

## Analysis of Deep Learning Implementation Using Xception for Rice Leaf Disease Classification

Niken Puspitaningrum <sup>1\*</sup>, Majid Rahardi <sup>2\*</sup>

\* Informatika, Universitas AMIKOM Yogyakarta

[nikenpuspita@students.amikom.ac.id](mailto:nikenpuspita@students.amikom.ac.id) <sup>1</sup>, [majid@amikom.ac.id](mailto:majid@amikom.ac.id) <sup>2</sup>

### Article Info

#### Article history:

Received 2025-11-19

Revised 2026-01-02

Accepted 2026-01-13

#### Keyword:

Deep Learning,  
Keras Application,  
Rice Leaf Disease,  
Web-Based,  
Xception..

### ABSTRACT

Identifying rice leaf diseases plays a crucial role in maintaining agricultural productivity and preventing massive losses. In recent years, deep learning models have shown very promising performance in plant disease classification tasks. This study proposes a Rice Leaf Disease Detection System based on the Xception model from Keras Applications, an architecture that is still relatively unexplored for rice plant disease cases. Through preprocessing, data augmentation, and model refinement, the developed system achieved a training accuracy of 93% and a testing accuracy of 89% in classifying rice leaf conditions. In addition, metric evaluation showed precision, recall, and F1-score values of 89%, reflecting the model's ability to make consistent and balanced predictions. The trained model was then integrated into a web-based application to facilitate real-time disease diagnosis through image uploads. The results of this study prove the effectiveness of the Xception architecture in extracting agricultural image features and its potential for application in artificial intelligence-based smart farming systems.



This is an open access article under the [CC-BY-SA](#) license.

### I. PENDAHULUAN

Padi (*Oryza sativa L.*) merupakan salah satu komoditas pangan utama yang memiliki peran penting dalam memenuhi kebutuhan pangan global[1]. Tanaman ini menjadi sumber karbohidrat utama bagi sebagian besar penduduk dunia, terutama di kawasan Asia[2]. Di Indonesia, masyarakat sangat bergantung pada hasil pertanian padi sebagai sumber utama bahan pangan sekaligus sebagai penopang perekonomian rakyat[3].

Produksi padi di Indonesia pada Agustus 2025 menunjukkan angka yang cukup signifikan, yaitu mencapai 5,63 juta ton gabah kering giling (GKG) berdasarkan data dari Badan Pusat Statistik (BPS). Capaian ini menggambarkan tingginya kapasitas produksi nasional yang didukung oleh luas panen sekitar 1,11 juta hektare di berbagai daerah sentra pertanian. Jumlah tersebut menegaskan bahwa subsektor tanaman pangan, khususnya padi, masih menjadi tulang punggung dalam menjaga stabilitas ketahanan pangan nasional serta berkontribusi besar terhadap perekonomian Indonesia[4]. Dengan demikian, upaya dalam mempertahankan kesehatan serta kualitas tanaman padi

menjadi faktor yang sangat penting guna menjamin hasil panen yang optimal[5].

Dalam budidaya padi, kesehatan daun merupakan indikator utama yang menentukan kualitas dan kuantitas hasil panen. Penyakit seperti *Bacterial Leaf Blight*, *Brown Spot*, dan *Leaf Blast* diketahui dapat menurunkan produktivitas apabila tidak ditangani dengan baik. Identifikasi penyakit secara tepat waktu menjadi komponen krusial dalam proses pengendalian untuk mencegah penularan yang lebih luas. Namun, pada praktiknya, proses diagnosis penyakit daun padi hingga kini masih sangat bergantung pada penilaian visual petani atau petugas lapangan[6]. Metode ini, meskipun umum digunakan, memiliki kelemahan berupa ketergantungan pada pengalaman individu, subjektivitas penilaian, serta potensi kesalahan pada kondisi lapangan yang dinamis. Ketidakkonsistenan ini dapat berdampak pada keterlambatan penanganan, menurunnya efisiensi operasional, serta risiko kerugian produksi yang lebih besar.

Ketergantungan pada pengamatan manual dalam menentukan jenis penyakit daun padi menuntut keahlian khusus dan berpotensi menimbulkan perbedaan persepsi antar petani maupun penyuluh pertanian. Akibatnya, proses

pemilihan kategori penyakit sering kali tidak presisi dan menyebabkan langkah pengendalian yang kurang optimal[7]. Untuk mengatasi masalah tersebut, dibutuhkan pendekatan berbasis teknologi yang mampu memberikan hasil diagnosis secara objektif, cepat, dan konsisten. Salah satu teknologi yang memiliki potensi besar adalah pemanfaatan pengolahan citra digital untuk mengklasifikasikan jenis penyakit berdasarkan pola visual pada daun[8]. Sejumlah penelitian menunjukkan bahwa metode *machine learning* dan *deep learning*, khususnya *Convolutional Neural Network* (CNN), mampu memberikan performa yang lebih konsisten dan objektif dibandingkan metode konvensional dalam mendeteksi penyakit daun padi[9][10].

Pendekatan berbasis *Convolutional Neural Network* (CNN) dilaporkan mampu mencapai akurasi pelatihan sebesar 85% setelah 10 epoch, menunjukkan potensi yang baik dalam mendukung deteksi dini penyakit tanaman[11]. Di sisi lain, studi pada kasus yang sama menggunakan algoritma berbasis *ensemble* seperti *Extra Trees* menunjukkan akurasi mendekati 90%, menunjukkan bahwa pemilihan algoritma sangat berpengaruh terhadap performa sistem klasifikasi[12]. Namun demikian, metode-metode tersebut umumnya masih bergantung pada ekstraksi fitur manual, sehingga kurang optimal dalam menangkap kompleksitas pola visual pada citra daun. Pada pendekatan *deep learning* yang lebih lanjut, arsitektur CNN modern seperti *ResNet* dilaporkan mampu mencapai akurasi sekitar 92% pada data klasifikasi penyakit daun padi. Meskipun performa pengujian pada citra baru menunjukkan penurunan akurasi hingga di bawah 80%[13]. Hal ini mengindikasikan adanya tantangan dalam generalisasi model terhadap variasi kondisi citra di lapangan. Sementara itu, studi mengenai arsitektur *Xception*, telah menunjukkan performa yang sangat baik pada klasifikasi penyakit tanaman lain dengan tingkat akurasi yang mencapai 94%[14]. Keunggulan *Xception* terletak pada kemampuannya mengekstraksi fitur visual dengan jumlah parameter yang relatif lebih ringan dibandingkan arsitektur CNN lain.

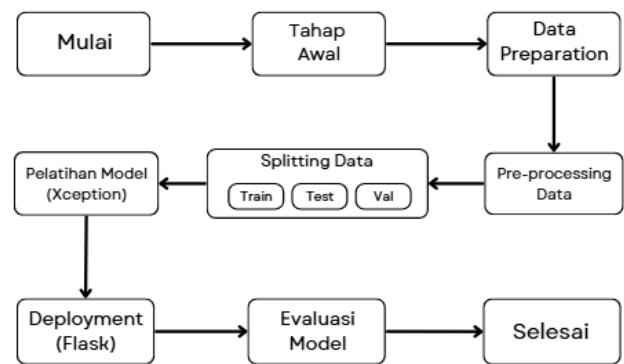
Penggunaan arsitektur *deep learning* seperti *Xception* terbukti lebih efisien dalam mengekstraksi fitur detail melalui pendekatan *depthwise separable convolution*, sehingga menghasilkan performa yang lebih baik pada klasifikasi multi-kelas[15]. Model *Xception*, yang dikenal memiliki struktur ringan namun akurat, dinilai sangat relevan untuk kasus deteksi penyakit daun padi. Arsitektur ini memungkinkan komputer mempelajari pola warna, tekstur, dan bercak penyakit secara mendalam melalui citra visual, sehingga mampu mengurangi ketergantungan pada penilaian manusia yang rentan kesalahan[16]. Selain itu, model dapat beradaptasi secara optimal pada dataset terbatas maupun beragam kondisi citra di lapangan[17].

Penelitian ini bertujuan untuk mengevaluasi performa model klasifikasi penyakit daun padi berbasis arsitektur *Xception* dalam membedakan empat kelas Utama, yaitu *Bacterial Leaf Blight*, *Brown Spot*, *Leaf Blast*, dan *Healthy*. Signifikansi penelitian ini terletak pada potensi peningkatan akurasi diagnosis secara otomatis, serta kontribusi terhadap

efisiensi proses monitoring kesehatan tanaman padi. Dengan menerapkan model *Xception* pada klasifikasi daun padi, diharapkan diperoleh solusi yang lebih objektif, stabil, dan efisien dibandingkan dengan identifikasi manual. Berdasarkan latar belakang tersebut, penelitian ini akan berfokus pada implementasi dan evaluasi model *Xception* untuk klasifikasi penyakit daun padi secara otomatis. Diharapkan hasil penelitian ini dapat memberikan kontribusi nyata dalam mendukung transformasi digital di sektor pertanian, khususnya dalam upaya meningkatkan produktivitas dan kesehatan tanaman padi melalui deteksi penyakit yang lebih cepat, objektif, dan presisi.

## II. METODE

Rancangan alur penelitian disusun untuk memberikan gambaran sistematis mengenai langkah-langkah yang ditempuh dalam menyelesaikan permasalahan yang diangkat[18]. Penelitian ini difokuskan pada proses pengembangan dan penerapan metode yang efektif untuk mencapai tujuan utama yang telah ditetapkan. Diagram alur penelitian secara lengkap dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

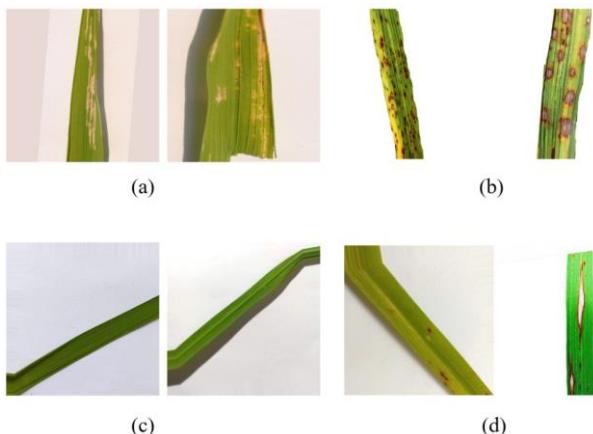
### A. Tahap Awal

Tahap awal pada penelitian ini mencakup proses pemahaman konteks penelitian, kajian literatur, dan pengumpulan data. Langkah ini berperan penting dalam mengidentifikasi secara jelas permasalahan yang akan diselesaikan serta menentukan arah pengembangan solusi berbasis teknologi yang tepat. Dalam penelitian ini, fokus utama terletak pada pengenalan penyakit daun padi yang selama ini masih dilakukan secara manual oleh petani maupun tenaga penyuluh lapangan. Proses identifikasi visual tersebut memiliki keterbatasan karena bersifat subjektif, memerlukan pengalaman khusus, serta memakan waktu yang tidak sedikit.

Berdasarkan kondisi tersebut, penelitian ini diarahkan untuk mengembangkan sebuah sistem diagnosis penyakit daun padi berbasis *deep learning* yang memanfaatkan arsitektur *Xception* dari pustaka *Keras Applications*. Sistem ini diharapkan mampu melakukan klasifikasi penyakit daun padi secara otomatis dengan tingkat akurasi yang tinggi.

### B. Data Preparation

Tahap ini dilakukan setelah tahap pemahaman konteks penelitian, tahap ini mencakup data yang akan digunakan untuk penelitian kemudian diproses oleh model *deep learning*. Pada penelitian ini, dataset yang digunakan adalah dataset publik berupa citra daun padi. Dataset diunduh melalui website *Kaggle*. Jumlah total citra dalam dataset adalah 6.158. Dataset tersebut mencakup beberapa kategori, yaitu daun padi sehat serta daun yang terinfeksi penyakit seperti *brown spot*, *leaf blast*, dan *bacterial leaf blight*. Berikut adalah contoh sample citra yang digunakan:



Gambar 2. (a)Bacterial Leaf Blight (b)Brown Spot (c)Healthy (d)Leaf Blast

Dataset yang digunakan dipilih karena memiliki variasi visual yang cukup beragam, baik dari segi warna, tekstur, maupun tingkat keparahan gejala penyakit pada daun padi. Keberagaman ini penting untuk melatih model agar mampu mengenali pola penyakit secara lebih robust dan tidak terbatas pada kondisi citra tertentu. Selain itu, penggunaan dataset publik memungkinkan penelitian ini untuk direplikasi dan dibandingkan dengan penelitian lain secara lebih objektif. Dengan jumlah data yang relatif besar dan representatif, dataset ini diharapkan dapat mendukung proses pelatihan model *Xception* secara optimal serta meningkatkan kemampuan generalisasi model terhadap data baru. Adapun rincian dataset dapat dilihat pada Tabel 1 berikut:

TABEL I  
RINCIAN ISI DATASET

Dataset		
Sub-kelas	Total	Deskripsi
Healthy	1491	Kondisi daun padi sehat tanpa bercak dan gejala penyakit.
Bacterial Leaf Bligh	1386	Penyakit daun yang disebabkan oleh bakteri <i>Xanthomonas oryzae</i> ditandai dengan ujung daun menguning lalu menyebar ke seluruh daun.
Brown Spot	1480	Penyakit yang ditandai dengan bercak coklat kehitaman pada daun padi yang disebabkan oleh jamur <i>Bipolaris oryzae</i> .

Dataset		
Sub-kelas	Total	Deskripsi
Leaf Blast	1801	Penyakit bercak daun berbentuk belah ketupat pada tanaman padi yang disebabkan oleh jamur <i>Pyricularia oryzae</i> .

### C. Pre-processing Data

Tahap *pre-processing* dilakukan untuk memastikan seluruh citra daun padi memiliki format dan kualitas yang seragam sebelum digunakan dalam pelatihan. Pada penelitian ini, proses *pre-processing* dan augmentasi data dilakukan menggunakan modul *ImageDataGenerator* dari pustaka *Keras*. Seluruh citra daun padi diproses dengan ukuran input sebesar  $128 \times 128$  piksel dan terdiri dari tiga kanal warna (RGB) agar sesuai dengan kebutuhan arsitektur *Xception*. Normalisasi dilakukan dengan mengubah nilai piksel dari rentang 0–255 menjadi 0–1 melalui parameter *rescale* = 1/255, sehingga mempercepat proses konvergensi dan meningkatkan stabilitas pelatihan model.

Berbeda dengan pendekatan augmentasi geometrik yang melibatkan rotasi, *flipping*, atau *zooming*, penelitian ini tidak menerapkan augmentasi spasial tambahan pada citra. Strategi ini dipilih untuk menjaga keaslian pola visual penyakit daun padi, mengingat beberapa karakteristik penyakit seperti arah bercak, pola memanjang, dan distribusi warna memiliki makna diagnostik yang penting. Dengan demikian, model dilatih menggunakan citra yang telah dinormalisasi tanpa distorsi bentuk, sehingga pembelajaran fitur tetap merepresentasikan kondisi visual daun padi secara alami.

Setelah itu, data diolah menggunakan tiga data generator yang berfungsi untuk mengatur aliran data selama proses pelatihan, validasi, dan pengujian. Data generator dibagi menjadi tiga bagian utama, yaitu *training generator*, *validation generator*, dan *testing generator*. *Training* dan *validation generator* menggunakan ukuran batch sebesar 64 citra, sedangkan *testing generator* menggunakan batch size yang disesuaikan secara otomatis berdasarkan jumlah data uji agar seluruh data dapat dievaluasi secara optimal dalam satu siklus pengujian. Seluruh generator menggunakan mode warna RGB dan skema klasifikasi kategorikal (*categorical class mode*) untuk mendukung klasifikasi multi-kelas. Pendekatan *pre-processing* ini memungkinkan model *Xception* untuk fokus pada ekstraksi fitur tekstur, warna, dan pola penyakit daun padi tanpa bias akibat transformasi citra buatan.

### D. Splitting Data

Pada tahap ini dataset yang berjumlah 6.158 citra daun padi dibagi menjadi tiga subset utama, yaitu *training set*, *validation set*, dan *testing set*. Proses pembagian dataset dilakukan menggunakan pendekatan *stratified split* agar proporsi setiap kelas tetap seimbang di semua subset. Kemudian data dibagi menjadi tiga bagian menggunakan metode *hold-out validation* dengan perbandingan 80% untuk

*training set*, 10% untuk *validation set*, dan 10% untuk *testing set*. Pendekatan ini dipilih untuk menjaga efisiensi komputasi serta memastikan konsistensi proses pelatihan dan evaluasi model.

*Training set* digunakan untuk melatih parameter model agar dapat mengenali pola visual pada daun padi berdasarkan empat kelas yang telah ditetapkan. Sementara itu, *validation set* berfungsi untuk mengevaluasi kinerja model selama proses pelatihan dan membantu mencegah terjadinya *overfitting*. Adapun *testing set* digunakan pada tahap akhir untuk mengukur performa model secara objektif menggunakan data yang belum pernah dilihat sebelumnya. Pembagian ini bertujuan untuk memastikan bahwa model *Xception* mampu melakukan generalisasi terhadap data baru dan tidak hanya menghafal pola dari data pelatihan. Detail keseluruhan pembagian dataset dirangkum dalam Tabel 2.

TABEL 2  
DETAIL PEMBAGIAN DATASET

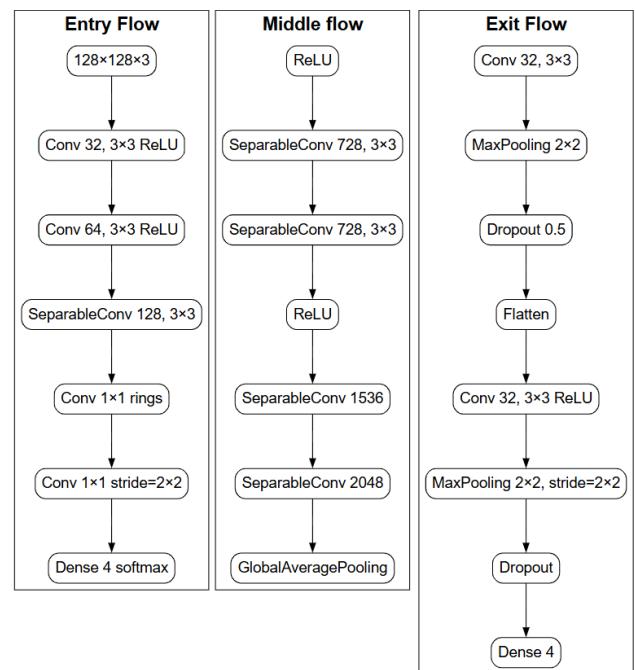
Infomasi	Training Set	Validation Set	Testing Set
<b>Proporsi</b>	80%	10%	10%
<b>Jumlah Data</b>	4926	616	616
<b>Bacterial Leaf Blight</b>	1109	139	138
<b>Brown Spot</b>	1184	148	148
<b>Healthy</b>	1193	149	149
<b>Leaf Blast</b>	1440	180	181

#### E. Pelatihan Model

Setelah dataset *dipre-processing*, langkah selanjutnya adalah melakukan pelatihan model. Tahap pelatihan model dilakukan dengan menggunakan *Convolutional Neural Network (CNN)* dengan arsitektur dasar *Xception* yang telah terlatih sebelumnya pada dataset *ImageNet*. Model ini dipilih karena memiliki performa yang baik dalam mengenali fitur-fitur citra secara mendalam.

Pertama, model *Xception* diimporkan tanpa lapisan akhir agar dapat digunakan sebagai *feature extractor*. Selanjutnya, lapisan dasar model dikunci dengan mengatur parameter *trainable = False* untuk mencegah perubahan bobot selama pelatihan, sehingga proses pelatihan hanya difokuskan pada lapisan tambahan yang dirancang khusus untuk dataset penelitian ini.

Lapisan tambahan yang ditambahkan meliputi *Conv2D* dengan 32 filter dan fungsi aktivasi *ReLU* untuk mengekstraksi fitur baru, dilanjutkan dengan *MaxPooling2D* untuk mengurangi dimensi spasial, serta *Dropout* sebesar 0,5 guna mencegah *overfitting*. Hasil ekstraksi kemudian diratakan menggunakan *Flatten*, dan diakhiri dengan lapisan *Dense* berisi empat neuron dengan fungsi aktivasi *softmax*, yang berfungsi untuk mengklasifikasikan citra ke dalam empat kategori penyakit daun padi.



Gambar 3. Arsitektur Model *Xception*

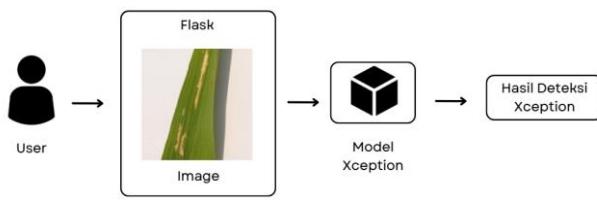
Model dikompilasi menggunakan *optimizer Adam* dengan *learning rate* sebesar 0,001, dan metrik evaluasi berupa *accuracy*, *precision*, *recall*, dan, *f1-score*. Pelatihan dilakukan selama 10 *epoch* menggunakan data hasil augmentasi (*train\_gen*) dan data validasi (*valid\_gen*). Melalui tahap ini, model dilatih untuk mengenali pola-pola visual dari setiap kelas daun padi sehingga mampu melakukan klasifikasi secara optimal pada tahap pengujian berikutnya.

TABEL 3  
TABEL PARAMETER

Name	Parameter Value
Optimizer	Adam
Loss Function	Categorical Cross-Entropy
Learning Rate	0,001
Batch Size	64
Epochs	10

#### F. Deployment

Setelah model *Xception* selesai dilatih dan menghasilkan performa terbaik, berikutnya model diimplementasikan ke dalam bentuk aplikasi web agar dapat digunakan secara interaktif oleh pengguna. Pada penelitian ini, proses *deployment* dilakukan menggunakan *Flask*, yaitu salah satu *framework Python* yang fleksibel untuk pengembangan aplikasi berbasis web. *Flask* digunakan untuk membuat antarmuka antara model *Xception* dengan pengguna melalui tampilan web.



Gambar 4. Arsitektur Deployment Flask

Tahapan awal dalam proses *deployment* dimulai dengan mengintegrasikan model *Xception* yang telah dilatih ke dalam struktur aplikasi *Flask*. Model yang sebelumnya disimpan dalam format *SavedModel*, yaitu berupa sebuah folder yang berisi struktur model lengkap. Model tersebut kemudian dimuat ke dalam aplikasi *Flask* menggunakan pustaka *TensorFlow* melalui fungsi *tf.saved\_model.load*, sehingga model dapat digunakan secara langsung untuk proses inferensi.

Sistem dirancang memiliki dua halaman utama, yaitu *CNN Model* dan *Image Classification*. Halaman *CNN Model* digunakan untuk menampilkan hasil evaluasi performa model *Xception* setelah proses pelatihan dan pengujian dilakukan. Adapun untuk halaman *Image Classification* disiapkan untuk menerima masukan berupa gambar daun padi dari pengguna. *Flask* menyediakan *endpoint* utama pada halaman antarmuka berbentuk form unggah, di mana pengguna dapat memilih gambar daun dengan format umum seperti .jpg, .png, atau .jpeg. Ketika pengguna berhasil mengunggah gambar daun padi, sistem akan melakukan *preprocessing* terhadap citra yang diunggah. Gambar tersebut diubah ukurannya menjadi  $128 \times 128$  piksel sesuai dengan ukuran input model, kemudian dinormalisasi agar memiliki nilai piksel antara 0 dan 1. Selanjutnya, citra tersebut dikirim ke model *Xception* yang telah dilatih untuk melakukan prediksi terhadap empat kelas utama, yaitu *bacterial leaf blight*, *brown spot*, *leaf blast*, dan *healthy*. Model kemudian mengeluarkan hasil berupa label prediksi dan *confidence level* untuk setiap gambar yang diuji.

Pada penelitian ini, aplikasi web yang dikembangkan masih dijalankan dalam lingkungan *localhost*, sehingga hanya dapat diakses secara lokal pada perangkat pengembang. Aplikasi belum terintegrasi dengan database maupun sistem autentifikasi pengguna, dan seluruh proses inferensi dilakukan secara langsung saat pengguna mengunggah citra. Penggunaan lingkungan lokal ini bertujuan untuk memvalidasi fungsionalitas sistem, memastikan integrasi antara model *Xception* dan aplikasi *Flask* berjalan dengan baik, serta mengevaluasi kemampuan sistem dalam melakukan klasifikasi citra daun padi secara real-time.

#### G. Evaluasi Model

Setelah dilakukan proses pelatihan, model *Xception* kemudian dievaluasi secara komprehensif menggunakan *test set* yang sepenuhnya terpisah dari data pelatihan maupun validasi. Evaluasi ini bertujuan untuk mengukur kemampuan generalisasi model dalam mengklasifikasikan daun padi ke dalam kelas yang benar pada citra yang belum pernah dilihat sebelumnya. Hasil evaluasi disajikan dalam bentuk tabel dan

grafik sehingga dapat memberikan gambaran menyeluruh terhadap performa model. Kinerja model dianalisis menggunakan empat metrik utama, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Adapun definisi dan rumus masing-masing metrik adalah sebagai berikut:

- 1) *Accuracy*: perbandingan antara jumlah seluruh prediksi yang tepat (baik positif maupun negatif) dengan keseluruhan data yang diuji. Rumusnya:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Dimana:

*True Positive* (TP) = model berhasil mengidentifikasi data sebagai positif sesuai dengan kondisi sebenarnya.

*True Negative* (TN) = model dengan tepat memprediksi data sebagai negatif.

*False Positive* (FP) = model mengklasifikasikan data sebagai positif, padahal kenyataannya data tersebut negatif.

*False Negative* (FN) = model memprediksi data sebagai negatif, namun sebenarnya data tersebut merupakan kasus positif.

- 2) *Precision*: rasio antara prediksi positif yang benar dengan seluruh prediksi yang dikategorikan sebagai positif. Ukuran ini menunjukkan seberapa akurat model dalam memberikan label positif yang memang benar-benar sesuai. Rumusnya:

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

- 3) *Recall*: perbandingan antara jumlah kelas positif yang berhasil diprediksi dengan benar dan total kelas positif yang ada. Ukuran ini menunjukkan sejauh mana model mampu menemukan seluruh kasus yang benar-benar positif. Rumusnya:

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

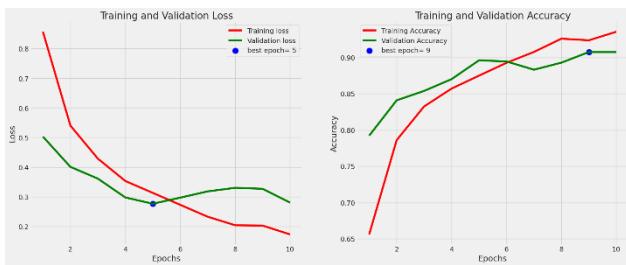
- 4) *F1-Score*: rata-rata harmonik dari nilai presisi dan recall, sehingga mampu memberikan keseimbangan antara kedua metrik tersebut. *F1-score* sangat bermanfaat terutama ketika distribusi kelas tidak merata. Rumusnya:

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Kelebihan dari *F1-Score* adalah metrik ini mempertimbangkan kedua aspek kinerja model (*Precision* dan *Recall*) dalam satu angka, sehingga gambaran mengenai kinerja model menjadi lebih lengkap.

### III. HASIL DAN PEMBAHASAN

Pada tahap ini disajikan hasil dari model *Xception* yang dikembangkan untuk mendeteksi citra daun padi dan melakukan klasifikasi penyakit menggunakan pendekatan *Deep Learning*. Pada penelitian ini, model *Xception* yang dibangun mampu melakukan prediksi serta mengelompokkan citra padi berdasarkan jenis penyakitnya, yang dibuktikan melalui data pelatihan dan data validasi. Proses pelatihan dilakukan menggunakan 10 *epoch*, dan pelatihan akan berhenti ketika seluruh kondisi pada setiap *epoch* terpenuhi. Setelah proses pelatihan selesai, diperoleh grafik yang menunjukkan perubahan nilai loss serta akurasi pada setiap *epoch*. Grafik *training* dan *validation* dapat dilihat pada Gambar 5.



Gambar 5. Grafik Training dan Validation Loss

Grafik *Training* dan *Validation Loss* memperlihatkan bahwa nilai *loss* pada data pelatihan menurun secara konsisten dari *epoch* ke *epoch*, yang menandakan bahwa model mampu belajar pola dengan baik. Sementara itu, *validation loss* juga mengalami penurunan, meskipun terdapat sedikit fluktuasi pada beberapa *epoch*. Hal ini menunjukkan bahwa proses pembelajaran berlangsung stabil dan tidak terjadi *overfitting* secara signifikan. Pada awal pelatihan, akurasi model meningkat tajam sebelum kemudian bergerak stabil pada nilai sekitar 91%. *Validation accuracy* mengikuti pola yang serupa dengan *training accuracy*, yang menandakan bahwa model tidak hanya menghafal data pelatihan, tetapi juga mampu memahami pola secara general. Titik akurasi terbaik juga terjadi pada *epoch* ke-9, sehingga bobot pada *epoch* ini menjadi bobot terbaik yang digunakan dalam evaluasi akhir.

Pada tahap selanjutnya, untuk menguji performa model dalam melakukan klasifikasi penyakit daun padi, digunakan *confusion matrix* yang menggambarkan sebaran prediksi model terhadap label aktual. Berdasarkan hasil evaluasi, model menunjukkan performa yang sangat baik pada kelas *bacterial\_leaf\_blight* dengan 137 prediksi benar dan hanya 1 salah prediksi. Pada kelas *brown\_spot*, model menghasilkan 136 prediksi benar namun masih terdapat beberapa kesalahan, termasuk 8 prediksi sebagai *leaf\_blast*. Kelas *healthy* menunjukkan hasil yang cukup baik dengan 129 prediksi benar, meskipun terdapat kesalahan prediksi menjadi *brown\_spot* dan *leaf\_blast*. Sementara itu, kelas *leaf\_blast* menunjukkan 161 prediksi benar dengan beberapa kesalahan menjadi *brown\_spot*. Secara umum, *confusion matrix* ini menunjukkan bahwa model mampu mengenali pola daun

dengan akurasi tinggi, meskipun masih mengalami beberapa kesulitan pada kelas *brown\_spot* dan *healthy* yang memiliki kemiripan tekstur dan warna dikarenakan citra yang diambil.

Confusion Matrix				
Actual				
	bacterial_leaf_blight	brown_spot	healthy	leaf_blast
bacterial_leaf_blight	137	1	0	0
brown_spot	2	136	2	8
healthy	3	6	129	11
leaf_blast	3	15	2	161
	bacterial_leaf_blight	brown_spot	healthy	leaf_blast

Gambar 6. Confusion Matrix

Untuk memperoleh gambaran evaluasi yang lebih komprehensif, dilakukan analisis lanjutan menggunakan *classification report* yang mencakup metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Detail hasil performa model *Xception* dapat dilihat pada Gambar 7.

Classification Report:				
	precision	recall	f1-score	support
bacterial_leaf_blight	0.97	0.98	0.97	138
brown_spot	0.85	0.86	0.85	148
healthy	0.90	0.89	0.89	149
leaf_blast	0.85	0.85	0.85	181
accuracy			0.89	616
macro avg	0.89	0.89	0.89	616
weighted avg	0.89	0.89	0.89	616

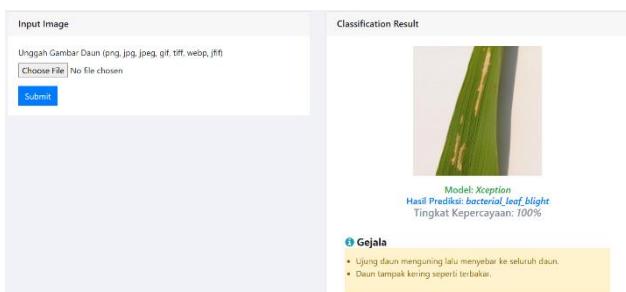
Gambar 7. Classification Report

Hasil *classification report* menunjukkan bahwa kelas *leaf\_blast* dan *bacterial\_leaf\_blight* memiliki nilai *precision* dan *recall* yang tinggi, sesuai dengan hasil pada *confusion matrix* yang memperlihatkan jumlah prediksi benar yang dominan pada kedua kelas tersebut. Sementara itu, kelas *brown\_spot* dan *healthy* menunjukkan nilai *F1-score* yang sedikit lebih rendah, mengindikasikan bahwa model masih mengalami kesalahan dalam membedakan karakteristik visual antara daun sehat dan penyakit bercak tertentu. Hal ini dapat disebabkan oleh kesamaan pola tekstur dan warna yang cenderung tumpang tindih antar kelas tersebut. Secara keseluruhan, model memiliki tingkat akurasi akhir sebesar 89%. Performa model *Xception* yang mencapai akurasi tinggi menunjukkan bahwa arsitektur ini efektif dalam mengekstraksi ciri visual daun padi, khususnya pola bercak, perubahan warna, dan tekstur permukaan daun. Keunggulan *Xception* dibandingkan CNN konvensional terletak pada penggunaan *depthwise separable convolution* yang memungkinkan pemisahan pembelajaran fitur spasial dan kanal warna secara lebih efisien. Mekanisme ini membantu

model menangkap detail lokal seperti tepi bercak dan distribusi warna penyakit dengan jumlah parameter yang lebih ringan, sehingga proses pembelajaran menjadi lebih stabil. Metrik *precision* rata-rata menunjukkan nilai tinggi yaitu 89%, yang berarti model jarang salah mendeteksi satu kelas sebagai kelas lain. Nilai rata-rata *recall* yang juga mencapai 89% memperlihatkan bahwa model mampu menemukan sebagian besar objek yang relevan pada setiap kelas. Sementara itu, nilai *f1-score* rata-rata sebesar 89% menunjukkan keseimbangan performa antara *precision* dan *recall*.

Namun demikian, hasil evaluasi juga menunjukkan bahwa kesalahan klasifikasi masih terjadi. Hal ini mengindikasikan bahwa kemiripan visual antara daun sehat dengan daun yang mengalami infeksi ringan dapat menjadi sumber ambiguitas bagi model. Kondisi pencahayaan yang tidak merata, kualitas citra yang bervariasi, serta perbedaan tingkat keparahan penyakit juga berpotensi memengaruhi performa prediksi. Dengan demikian, meskipun *Xception* menunjukkan performa yang baik secara umum, model masih memiliki keterbatasan dalam membedakan kelas dengan karakteristik visual yang saling tumpang tindih.

Setelah diperoleh hasil metrik evaluasi, implementasi model dilakukan dengan *deployment* aplikasi berbasis *Flask*. Sistem disiapkan untuk menerima masukan berupa gambar daun padi dari pengguna. Ketika pengguna mengunggah gambar daun padi, sistem melakukan *preprocessing* yaitu perubahan ukuran menjadi  $128 \times 128$  piksel dan normalisasi nilai piksel agar sesuai format input model. Setelah itu, citra dikirim ke model *Xception* untuk prediksi pada empat kelas, yaitu *bacterial leaf blight*, *brown spot*, *leaf blast*, dan *healthy*.



Gambar 8. Tampilan Hasil Deployment Menggunakan Flask

Hasil klasifikasi tersebut akan ditampilkan secara langsung di halaman web dalam bentuk antarmuka yang informatif dan mudah dipahami. Tampilan hasil prediksi menampilkan model yang digunakan, kelas penyakit daun padi yang terdeteksi, serta tingkat kepercayaan model terhadap hasil tersebut. Selain itu, sistem juga menampilkan informasi tambahan yang berguna bagi pengguna, seperti gejala penyakit, penyebab, dan langkah pencegahan sesuai dengan label hasil prediksi. Informasi ini disajikan dalam format visual yang terstruktur dengan ikon dan warna berbeda untuk setiap kategori agar memudahkan pengguna dalam membaca hasil analisis.

### ¶ Penyebab

Bacterial leaf blight disebabkan oleh bakteri *Xanthomonas oryzae* dan menyebar cepat saat musim hujan.

### ▢ Pencegahan

- Gunakan benih bersertifikat tahan BLB.
- Sanitasi lahan dan alat pertanian.
- Rotasi tanaman dengan non-padi.

### ▢ Referensi

- TNAU - Penyakit BLB
- BPPM Lembang - Bacterial Blight

Gambar 9. Tampilan Hasil Deteksi

Pada bagian bawah tampilan hasil, juga disertakan referensi pendukung dari sumber terpercaya yang dapat membantu pengguna memahami lebih dalam mengenai penyakit yang terdeteksi. Dengan adanya bagian referensi ini, sistem tidak hanya berfungsi sebagai alat klasifikasi otomatis, tetapi juga sebagai sarana edukatif bagi petani, mahasiswa, maupun peneliti dalam mengenali berbagai jenis penyakit daun padi.

Sebagai bagian dari evaluasi akhir, dilakukan pula pengujian sistem menggunakan beberapa gambar secara manual di luar dataset pelatihan. Pengujian sistem aplikasi pada penelitian ini dilakukan dalam lingkungan *localhost* sebagai tahap verifikasi fungsional dan teknis dari integrasi model *deep learning* ke dalam aplikasi berbasis web. Pengujian difokuskan pada aspek fungsionalitas sistem dan performa inferensi model, tanpa melibatkan pengguna akhir maupun penyimpanan data berbasis database. Pendekatan ini bertujuan untuk memastikan bahwa model *Xception* dapat dijalankan dengan baik dalam arsitektur aplikasi web sederhana. Hasil pengujian tersebut ditampilkan dalam Tabel 4.

TABEL 4  
PENGUJIAN SISTEM

No.	Gambar Input	Prediksi	Keterangan
1.	Daun padi dengan penyakit Bacterial Leaf Blight	Bacterial Leaf Blight	Sesuai
2.	Daun padi dengan penyakit Brown Spot	Brown Spot	Sesuai
3.	Daun padi Sehat	Healthy	Sesuai
4.	Daun padi dengan penyakit Leaf Blast	Leaf Blast	Sesuai
5.	Daun padi dengan penyakit Bacterial Leaf Blight	Brown Spot	Tidak Sesuai
6.	Daun padi Sehat	Healthy	Sesuai
7.	Daun Padi Sehat	Healthy	Sesuai
8.	Daun padi dengan penyakit Brown Spot	Bacterial Leaf Blight	Tidak Sesuai
9.	Daun padi dengan penyakit Leaf Blast	Leaf Blast	Sesuai

No.	Gambar Input	Prediksi	Keterangan
10.	Daun padi dengan penyakit Bacterial Leaf Blight	Bacterial Leaf Blight	Sesuai

Pengujian ini bertujuan untuk melihat bagaimana model bekerja pada citra yang bervariasi dalam hal warna, intensitas cahaya, maupun tingkat kejelasan gejala penyakit. Dari sepuluh sampel uji, delapan di antaranya berhasil diprediksi dengan benar, sementara dua sampel mengalami kesalahan deteksi. Kesalahan prediksi tersebut menunjukkan bahwa penyakit dengan pola bercak yang serupa dapat menimbulkan ambiguitas model dalam beberapa kondisi. Meski masih terdapat beberapa kesalahan prediksi pada kelas tertentu, performa keseluruhan menunjukkan bahwa model ini cukup andal dan dapat dijadikan dasar untuk implementasi aplikasi deteksi penyakit daun padi yang digunakan secara langsung oleh pengguna.

Hasil ini menunjukkan potensi penerapan sistem berbasis kecerdasan buatan sebagai alat bantu deteksi dini penyakit tanaman di tingkat lapangan. Model klasifikasi citra daun padi yang diintegrasikan ke dalam aplikasi berbasis web memungkinkan petani atau penyuluh pertanian untuk melakukan pemantauan kondisi tanaman secara cepat tanpa bergantung sepenuhnya pada pemeriksaan manual. Dengan adanya sistem ini, tindakan pengendalian seperti pemilihan jenis pestisida, penyesuaian pola perawatan, maupun pencegahan penyebaran penyakit dapat dilakukan lebih tepat waktu dan terarah. Penerapan teknologi ini sejalan dengan konsep pertanian presisi, di mana keputusan budidaya didukung oleh data dan analisis otomatis, sehingga berpotensi meningkatkan efisiensi produksi, menekan biaya operasional, serta mengurangi risiko kerugian akibat keterlambatan penanganan penyakit tanaman.

#### IV. KESIMPULAN

Kebutuhan padi di Indonesia yang terus meningkat menuntut adanya upaya untuk menjaga stabilitas produksi dan mencegah kegagalan panen. Salah satu langkah penting dalam menjaga keberlanjutan hasil panen adalah melakukan deteksi dini terhadap penyakit daun padi yang dapat menyebabkan penurunan produktivitas secara signifikan. Penelitian ini berhasil mengimplementasikan model *Deep Learning* berbasis arsitektur *Xception* untuk melakukan identifikasi dan klasifikasi penyakit daun padi secara otomatis dari citra, sehingga mampu memberikan solusi yang cepat, akurat, dan efisien dalam mendukung pengendalian penyakit tanaman.

Berdasarkan hasil eksperimen, model *Xception* yang dilatih selama 10 epoch menghasilkan akurasi training sebesar 93% dan akurasi testing sebesar 89%, menunjukkan konsistensi antara data pelatihan dan data validasi tanpa indikasi *overfitting* yang signifikan. Evaluasi lanjutan menggunakan *classification report* memperlihatkan nilai *precision* 89%, *recall* 89%, dan *F1-score* 89%, yang menandakan kemampuan model dalam membedakan empat

kelas penyakit secara akurat dan seimbang. Kinerja model juga dikonfirmasi melalui pengujian manual pada citra baru, di mana sebagian besar sampel berhasil diprediksi dengan benar, meskipun terdapat beberapa kesalahan pada kelas dengan kemiripan gejala visual. Hasil ini menunjukkan bahwa model *Xception* memiliki potensi kuat untuk dikembangkan sebagai sistem deteksi penyakit daun padi berbasis citra yang cepat, akurat, dan efisien. Teknologi ini membuka peluang penerapan lebih luas dalam sektor pertanian digital, khususnya pada sistem pemantauan kesehatan tanaman secara otomatis untuk mendukung pengambilan keputusan di tingkat lapangan.

#### DAFTAR PUSTAKA

- [1] R. A. Saputra, S. Wasyanti, A. Supriyatna, and D. F. Saefudin, "Penerapan Algoritma Convolutional Neural Network Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi," *JURNAL SWABUMI*, vol. 9, no. 2, Sep. 2021, doi: <https://doi.org/10.31294/swabumi.v9i2.11678>.
- [2] Arsani and Ade, "The Future of Indonesia and Global Agriculture: Rice Consumption and Agricultural Modernization," *Jurnal Litbang Sukowati Media Penelitian dan Pengembangan*, vol. 4, pp. 57–64, Nov. 2020, doi: 10.32630/sukowati.v4i1.132.
- [3] R. Suciani, D. A. Anugra, and E. Faisal, "Deteksi Penyakit Daun Padi Menggunakan Deep Learning Dengan Arsitektur CNN," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 8, no. 5, 2025, doi: <https://doi.org/10.31539/9112kc41>.
- [4] Badan Pusat Statistik, "Luas panen padi pada Agustus 2025 sebesar 1,11 juta hektare dengan produksi padi diperkirakan sebanyak 5,63 juta ton gabah kering giling (GKG)," BPS.
- [5] Xiaolong Sun, Jing Lyu, and Candi Ge, "Knowledge and Farmers' Adoption of Green Production Technologies: An Empirical Study on IPM Adoption Intention in Major Indica-Rice-Producing Areas in the Anhui Province of China," *Int J Environ Res Public Health*, vol. 19, no. 21, pp. 1–16, Nov. 2022, doi: 10.3390/ijerph192114292.
- [6] Yibin Wang, Haifeng Wang, and Zhaohua Peng, "Rice Diseases Detection and Classification Using Attention Based Neural Network and Bayesian Optimization," *Expert Syst Appl*, vol. 178, p. 114770, Sep. 2021, doi: <https://doi.org/10.1016/j.eswa.2021.114770>.
- [7] Qudsiah Nur Azizah, "Penyakit Daun Jagung Menggunakan Metode Convolutional Neural Network AlexNet," *Sudo Jurnal Teknik*, vol. 2, no. 1, pp. 28–33, 2023, doi: <https://doi.org/10.56211/sudo.v2i1.227>.
- [8] Didit Iswantoro and Dewi Handayani UN, "Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN)," *Jurnal Ilmiah Universitas Batanghari Jambi*, vol. 22, no. 2, p. 900, Jul. 2022, doi: 10.33087/jiubj.v22i2.2065.
- [9] R. Ardiansyah, M. Ayu, D. Widayadara, and U. Mahdyah, "Deteksi Penyakit Daun Mangga Menggunakan Convolutional Neural Network Untuk Analisis Komperasi Arsitektur VGG16, Xception," 2025. doi: <https://doi.org/10.29407/bv3y4028>.
- [10] A. Wulandari, R. Regasari, M. Putri, and A. S. Budi, "Implementasi Algoritma Xception pada Sistem Deteksi Katarak Menggunakan Raspberry Pi Berbasis Citra Mata," Apr. 2025. doi: <https://j-ptik.ub.ac.id/index.php/j-ptik/article/view/14684>.
- [11] Fakhri Habib Hawari, Faslah Fadillah, Muhamad Rifqi Alviandi, and Toni Arifin, "Klasifikasi Penyakit Padi Menggunakan Algoritma CNN (Convolutional Neural Network)," *JURNAL RESPONSIF*, vol. 4, no. 2, pp. 184–189, Aug. 2022, doi: <https://doi.org/10.51977/jti.v4i2.856>.
- [12] Syaikhul Anam Alidrus, Mustafa Aziz, and Oddy Virgantara Putra, "Deteksi Penyakit Pada Daun Tanaman Padi Menggunakan Metode Convolutional Neural Network." 2021.

- [13] Z. Firmansyah, D. Asmarajati, M. Hidayat, N. Hasanah, M. Alif Muwafiq Baihaqy, and S. Rohman, "Sistem Deteksi Dan Klasifikasi Penyakit Tanaman Padi Berdasarkan Daun Menggunakan Algoritma Convolutional Neural Network (CNN) Dengan Arsitektur ResNet-50," *TECHNOMEDIA : Informatics and Computer Science*, vol. 2, no. 2, pp. 3047–2180, Jun. 2025, doi: 10.58641.
- [14] G. V. de Andrade, S. R. dos Santos, I. P. C. A. da Silva, E. A. M. Pereira, and E. de A. Barboza, "Evaluating the Robustness of Convolutional Neural Networks for Disease Diagnosis in Mango Leaves," Dec. 2025, doi: 10.48550/arXiv.2512.13641.
- [15] X. Wu, R. Liu, H. Yang, and Z. Chen, "An Xception Based Convolutional Neural Network for Scene Image Classification with Transfer Learning," in *2020 2nd International Conference on Information Technology and Computer Application (ITCA)*, IEEE, Dec. 2020, pp. 262–267. doi: 10.1109/ITCA52113.2020.00063.
- [16] D. P. Pamungkas and M. F. Amrulloh, "Klasifikasi Penyakit Daun Bawang Menggunakan Algoritma CNN Xception," *JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 8, no. 1, pp. 359–366, Aug. 2025, doi: 10.29100/jipi.v10i1.5875.
- [17] M. S. Akter, H. Shahriar, S. Sneha, and A. Cuzzocrea, "Multi-class Skin Cancer Classification Architecture Based on Deep Convolutional Neural Network," in *2022 IEEE International Conference on Big Data (Big Data)*, IEEE, Dec. 2022, pp. 5404–5413. doi: 10.1109/BigData55660.2022.10020302.
- [18] W. Hidayat, E. Utami, A. F. Iskandar, A. D. Hartanto, and A. B. Prasetyo, "Perbandingan Performansi Model pada Algoritma K-NN terhadap Klasifikasi Berita Fakta Hoaks Tentang Covid-19," *Edumatic: Jurnal Pendidikan Informatika*, vol. 5, no. 2, pp. 167–176, Dec. 2021, doi: 10.29408/edumatic.v5i2.3664.