



Perbandingan Metode Inception dan Xception dalam Mendeteksi Penyakit Tanaman Daun Pisang

Andika Yudha Utama¹, Iqbal Maulana²

Universitas Singaperbangsa Karawang

Abstrak

Received: 14 Januari 2026

Revised: 28 Januari 2026

Accepted: 2 Februari 2026

Tanaman pisang merupakan salah satu komoditas unggulan di Indonesia, namun rentan terserang penyakit daun seperti Cordana, Sigatoka, dan Pestalotiopsis, yang dapat menurunkan kualitas dan hasil panen. Penelitian ini bertujuan membandingkan kinerja dua arsitektur deep learning, yaitu Inception dan Xception, dalam mendeteksi penyakit daun pisang berdasarkan citra gambar. Metodologi yang digunakan mengadopsi CRISP-DM, meliputi tahap pemahaman bisnis, persiapan data, pemodelan, dan evaluasi. Dataset diperoleh dari Kaggle dengan empat kelas: sehat, Cordana, Sigatoka, dan Pestalotiopsis. Evaluasi model dilakukan menggunakan akurasi, precision, recall, dan f1-score. Hasil menunjukkan bahwa model Xception dengan skema undersampling memiliki performa terbaik dengan akurasi 95,19%, precision 83,65%, recall 87,99%, dan f1-score 88,26%. Hasil ini menunjukkan Xception lebih efektif dalam mendeteksi penyakit daun pisang dan berpotensi mendukung produktivitas pertanian.

Kata kunci: Deteksi penyakit daun pisang, Deep learning, Inception, Xception, CRISP-DM.

(*) Corresponding Author: andikayuu18@gmail.com

How to Cite: Utama, A., & Maulana, I. (2026). Perbandingan Metode Inception dan Xception dalam Mendeteksi Penyakit Tanaman Daun Pisang. *Jurnal Ilmiah Wahana Pendidikan*, 12(7.D), 26-34. Retrieved from <https://jurnal.peneliti.net/index.php/JIWP/article/view/12664>

INTRODUCTION

Tanaman pisang (*Musa sp.*) merupakan salah satu komoditas hortikultura unggulan yang berasal dari Asia Tenggara dan tumbuh subur di wilayah beriklim tropis, termasuk Indonesia. Sebagai negara penghasil pisang terbesar di dunia, Indonesia mencatatkan peningkatan produksi pisang dari 7,28 juta ton pada tahun 2019 menjadi 8,05 juta ton pada tahun 2022, dan mencapai 9,69 juta ton pada tahun 2024 (BPS & Direktorat Jenderal Hortikultura). Peningkatan produksi ini dipengaruhi oleh kandungan gizi pisang yang tinggi, harga yang relatif terjangkau, ketersediaan bahan baku yang melimpah, serta ketahanan tanaman pisang yang dapat dipanen sepanjang tahun tanpa tergantung musim. Buah pisang kaya akan karbohidrat, vitamin A, vitamin C, vitamin B6, serta rendah kolesterol, sehingga menjadi sumber energi dan nutrisi penting bagi masyarakat.

Meskipun memiliki banyak keunggulan, budidaya pisang di Indonesia masih menghadapi tantangan serius terkait serangan hama dan penyakit. Minimnya informasi yang diterima masyarakat serta terbatasnya jumlah ahli fitopatologi menyebabkan lambatnya penanganan penyakit pada tanaman pisang, yang berdampak pada penurunan kualitas dan produktivitas tanaman (Anjhelina Maharani, Fitri Laxmi, & Riana, 2021).

Seiring dengan perkembangan teknologi, penerapan metode deep learning telah banyak digunakan dalam mendeteksi penyakit tanaman secara otomatis

melalui citra digital. Penelitian terdahulu menunjukkan bahwa model Xception mampu mendeteksi penyakit pada tanaman padi dengan akurasi rata-rata sebesar 99,73% pada dataset publik dan 98,05% pada dataset domestik (Meena, Joshi, & Raghuwanshi, 2024). Selain itu, model Xception juga berhasil mendeteksi penyakit daun pada tanaman tomat dengan tingkat akurasi 85,84% (Arifin N. dkk., 2024). Penelitian lainnya mengungkapkan bahwa model Inception memiliki akurasi 85% dalam mendeteksi patogen pada gambar daun (Karthi, 2024).

Dengan mempertimbangkan keberhasilan kedua model tersebut, penelitian ini memanfaatkan pendekatan deep learning berbasis transfer learning dengan menggunakan model Inception dan Xception untuk mendeteksi penyakit pada daun tanaman pisang. Penggunaan metode ini diharapkan dapat memberikan solusi yang lebih akurat dan efisien dibandingkan metode tradisional, sehingga mendukung upaya peningkatan produktivitas pertanian pisang di Indonesia (Masrurroh, Surarso, & Warsito, 2023). Penelitian ini bertujuan untuk membangun dan mengevaluasi model Inception dan Xception dalam mengidentifikasi penyakit pada daun pisang, serta

METHODS

Penelitian ini menggunakan pendekatan CRISP-DM (*Cross Industry Standard Process for Data Mining*), yang merupakan metodologi standar dan banyak diterapkan dalam proyek data mining serta machine learning. Metodologi ini melakukan pendekatan 4 tahapan dari CRISP-DM yaitu:

1. Pendefinisian Masalah :

Penelitian ini diawali dengan identifikasi permasalahan terkait penurunan produksi pisang akibat penyakit pada daun yang dapat mengganggu proses fotosintesis. Untuk mengatasi permasalahan tersebut, penelitian ini menerapkan metode transfer learning dengan memanfaatkan arsitektur Inception dan Xception dalam mendeteksi serta mengklasifikasikan penyakit pada daun pisang secara otomatis.

2. Mempersiapkan Data :

Pengumpulan data dalam penelitian ini dilakukan dengan menggunakan dataset *Banana Leaf Disease* yang diunduh dari situs Kaggle dan bersifat publik. Dataset ini terdiri dari gambar daun pisang yang telah dikategorikan ke dalam empat kelas, yaitu *Healthy*, *Cordana*, *Sigatoka*, dan *Pestalotiopsis*. Data tersebut kemudian diproses dan dipersiapkan untuk memastikan kualitas serta keberhasilan model yang akan dibangun. Tahap ini meliputi identifikasi dan penyesuaian data guna menemukan pola yang relevan, sehingga dapat mendukung prediksi yang akurat pada proses klasifikasi penyakit daun pisang. Dapat dilihat dataset yang didapat dengan 4 kategori yaitu *Healthy*, *Cordana*, *Sigatoka*, dan *Pestalotiopsis*

Tabel 1. Dataset Citra Gambar

Kategori	Jumlah Data
<i>Healthy</i>	128
<i>Cordana</i>	162
<i>Sigatoka</i>	473

Ketidakseimbangan jumlah data antar kategori diatasi dengan menerapkan teknik *undersampling*. Teknik ini dilakukan dengan mempertahankan seluruh data pada kelas minoritas dan mengurangi jumlah data pada kelas mayoritas agar setiap kategori memiliki jumlah data yang sama. Tujuan dari *undersampling* adalah untuk mencegah model terlalu condong memprediksi kategori dengan jumlah data yang lebih banyak, sehingga dapat meminimalkan bias dan meningkatkan akurasi klasifikasi. Proses *Undersampling Data* dapat dilihat pada **Tabel 2**.

Tabel 2. Proses *Undersampling Data*


Kategori	Jumlah Data Sebelum Proses Under Sampling	Jumlah Data Sesudah Proses Under Sampling
<i>Healthy</i>	128	128
<i>Cordana</i>	162	128
<i>Sigatoka</i>	473	128
<i>Pestalotiopsis</i>	173	128

Selanjutnya data akan dilakukan pemisahan data yang akan digunakan untuk pelatihan model dan pengujian model. Rasio perbandingan antara data latih dan data uji adalah 80 : 20. Proses under sampling dijelaskan pada **Tabel 3** berikut

Tabel 3. Proses Pemisahan Data

Kategori	Jumlah Data	Jumlah Data Latih (80%)	Jumlah Data Uji (20%)
<i>Healthy</i>	128	102	26
<i>Cordana</i>	128	102	26
<i>Sigatoka</i>	128	102	26
<i>Pestalotiopsis</i>	128	102	26

Tahap selanjutnya adalah augmentasi gambar yang dilakukan untuk meningkatkan jumlah dan keragaman data citra yang digunakan dalam pelatihan model. Teknik ini bertujuan untuk memperkaya representasi data

**Gambar 1** Ilustrasi Augmentasi Gambar

dan mengurangi risiko overfitting. Beberapa transformasi yang diterapkan dalam proses augmentasi meliputi *rescale*, *rotation* (*rotation range*), pembalikan vertikal (*vertical flip*), *range* (*shear range*), *zoom* (*zoom range*), serta pengisian piksel kosong menggunakan mode tertentu (*fill mode*). Ilustrasi dari hasil augmentasi citra dapat dilihat pada **Gambar 1**.

3. Modelling :

Kinerja model machine learning yang kurang optimal tidak selalu disebabkan oleh adanya kesalahan atau bug dalam arsitektur model, melainkan dapat disebabkan oleh keterbatasan data atau kompleksitas fitur. Oleh karena itu, pada penelitian ini diterapkan pendekatan *transfer learning* untuk melatih model secara lebih efisien dan akurat. Arsitektur yang digunakan adalah Xception dan Inception, yang telah terbukti efektif dalam pengenalan citra dan diharapkan mampu memberikan hasil evaluasi model yang baik. Proses pembuatan dan pelatihan model dapat dilihat pada Tabel 4.

Tabel 4 Proses Pembuatan Model Iception

Layer (type)	Output Shape	Parameter
Inception_v3(Functional)	(None, 3, 3, 2048)	21802784
flatten (Flatten)	(None, 18432)	0
dense (dense)	(None, 4)	73732
Total parameter : 21,876,516		
Trainable parameter : 73,732		
Non-trainable params : 21,802,784		

Selanjutnya rincian lapisan model *Machine Learning* yang dibuat dengan metode Xception pada Tabel 5.

Tabel 5 Lapisan Model Xception

Layer (type)	Output Shape	Parameter
xception (Functional)	(None, 5, 5, 2048)	20861480
flatten (Flatten)	(None, 51200)	0
dense (Dense)	(None, 4)	204804
Total parameter : 21,066,284		
Trainable parameter : 204,804		
Non-trainable parameter: 20,861,480		

4. Evaluasi Model :

Setelah proses pelatihan model selesai, tahap selanjutnya adalah evaluasi untuk menilai kemampuan model dalam memprediksi target pada data baru. Evaluasi dilakukan dengan menggunakan data uji yang telah diberi label, sehingga memungkinkan perbandingan antara hasil prediksi model dengan nilai target sebenarnya. Penggunaan data pelatihan untuk evaluasi tidak dianjurkan karena dapat menyebabkan model hanya menghafal data tanpa benar-benar mempelajari pola yang berguna. Oleh karena itu, evaluasi dilakukan dengan menggunakan data yang belum

pernah dilihat oleh model selama pelatihan. Penilaian kinerja model dilakukan melalui perhitungan metrik evaluasi, yaitu *accuracy*, *precision*, *recall*, dan *f1 score*. Metrik ini digunakan untuk mengukur sejauh mana hasil prediksi model sesuai dengan nilai sebenarnya. Ilustrasi proses evaluasi model disajikan pada Tabel 5.

Tabel 5 Ilustrasi Proses Evaluasi Model

Kategori	Akurasi	Recall	Precision	F1 Score
A	0.93	0.97	0.80	0.94
B	0.87	0.95	0.91	0.89
C	0.85	0.82	0.83	0.88

RESULTS & DISCUSSION

Results


1. Model Training

Proses pelatihan model *Machine Learning* pada seluruh skema memerlukan waktu yang cukup lama. Waktu dinyatakan dalam satuan detik. Lalu, terdapat juga variabel *val_loss* dan *val_accuracy* yang digunakan untuk memvalidasi sebuah model selama proses pelatihan. Variabel ini dapat menjadi acuan apakah model akan mengalami *overfitting* atau *underfitting* jika terdapat perbedaan nilai yang cukup jauh atau sangat besar. Proses pelatihan model ini dibuat 50 *epoch* atau iterasi, dapat dilihat pada Tabel 6, hasil ini telah diringkaskan di Google Colab ketika proses pelatihan model selesai.

Tabel 6 Waktu Pelatihan Model

Kategori	Metode	Total Waktu Train	Rata – Rata Waktu Train / Epochs
Skema Undersampling	Inception	1 jam 4 menit	77 detik
	Xception	1 jam 13 menit	88 detik

Setelah proses pelatihan sudah dilakukan dan selesai, metrik *accuracy* dan *loss* akan divisualisasikan dalam bentuk grafik garis untuk menunjukkan apakah model yang dibuat menghasilkan nilai baik atau tidak, dan memberitahu apakah mengalami *overfitting* atau *underfitting*. Pada Gambar 2. Model *machine learning* yang sudah dilatih tidak mengalami proses *underfitting* ataupun *overfitting*. Hal tersebut ditandai oleh parameter *train accuracy* dan *test accuracy* yang memiliki nilai yang tidak berbeda jauh. Selain itu, parameter *training loss* dan *test loss* juga tidak memiliki perbedaan nilai yang sangat jauh.




Gambar 2. Visualisasi Model Metode Inception

Pada Gambar 3 model *machine learning* yang sudah dilatih tidak mengalami proses *underfitting* dan *overfitting*. Hal tersebut dapat dilihat dari parameter *train accuracy* dan *test accuracy* yang memiliki nilai tidak berbeda jauh. Selain itu, parameter *training loss* dan *test loss* juga tidak memiliki perbedaan nilai yang sangat jauh.

2. Evaluasi Model


Setelah melatih model yang digunakan yaitu metode Inception dan Xception, selanjutnya model *machine learning* akan dievaluasi menggunakan *confusion matrix*. Tujuan evaluasi ini adalah untuk menilai baik kualitas model *machine learning* yang dihasilkan dalam pendeteksi penyakit tanaman daun pisang. Pengujian ini dilakukan menggunakan data uji yang sudah dipisahkan, sehingga jumlah nilai pada *confusion matrix* sesuai dengan jumlah data uji.

Pada Gambar 3 menunjukkan bahwa model *machine learning* dari Inception yang dibuat dapat menghasilkan prediksi yang benar. Hal tersebut dapat dilihat dari tingginya jumlah label yang benar dan label prediksi yang sesuai.



Gambar 3 Confusion Matrix dengan Metode Inception

Kemudian, Gambar 4 menunjukkan bahwa model *machine learning* dari Xception yang dibuat dapat menghasilkan prediksi yang benar. Hal tersebut dapat dilihat dari tingginya jumlah label yang benar dan label prediksi yang sesuai.



Gambar 4 *Confusion Matrix* dengan Metode Xception

Berdasarkan dari beberapa gambar *confusion matrix* diatas, dilihat bahwa *confusion matrix* ini memiliki *True label* dan *Predict label*. Angka-angka pada label tersebut saling bersilangan dan sesuai dengan seberapa banyak model yang dihasilkan memiliki prediksi yang benar. sementara angka yang lainnya menunjukkan seberapa banyak model yang dihasilkan memiliki prediksi yang salah.

Untuk ditahap selanjutnya dan memahami nilai *confusion matrix* lebih lanjut, tabel dibawah ini akan menjelaskannya. Pada tabel tersebut, menjelaskan bahwa nilai-nilai yang disajikan dalam bentuk persentase untuk mempermudah analisis kinerja model yang digunakan dengan metode Inception dan metode Xception.

Tabel 7 Nilai Rata - Rata *Confusion Matrix*

Metode	Akurasi	Precision	Recall	F1 Score
Inception	94,23%	80,30%	79,80%	87,29%
Xception	95,19%	83,65%	87,99%	88,26%

Berdasarkan hasil *confusion matrix* pada Tabel 7 dapat disimpulkan bahwa model *machine learning* yang dihasilkan dengan menggunakan metode Xception lebih unggul dibandingkan model *machine learning* dengan metode Inception, dapat dilihat dari nilai rata-rata akurasi, presisi, recall, dan f1 score.

CONCLUSION

Berdasarkan hasil penelitian yang telah dilakukan, penerapan arsitektur *deep learning* pada model *machine learning* dengan metode Inception dan Xception mampu mendeteksi penyakit pada tanaman daun pisang berdasarkan citra gambar dalam kondisi terang. Selain itu model yang dihasilkan dapat melakukan klasifikasi pada daun pisang dengan kategori daun pisang *healthy*, daun pisang terinfeksi *cordana*, daun pisang terinfeksi *sigatoka*, dan daun pisang terinfeksi *pestalotiopsis*.

Selanjutnya, berdasarkan hasil evaluasi model Inception dan Xception dapat disimpulkan bahwa model *machine learning* dengan metode Xception lebih unggul dibandingkan model *machine learning* dengan metode Inception. Hal tersebut dapat dilihat pada Tabel 7 menunjukkan bahwa metode Xception memiliki nilai persentase akurasi 95,19%, precision sebesar 83,65%, recall 87,99%, dan f1 score 88,26%.

REFERENCES

- Aji, O. R., Sari, A. K., & Putri, A. (2022). *ISOLASI DAN UJI AKTIVITAS ANTAGONISME JAMUR ENDOFIT TANAMAN PISANG (Musa paradisiaca L .) TERHADAP Fusarium oxysporum Program Studi Laboratorium Mikrobiologi , FSTT , Universitas Ahmad Dahlan , Program Studi Biologi , FSTT , Universitas Ahmad Dahlan , In.* 10(1), 10–17.
- Alamsyah, D., & Pratama, D. (2020). Implementasi Convolutional Neural Networks (CNN) untuk Klasifikasi Ekspresi Citra Wajah pada FER-2013 Dataset. *Jurnal Teknologi Informasi*, 4(2), 350–355. <https://doi.org/10.36294/jurti.v4i2.1714>
- Andera, R., Priyatiningsih, & Mutiara, M. (2021). Deteksi Dan Identifikasi Penyakit Tanaman Pisang (*Musa Acuminata*) Oleh Cendawan *Cordana Musae* Dengan Beberapa Metode. *Prosiding SEMNAS BIO*, 01(2021), 700–709.
- Anggraini, W., (2020) *Deep Learning Untuk Deteksi Wajah Yang Berhijab Menggunakan Algoritma Convolutional Neural Network (CNN) Dengan Tensorflow*.
- Anggiratih, E., Siswanti, S., Octaviani, S. K., & Sari, A. (2021). Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 dengan Transfer Learning. *Jurnal Ilmiah SINUS*, 19(1), 75. <https://doi.org/10.30646/sinus.v19i1.526>
- Bhuiyan, M. A. B., Abdullah, H. M., Arman, S. E., Saminur Rahman, S., & Al Mahmud, K. (2023). BananaSqueezeNet: A very fast, lightweight convolutional neural network for the diagnosis of three prominent banana leaf diseases. *Smart Agricultural Technology*, 4(December 2022), 100214. <https://doi.org/10.1016/j.atech.2023.100214>
- Eka, A., P., Farid, M., N., Riandaru, V., P., Kalirungkut, J. R., Rungkut, K., Rungkut, K., Sby, K., & Timur, J. (2023). *JEPIN (Jurnal Edukasi dan Penelitian Informatika) Klasifikasi Jenis Rempah Menggunakan Convolutional Neural Network dan Transfer Learning*. 9(1), 12–18.
- Darmasita. (2020). Deteksi Penggunaan Masker Menggunakan Xception Transfer Learning. *JURNAL INSTEK (Informatika Sains dan Teknologi)*, 5, 279–288.

- Ghani, M. A., Fahrizal, F., & Lawi, A. (2021). Implementasi Arsitektur Xception Untuk Klasifikasi Citra Covid-19 Radiography. *Konferensi Nasional Ilmu Komputer (KONIK)*, 413–419.
- Istiqomah, A. M. (2020). *Klasifikasi Citra Menggunakan Metode Convolutional Neural Network Arsitektur Inception V4 Berbasis Android Pada Dataset Flower Recognition* Ainun Mardiyah Istiqamah. 13–20. http://repository.unhas.ac.id/id/eprint/804/%0Ahttp://repository.unhas.ac.id/id/eprint/804/2/H13116507_skripsi_1-2.pdf
- Kosasih, F. (2023). Estimasi Biomassa Tanaman Nanas Berdasarkan Lebar Daun Menggunakan Algoritma *Machine Learning*.
- Maharani, L. A., Laxmi, G. F., & Riana, F. (2021). Sistem Pakar Untuk Mendiagnosis Hama Dan Penyakit Tanaman Pisang Dengan Teorema Bayes. *Jurnal Ilmiah Teknologi Infomasi Terapan*, 8(1), 19–25. <https://doi.org/10.33197/jitter.vol8.iss1.2021.710>
- Masruroh, F., Surarso, B., Warsito, B., & Korespondensi, P. (2023). *Perbandingan Kinerja Inception-Resnetv2, Xception, Inception-V3, Dan Resnet50 Pada Gambar Bentuk Wajah Performance Comparison of Inception-Resnetv2, Xception, Inception-V3, and Resnet50 on Face Shape Images*. 10(1), 11–20. <https://doi.org/10.25126/jtiik.2023104941>
- Maulana, F. F., & Rochmawati, N. (2020). Klasifikasi Citra Buah Menggunakan Convolutional Neural Network. *Journal of Informatics and Computer Science (JINACS)*, 1(02), 104–108. <https://doi.org/10.26740/jinacs.v1n02.p104-108>
- Nugroho, P. A., Fenriana, I., & Arijanto, R. (2020). Implementasi Deep Learning Menggunakan Convolutional Neural Network (Cnn) Pada Ekspresi Manusia. *Algor*, 2(1), 12–21.
- Rasywir, E., Sinaga, R., & Pratama, Y. (2020). Evaluasi Pembangunan Sistem Pakar Penyakit Tanaman Sawit dengan Metode Deep Neural Network (DNN). *Jurnal Media ...*, 4(5), 1206–1215. <https://doi.org/10.30865/mib.v4i4.2518>
- Ryan, I., & Pigai, S. (2020). Morfologi tanaman pisang Jiikago berdasarkan kearifan lokal suku Mee di kampung Idaiyo distrik Obano kabupaten Paniai. *Jurnal Pertanian dan Peternakan*, 5(2), 1–8.
- Septian, M. R. D., Paliwang, A. A. A., Cahyanti, M., & Swedia, E. R. (2020). Penyakit Tanaman Apel Dari Citra Daun Dengan Convolutional Neural Network. *Sebatik*, 24(2), 207–212. <https://doi.org/10.46984/sebatik.v24i2.1060>
- Zunaidi, M., Pane, U. F. S. S., & Nasyuha, A. H. (2021). Analisis Teorema Bayes Dalam Mendiagnosa Penyakit Tanaman Pisang. *Jurnal Media Informatika Budidarma*, 5(4), 1302. <https://doi.org/10.30865/mib.v5i4.3225>