sebagai lingkungan komputasi berbasis *cloud*. Bahasa pemrograman yang digunakan adalah *Python* dengan *library TensorFlow/Keras* untuk membangun arsitektur *Xception*. Proses *oversampling* kelas minoritas dilakukan menggunakan algoritma *SMOTE* yang diimplementasikan melalui *library imbalanced-learn*.

3.5. Evaluasi Model

Evaluasi model dilakukan untuk mengevaluasi kinerja *Xception* dalam mendeteksi penyakit pada daun kelapa. Evaluasi mencakup metrik Akurasi, *Precision*, *Recall*, *F1-Score* melalui *confusion matrix* guna memastikan tingkat akurasi dan efektivitas model pada tahap training maupun *testing*. Rumus perhitungan Akurasi, *Precision*, *Recall*, *F1-Score* ditunjukkan pada Persamaan (1), (2), (3), dan (4).

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$

$$\text{Precision} = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

$$\text{F1 - Score} = \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

Keterangan:

TP : Nilai True Positif, prediksi yang benar memang terbukti benar.

TN : Nilai True Negatif, prediksi yang salah memang terbukti salah.

FP : Nilai False Positif, prediksi yang benar namun ternyata salah.

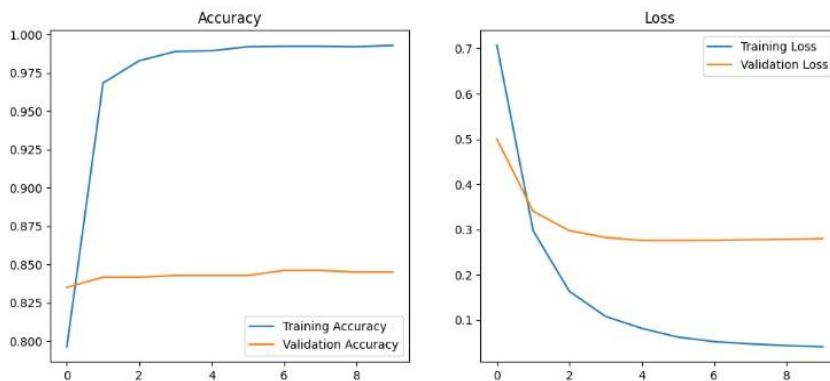
FN : Nilai False Negatif, prediksi yang salah namun ternyata benar.

4. Hasil dan Pembahasan

4.1. Pemodelan dan Analisis Proses Pelatihan

Pelatihan model klasifikasi citra daun kelapa (*Cocos nucifera*) dilakukan menggunakan arsitektur *Xception*. Konfigurasi hyperparameter mencakup resolusi citra masukan 299x299 piksel, tingkat pembelajaran (*learning rate*) 0.00001, nilai Dropout 0.5, serta penggunaan *batch size* berkapasitas 32. Untuk mencegah model mengalami hafalan data yang berlebihan (*overfitting*), mekanisme *Early Stopping* diaktifkan dengan toleransi

(*patience*) 4 *epoch*, di mana proses pelatihan akan otomatis berhenti apabila nilai kerugian validasi (*validation loss*) tidak menunjukkan perbaikan. Sepanjang fasa pelatihan, grafik performa menunjukkan pola yang sangat stabil. *Accuracy* dan *Loss* selama pelatihan dapat dilihat pada Gambar 3.

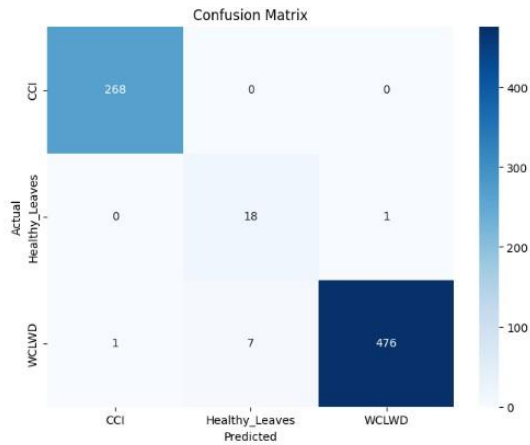


Gambar 3. *Accuracy* dan *Loss* selama pelatihan

Pelatihan Kurva kerugian pelatihan (*Training Loss*) bergerak turun secara bertahap menuju angka nol, sejalan dengan kurva *Validation Loss* yang konstan di kisaran 0.3, membuktikan bahwa model mampu belajar dengan baik tanpa mengalami anomali divergensi.

4.2. Kinerja Model pada Pengujian Data Internal

Tahap pengujian menggunakan kumpulan data uji internal (*testing data*) memperlihatkan kinerja komputasi yang sangat istimewa, dengan pencapaian tingkat akurasi gabungan (*overall accuracy*) menyentuh 99%. Secara spesifik, analisis pada matriks kekeliruan (*Confusion Matrix*) dan laporan klasifikasi menjabarkan tingkat keberhasilan yang tinggi pada tiap kelas. Pada kategori *Caterpillar Choking Injury (CCI)*, model mencetak rasio pengenalan tanpa cacat dengan nilai *Precision*, *Recall*, dan *F1-Score* yang identik di angka 1.00, di mana seluruh 268 citra uji pada kelas ini terklasifikasi dengan akurat. Selanjutnya, performa deteksi untuk kategori *Weligama Coconut Leaf Wilt Disease (WCLWD)* juga sangat optimal, ditandai dengan pencapaian *Precision* 1.00 dan *Recall* 0.98, yang berujung pada nilai *F1-Score* sebesar 0.99. Sementara itu, pada kategori *Healthy Leaves (Daun Sehat)* yang awalnya merupakan kelompok minoritas, model mampu meraih tingkat sensitivitas (*Recall*) sebesar 0.95. Walaupun tingkat presisinya tertahan di angka 0.72 akibat adanya 7 prediksi keliru dari kelas *WCLWD* yang terdeteksi sebagai daun sehat, nilai *F1-Score* akhir tetap berada di level yang solid, yaitu 0.82. Capaian metrik ini secara empiris mengonfirmasi bahwa penerapan *SMOTE* pada tahap pra-pemrosesan sukses besar dalam meningkatkan kepekaan model terhadap sampel minoritas tanpa mengorbankan performa kelas lainnya. *Confussion Matrix* dan Hasil klasifikasi dapat dilihat pada Gambar 4 dan Gambar 5.



Gambar 4. Confussion Matrix

```

Classification Report:
              precision    recall  f1-score   support

   CCI                1.00      1.00      1.00         268
 Healthy_Leaves       0.72      0.95      0.82          19
   WCLWD                1.00      0.98      0.99         484


 accuracy              0.99         771
 macro avg              0.90      0.98      0.94         771
 weighted avg           0.99      0.99      0.99         771
    
```

Gambar 5. Hasil klasifikasi

4.3. Evaluasi Kemampuan Generalisasi pada Data Eksternal

Kapasitas generalisasi model diuji lebih lanjut menggunakan citra nyata di luar distribusi dataset awal. Kemampuan generalisasi pada data eksternal pada Tabel 2.

Tabel 2 Kemampuan generalisasi pada data eksternal

Label	Prediksi model	keterangan
Daun Sehat	<p>Hasil Prediksi: Healthy_Leaves Confidence: 96.47%</p> 	Prediksi benar dengan Tingkat kepercayaan tinggi

Daun Sehat

Hasil Prediksi: Healthy Leaves
Confidence: 85.94%



Prediksi benar dengan
Tingkat kepercayaan tinggi

Daun Sehat

Hasil Prediksi: Healthy Leaves
Confidence: 54.11%



Prediksi benar dengan
Tingkat kepercayaan rendah
dikarenakan adanya garis
kuning pada tulang daun

WCLWD

Hasil Prediksi: WCLWD
Confidence: 70.68%



Prediksi benar dengan
Tingkat kepercayaan tinggi

WCLWD

Hasil Prediksi: WCLWD
Confidence: 83.97%



Prediksi benar dengan
Tingkat kepercayaan tinggi

WCLWD



Prediksi benar dengan
Tingkat kepercayaan tinggi

CCI




Prediksi salah dengan
Tingkat kepercayaan rendah

CCI



Prediksi salah dengan
Tingkat kepercayaan rendah

CCI



Prediksi salah dengan
Tingkat kepercayaan rendah

Non

Hasil Prediksi: CCI
Confidence: 43.06%Tes dimaksudkan untuk
mengetes citra diluar kelas
yang didistribusikan**White**

#FFFFFF

Berdasarkan Tabel 2. Pada uji kelas *Healthy Leaves* dan *WCLWD*, algoritma mendemonstrasikan keandalan yang tinggi dengan tingkat keyakinan prediktif (*confidence score*) yang solid, yaitu 54.11% hingga 96.47% untuk daun sehat, dan 70.68% hingga 95.64% untuk *WCLWD*.

Namun, pengujian pada citra eksternal kelas *CCI* menyingkap performa model yang kurang maksimal. Model mengalami kegagalan sistematis dalam mengenali sampel *CCI* eksternal, dengan hasil prediksi yang terpecah menjadi kelas *WCLWD* (pada tingkat *confidence* 45.57% dan 58.76%) serta *Healthy Leaves* (44.21%).

Faktor utama yang menyebabkan kurang maksimalnya prediksi pada kelas *CCI* ini adalah adanya *background bias* (bias latar belakang) yang tertanam kuat pada model semasa pelatihan. Di dalam dataset asli, mayoritas citra *CCI* menampilkan karakteristik kerusakan daun yang sangat khas, yaitu lubang-lubang besar berserat akibat gigitan hama ulat yang mengekspos latar belakang berupa langit cerah atau pantulan cahaya putih yang terang. Pola numerik dari komponen latar belakang putih inilah yang secara keliru dipelajari oleh model sebagai identitas utama dari kelas *CCI*. Ketika diuji menggunakan citra *CCI* eksternal yang memiliki latar belakang padat atau terhalang oleh pelepah hijau terang di bagian tengahnya, model kehilangan isyarat kontekstual dari latar belakang terang tersebut. Akibatnya, ekstraksi fitur model menjadi tidak maksimal; model mengabaikan tekstur daun kering kecokelatan di sekitarnya dan mengalami ambiguitas visual yang berujung pada salah klasifikasi. Kendati demikian, nilai probabilitas salah tebak yang rendah (di bawah 60%) membuktikan bahwa penerapan *Dropout* 0.5 berhasil mencegah model dari sifat *overconfident*.

4.4. Perbandingan Kinerja Model dengan Model Tanpa *SMOTE*

Setelah Setelah evaluasi awal, dilakukan perbandingan kinerja antara *Xception* + *SMOTE* dan *Xception* tanpa *SMOTE* untuk menilai pengaruh oversampling terhadap kemampuan klasifikasi pada dataset yang tidak seimbang. Bagian ini mencakup perbandingan nilai *Precision*, *Recall*, *F1-Score*, dan kemampuan generalisasi kedua model.

```

Classification Report:
              precision    recall  f1-score   support

   CCI         1.00        1.00        1.00        268
Healthy_Leaves  1.00        0.32        0.48         19
   WCLWD        0.97        1.00        0.99        484

 accuracy              0.98        771
 macro avg              0.99        0.77        0.82        771
 weighted avg          0.98        0.98        0.98        771
    
```

Gambar 6. Hasil klasifikasi *Xception* tanpa *SMOTE*


Berdasarkan Gambar 6. Hasil klasifikasi menunjukkan akurasi yang cukup tinggi secara keseluruhan yaitu 0.98. Namun, terdapat tanda-tanda masalah serius pada kelas *Healthy_Leaves* meskipun *precision* mencapai nilai yang cukup tinggi (1.00) tetapi *recall* dan *f1-score* yang cukup rendah dengan nilai *recall* 0.32 dan *f1-score* 0.48 dengan support hanya 19. Hal ini mengindikasikan model sering mengabaikan contoh *Healthy_Leaves* sehingga terjadinya *pseudo-accuracy* yang menutupi kegagalan mendeteksi kelas minoritas. Untuk perbandingan performa *Xception + SMOTE* dan *Xception* tanpa *SMOTE* dapat dilihat pada Tabel 3.

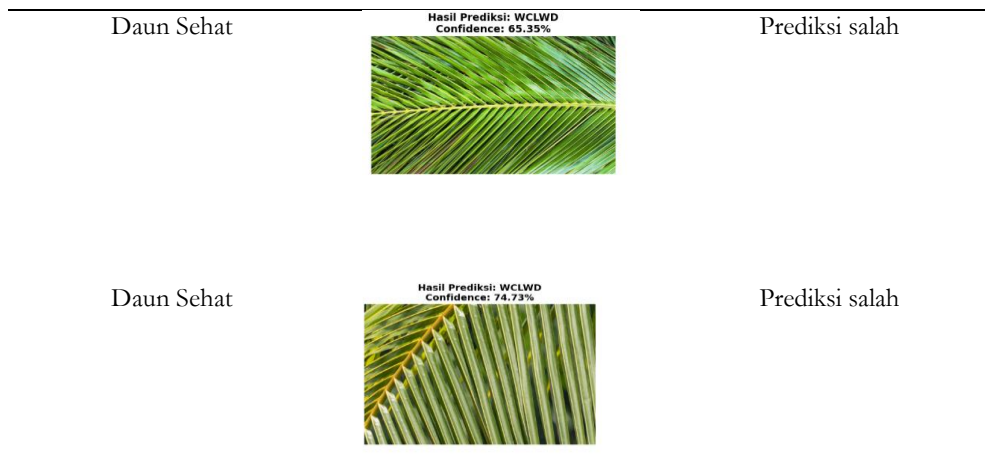
Tabel 3 perbandingan performa *Xception + SMOTE* dan *Xception* tanpa *SMOTE*

Skenario model	Kelas	Precision	Recall	F1-score
<i>Xception + SMOTE</i>	<i>WCLWD</i>	1.00	0.98	0.99
	Daun Sehat	0.72	0.95	0.82
	CCI	1.00	1.00	1.00
<i>Xception</i> tanpa <i>SMOTE</i>	<i>WCLWD</i>	0.97	1.00	0.99
	Daun Sehat	1.00	0.32	0.48
	CCI	1.00	1.00	1.00

Selain perbedaan performa pada Tabel 3. Pada uji kemampuan generalisasi model, daun sehat gagal diprediksi oleh *Xception* tanpa *SMOTE* dikarenakan adanya ketimpangan data (*imbalanced data*) sehingga adanya bias pada kelas minoritas. Hal ini dapat dilihat pada Tabel 4.

Tabel 4 Kemampuan generalisasi *Xception* tanpa *SMOTE* pada data eksternal

Label	Prediksi model	keterangan
Daun Sehat		Prediksi salah



4.5. Uji Ketahanan Model (*Stress Testing*)

Pada uji ketahanan (*stress testing*) diterapkan guna mengeksplorasi respons sistem terhadap data anomali yang sama sekali tidak memiliki fitur dedaunan (berupa citra putih berteks). Hasil eksekusi menunjukkan bahwa model memprediksi gambar tersebut sebagai kelas *CCI* dengan rasio keyakinan 43.06%. Kasus ini menjadi bukti empiris yang memperkuat analisis mengenai adanya background bias pada kelas *CCI*. Karena gambar uji didominasi oleh warna putih polos, jaringan saraf tiruan mengasosiasikannya dengan karakteristik ruang kosong atau langit terang yang sering dijumpai pada latar belakang dataset *CCI* asli. Walaupun fungsi aktivasi *Softmax* secara matematis memaksakan total akumulasi probabilitas 100% pada pilihan kelas yang tersedia, perolehan skor yang rendah dan mendekati batas tebakan acak (33.3%) ini membuktikan bahwa model mampu mendeteksi ketidakpastian dengan baik ketika dihadapkan pada objek non-daun

5. Kesimpulan

Merujuk pada keseluruhan rangkaian tahapan pelatihan, pengujian internal, serta evaluasi data eksternal yang telah dilaksanakan, dapat disimpulkan bahwa pemanfaatan arsitektur *Deep Learning Xception* yang dikolaborasi dengan metode *oversampling* SMOTE menghadirkan solusi pengklasifikasian penyakit daun kelapa yang sangat presisi pada lingkungan data internal, dengan pencapaian akurasi pengujian menyentuh angka 99%. Keberhasilan pemodelan ini didukung secara optimal oleh konfigurasi operasional hiperparameter yang melibatkan pemakaian resolusi citra murni 299x299, pengetatan *learning rate* di angka 0.00001, serta aplikasi lapisan *Dropout* 0.5 yang memainkan peran vital dalam menjaga stabilitas komputasi dan memitigasi potensi *overfitting*. Meskipun demikian, analisis pada pengujian data luar (*unseen wild data*) menyingkap bahwa pengenalan khusus pada kelas *CCI* berjalan kurang maksimal akibat adanya fenomena background bias yang tertanam semasa pelatihan. Ketidakhadiran elemen latar belakang

terang atau langit pada data luar yang berpadu dengan kemunculan fitur pelepah hijau dominan memicu ambiguitas fitur numerik, sehingga citra *CCI* eksternal salah diprediksi sebagai kelas *WCLWD* dan *Healthy Leaves*. Namun, tingkat *confidence* yang rendah (di bawah 60%) pada hasil salah tebak tersebut serta pada hasil stress test citra acak (43.06%) membuktikan secara empiris bahwa sistem memiliki kalibrasi penolakan ketidakpastian yang sehat untuk meredam sifat *overconfident* model.

Berdasarkan batasan penelitian (*research limitations*) yang ditetapkan dalam studi ini, proses modifikasi, manipulasi, ataupun perluasan secara langsung terhadap dataset pelatihan asli berada di luar ruang lingkup yang dapat dilakukan oleh penulis pada tahapan ini. Oleh karena itu, guna mengatasi kendala background bias yang menyebabkan kurang maksimalnya prediksi pada kelas *CCI* tanpa harus merombak dataset yang sudah ada, pengembangan riset selanjutnya di masa mendatang disarankan untuk mengeksplorasi pengayaan variasi spektrum dataset baru secara terpisah yang mencakup fase kerusakan hama ulat (*CCI*) secara lebih komprehensif, khususnya pada kondisi daun yang telah mengering total tanpa menyisakan komponen hijau pada pelepah ataupun ruang kosong latar belakang. Penelitian ini berkontribusi untuk tidak sekadar mengejar akurasi, tetapi memberikan metodologi pengujian ketahanan (*stress testing*) dan mengukur kalibrasi ketidakpastian model computer vision saat menghadapi data anomali. Penelitian ini juga memberikan pembuktian empiris bahwa teknik *SMOTE* dapat diintegrasikan pada data citra berdimensi tinggi yang terbukti secara signifikan mampu memulihkan sensitivitas (*Recall*) kelas minoritas tanpa memicu *overfitting*. Langkah perbaikan terakhir yang dapat dipertimbangkan adalah penyisipan kelas anomali (*Out-of-Distribution/OOD*) berupa kategori kelas keempat seperti "Lainnya" (*Other/Unknown*) yang dilatih menggunakan sampel citra non-daun, sehingga fungsi Softmax memiliki wadah penolakan otomatis dan tidak memaksakan nilai probabilitas tinggi pada pilihan opsi kelas yang tidak relevan.

6. Ucapan Terima Kasih

Penulis menyampaikan terima kasih yang sebesar-besarnya kepada Bapak Daniel Udjulawa, S.Kom., M.T.I, selaku dosen pembimbing, atas segala bimbingan dan arahan yang sangat berarti. Penghargaan yang sama juga ditujukan kepada seluruh jajaran dosen Program Studi Teknik Informatika, Universitas Multi Data Palembang, serta rekan-rekan dan semua pihak yang telah memberikan dukungan moril selama proses penelitian ini berlangsung.

7. Pernyataan Penulis

Penulis menyatakan bahwa tidak ada konflik kepentingan terkait publikasi artikel ini. Penulis menyatakan bahwa data dan makalah bebas dari plagiarisme serta penulis bertanggung jawab secara penuh atas keaslian artikel.

Bibliografi

- Alam, T. S., Jowthi, C. B., & Pathak, A. (2024). Comparing pre-trained models for efficient leaf disease detection: a study on custom CNN. *Journal of Electrical Systems and Information Technology*, 11(1). <https://doi.org/10.1186/s43067-024-00137-1>
- Arifin, N., Maratuttahirah, Rusman, J., & Rasyid, M. F. (2024). Leaf disease detection in tomato plants using Xception model in convolutional neural network method. *Jurnal Teknik Informatika (JUTIF)*, 5(2), 571–577. <https://doi.org/10.52436/1.jutif.2024.5.2.1926>
- Arnita, Marpaung, F., Aulia, F., Suryani, N., & Nabila, R. C. (2022). *Computer vision dan pengolahan citra digital* (A. B. Surya, Ed.). Pustaka Aksara. www.pustakaaksara.co.id
- Gopalakrishna, K. M., & Lingaraju, R. M. (2025). A prediction of coconut and coconut leaf disease using MobileNetV2 based classification. *International Journal of Electrical and Computer Engineering (IJECE)*, 15(3), 2834. <https://doi.org/10.11591/ijece.v15i3.pp2834-2844>
- Huang, X., Alobaedy, M. M., Fazea, Y., Goyal, S. B., & Deng, Z. (2025). Disease infection classification in coconut tree based on an enhanced Visual Geometry Group model. *Processes*, 13(3). <https://doi.org/10.3390/pr13030689>
- Kabir, F., Rahman, M., Al Mamun, A., & Ahmad, Y. (2025). Coconut leaf disease detection using deep learning techniques. *International Journal on Science and Technology*, 16. <https://doi.org/10.71097/IJSAT.v16.i1.1751>
- Kavithamani, V., & UmaMaheswari, S. (2023). Investigation of deep learning for whitefly identification in coconut tree leaves. *Intelligent Systems with Applications*, 20. <https://doi.org/10.1016/j.iswa.2023.200290>
- Kurniawan, W. A., & Salam, A. (2024). Penggunaan feature space SMOTE untuk mengurangi overfitting akibat imbalance dataset. *Techno.COM Journal*, 23(2), 328–337. <https://doi.org/10.62411/tc.v23i2.10215>
- Masaugi, F. F., Yanto, F., Budianita, E., Sanjaya, S., & Syafria, F. (2024). Deep learning menggunakan algoritma Xception dan augmentasi flip pada klasifikasi kematangan sawit. *KLIK: Kajian Ilmiah Informatika dan Komputer*, 4(6), 2918–2927. <https://doi.org/10.30865/klik.v4i6.1938>
- Meena, R., Joshi, S., & Raghuvanshi, S. (2024). Xception model for disease detection in rice plant. *Journal of Intelligent and Fuzzy Systems*, 46(1), 181–198. <https://doi.org/10.3233/JIFS-230655>
- Naik, S. M., Chakraborty, T., Panja, M., Hadid, A., & Chakraborty, B. (2025). Skew-probabilistic neural networks for learning from imbalanced data. *Pattern Recognition*, 165, 111677. <https://doi.org/10.1016/j.patcog.2025.111677>

- Nesarajan, D., Kunalan, L., Logeswaran, M., Kasthuriarachchi, S., & Lungalage, D. (2020). Coconut disease prediction system using image processing and deep learning techniques. In 2020 4th International Conference on Image Processing, Applications and Systems (IPAS), 212–217. <https://doi.org/10.1109/IPAS50080.2020.9334934>
- Pantha, D., & Koju, Dr. R. (2024). Plant leaf disease detection using Xception model. *Journal of Image Processing and Intelligent Remote Sensing*, (45), 41–54. <https://doi.org/10.55529/jipirs.45.41.54>
- Pulungan, M. P., Purnomo, A., & Kurniasih, A. (2024). Penerapan SMOTE untuk mengatasi imbalance class dalam klasifikasi kepribadian MBTI menggunakan Naive Bayes classifier. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(5), 1033–1042. <https://doi.org/10.25126/jtiik.2024117989>
- Saleem, M. H., Potgieter, J., & Arif, K. M. (2020). Plant disease classification: A comparative evaluation of convolutional neural networks and deep learning optimizers. *Plants*, 9(10), 1–17. <https://doi.org/10.3390/plants9101319>
- Vidhanaarachchi, S., Wijekoon, Dr. J. L., Gunasekara, T., & Liyanarachchi, R. (2022). Coconut Diseases and Pest Infestations. Kaggle. <https://doi.org/10.34740/KAGGLE/DS/2419296>
- Vidhanaarachchi, S., Wijekoon, J. L., Abeysiriwardhana, W. A. S. P., & Wijesundara, M. (2025). Early diagnosis and severity assessment of Weligama coconut leaf wilt disease and coconut caterpillar infestation using deep learning-based image processing techniques. *IEEE Access*, 13, 24463–24477. <https://doi.org/10.1109/ACCESS.2025.3537664>
- Wiratno, O. (2025). Outlook Kelapa (A. A. Susanti & E. Respati, Ed.). Pusat Data dan Sistem Informasi Pertanian Sekretariat Jenderal - Kementerian Pertanian.