

Plant Image Classification Using Deep Learning with Xception Architecture and Fine-Tuning Techniques

Muhammad Amirul Mustofa^{1*}, Panca Dear², Afif Zainul Muttaqin³
Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Nahdlatul Ulama
Lampung

Corresponding Author: Muhammad Amirul Mustofa
amirmustofa814@gmail.com

ARTICLE INFO

Keywords : Image Classification, Deep Learning, Xception, Fine-Tuning, Plant Identification

Received : 02 June 2025

Revised : 20 June 2025

Accepted: 25 July 2025

©2025 Mustofa, Dear, Muttaqin: This is an open-access article distributed under the terms of the [Creative Commons Attribution 4.0 International](https://creativecommons.org/licenses/by/4.0/).



ABSTRACT

The decline in public knowledge about medicinal plants in Indonesia threatens cultural preservation and the utilization of biodiversity. This community service project aims to bridge this gap by developing a prototype of an automated plant identification tool. The community service process focused on designing and training an Artificial Intelligence-based system. The method used was deep learning with the Xception architecture, implementing transfer learning and fine-tuning strategies for optimization. All activities, from data collection to model testing, were carried out from September to December 2024. The result was a classification model with 98.05% accuracy. Consequently, this model has great potential to be developed into a publicly accessible application, supporting the preservation of traditional knowledge and botanical education.

Klasifikasi Citra Tanaman Menggunakan Deep Learning dengan Arsitektur Xception dan Teknik Fine-Tuning

Muhammad Amirul Mustofa^{1*}, Panca Dear², Afif Zainul Muttaqin³
Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Nahdlatul Ulama
Lampung

Corresponding Author: Muhammad Amirul Mustofa
amirmustofa814@gmail.com

ARTICLE INFO

Kata Kunci: Klasifikasi Citra, Deep Learning, Xception, Fine-Tuning, Identifikasi Tanaman

Received : 02 June 2025

Revised : 20 June 2025

Accepted: 25 Juli 2025

©2025 Mustofa, Dear, Muttaqin: This is an open-access article distributed under the terms of the [Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).



ABSTRAK

Menurunnya pengetahuan masyarakat mengenai tanaman obat di Indonesia mengancam kelestarian budaya dan pemanfaatan keanekaragaman hayati. Pengabdian ini bertujuan menjembatani kesenjangan tersebut dengan mengembangkan prototipe alat bantu identifikasi tanaman otomatis. Proses pengabdian berpusat pada perancangan dan pelatihan sistem berbasis *Artificial Intelligence*. Metode yang digunakan adalah *deep learning* dengan arsitektur Xception, menerapkan strategi *transfer learning* dan *fine-tuning* untuk optimasi. Seluruh kegiatan, mulai dari pengumpulan data hingga pengujian model, dilaksanakan dari September hingga Desember 2024. Hasilnya adalah sebuah model klasifikasi dengan akurasi 98,05%. Implikasinya, model ini sangat potensial untuk dikembangkan menjadi aplikasi yang mudah diakses publik, mendukung pelestarian pengetahuan tradisional dan edukasi botani.

PENDAHULUAN

Indonesia kaya akan keanekaragaman hayati, dengan sekitar 50.000 jenis tanaman, di mana 7.500 di antaranya memiliki potensi sebagai obat tradisional. Sejak dulu, masyarakat Indonesia secara turun-temurun sudah memanfaatkan tanaman-tanaman ini sebagai obat. Obat tradisional sering dianggap lebih aman dan memiliki efek samping yang minimal dibandingkan obat modern. Namun, belakangan ini pengetahuan masyarakat tentang tanaman obat semakin menurun. Keterbatasan memori dan banyaknya varietas tanaman obat membuat identifikasi menjadi sulit. Akibatnya, ribuan tanaman yang berpotensi sebagai obat tradisional banyak yang terbuang karena dianggap sebagai tanaman liar, sehingga potensi pemanfaatannya tidak maksimal. Jika ini terus berlanjut, budaya penggunaan tanaman obat tradisional di Indonesia terancam punah karena menurunnya pengetahuan masyarakat (Setiyono et al., 2023).

Lebih lanjut, identifikasi dan klasifikasi tanaman memiliki peran krusial di berbagai bidang, termasuk pertanian, botani, dan pendidikan. Misalnya, di sektor pertanian, kemampuan untuk membedakan jenis tanaman hias seringkali menjadi tantangan, di mana banyak orang kesulitan membedakan satu tanaman hias dengan yang lain. Oleh karena itu, dibutuhkan sebuah sistem informasi yang dapat menyediakan portal informasi mengenai tanaman, mempermudah identifikasi, dan menambah pengetahuan masyarakat (Mareta Tama & Candra Noor Santi, 2023).

Kemajuan pesat dalam teknologi komputasi, khususnya di bidang *Artificial Intelligence* (AI) dan *Machine Learning* (ML), menawarkan solusi untuk mengatasi permasalahan identifikasi ini (Mareta Tama & Candra Noor Santi, 2023). *Deep Learning*, sebagai salah satu cabang ML, telah menunjukkan kemampuan luar biasa dalam mengenali pola dan belajar dari data untuk membuat keputusan (Abdel-Jaber et al., 2022). *Convolutional Neural Network* (CNN) adalah salah satu algoritma *deep learning* yang sangat efektif dalam mendeteksi dan mengenali objek pada citra (Setiyono et al., 2023). CNN mampu mengekstraksi fitur-fitur penting dari gambar dan mengklasifikasikannya dengan akurasi tinggi (Dwiatmoko et al., 2024).

Meskipun demikian, pengembangan model *deep learning* yang optimal memerlukan strategi yang cermat, termasuk pra-pemrosesan data yang baik, augmentasi data untuk meningkatkan generalisasi, dan pemilihan arsitektur yang tepat. Teknik *transfer learning* seringkali menjadi pilihan yang efisien, di mana model yang telah dilatih pada dataset besar (seperti ImageNet) digunakan sebagai basis, kemudian disesuaikan (*fine-tuning*) dengan dataset spesifik yang lebih kecil. Model EfficientNetV2, misalnya, telah dipilih sebagai model dasar dalam penelitian identifikasi tanaman herbal karena performanya yang kompetitif, waktu pelatihan yang lebih cepat, dan efisiensi. Demikian pula, arsitektur Xception dikenal memiliki performa yang baik dalam klasifikasi citra. Berdasarkan uraian di atas, penelitian ini bertujuan untuk mengembangkan sistem klasifikasi citra tanaman otomatis menggunakan pendekatan *deep learning*. Dengan memanfaatkan arsitektur Xception dan teknik *fine-tuning*, penelitian ini berupaya menjawab tantangan identifikasi keanekaragaman hayati tanaman secara akurat dan efisien. Fokus penelitian ini adalah pada perancangan

arsitektur model, penerapan strategi pelatihan dua tahap (*transfer learning* dan *fine-tuning*), serta evaluasi kinerja model menggunakan metrik akurasi dan *loss* pada data uji yang independen. Diharapkan model yang dihasilkan dapat menjadi alat bantu yang andal dan akurat untuk identifikasi jenis tanaman otomatis yang efisien dan dapat diakses oleh masyarakat luas, mendukung pelestarian pengetahuan tanaman obat serta pengembangan di sektor pertanian dan botani.

TINJAUAN PUSTAKA

Deep Learning

Deep learning (DL) kini jadi bagian utama kecerdasan buatan (AI) modern. Teknologi ini udah bikin banyak kemajuan di berbagai bidang karena bisa menganalisis sistem yang rumit, contohnya buat memahami cara protein melipat dalam biologi, menemukan molekul baru di kimia, sampai interaksi partikel di fisika.

Bidang deep learning terus berkembang, apalagi dengan inovasi terbaru di arsitektur dan penerapannya. Deep learning juga udah banyak banget mengubah bidang AI, bisa dibilang udah mencapai kinerja yang luar biasa di banyak aplikasi. Ini karena deep learning punya kemampuan yang kuat buat menangani data dalam jumlah besar dan komputasi yang kompleks. Sebagai bagian dari machine learning (ML), deep learning memanfaatkan arsitektur yang terdiri dari banyak lapisan "node" atau neuron. Setiap lapisan ini dirancang buat memodelkan pola yang makin kompleks di dalam data (Mienye & Swart, 2024).

Convolutional Neural Networks (CNNs)

Convolutional Neural Networks (CNNs) telah menjadi inti dari berbagai terobosan dalam deep learning, terutama di bidang visi komputer, memungkinkan investigasi fitur informasi secara otomatis untuk deteksi retakan jalan. Berbeda dengan metode pemrosesan citra digital tradisional, CNNs dapat mempelajari pola dan representasi hierarkis langsung dari data, menghasilkan hasil yang lebih baik dalam pengenalan retakan. Banyak peneliti telah memanfaatkan arsitektur CNN dalam upaya deteksi dan kuantifikasi retakan, termasuk penggunaan Mask R-CNN untuk evaluasi retakan beton, jaringan fusi fitur multilayer berbasis Faster R-CNN untuk deteksi cacat permukaan terowongan, serta pendekatan berbasis visi menggunakan arsitektur CNN yang dalam untuk memantau retakan beton. Model-model seperti Faster R-CNN dan Mask R-CNN, yang merupakan varian CNN yang telah terbukti berhasil dalam visi umum, sedang diinvestigasi untuk tugas spesifik deteksi retakan jalan. Implementasi CNNs yang mendalam ini sangat penting untuk mengatasi tantangan deteksi retakan di lingkungan yang bervariasi dan kompleks (Xu et al., 2022).

Transfer Learning

Transfer learning (TL) adalah metodologi krusial dalam deep learning yang mengatasi tantangan ketersediaan data dengan memungkinkan pemanfaatan pengetahuan yang diperoleh dari satu domain atau tugas, yang memiliki banyak data berlabel, untuk meningkatkan kinerja model di domain atau tugas target

yang datanya terbatas atau sulit dikumpulkan. Metode ini sangat bermanfaat ketika data yang cukup tidak tersedia di domain target tetapi kumpulan data yang besar tersedia di domain sumber. Dalam TL, model yang sudah dilatih pada dataset besar, seperti ImageNet, digunakan sebagai basis, kemudian disesuaikan (*fine-tuning*) dengan dataset spesifik yang lebih kecil. Pendekatan TL ini telah terbukti meningkatkan kinerja secara signifikan dibandingkan dengan pendekatan tanpa transfer learning, dan telah diterapkan secara efektif dalam berbagai aplikasi seperti klasifikasi gambar medis, pengenalan wajah, dan deteksi retakan (Agarwal et al., 2021).

Xception

Arsitektur Xception, yang merupakan turunan dari Inception, dikenal karena efisiensi komputasi dan kemampuannya untuk mengekstraksi fitur multi-skala secara efektif dengan menggunakan konvolusi *depth-separable*. Dalam konteks klasifikasi citra tanaman, Xception mengurangi kompleksitas model dan risiko *overfitting* dibandingkan dengan arsitektur CNN konvensional, menjadikannya pilihan yang kuat untuk tugas deteksi dan klasifikasi penyakit tanaman yang membutuhkan kompetensi fitur yang beragam. Pendekatan hibrida seperti Inception-Xception (IX-CNN) yang menggabungkan lapisan Inception dan konvolusi *depth-separable* telah diusulkan untuk meningkatkan kinerja deteksi penyakit, terbukti dengan akurasi tinggi pada berbagai dataset tanaman seperti PlantVillage, Plant Doc, dan Rice Disease. Model ini secara signifikan meningkatkan ekstraksi fitur dan generalisasi, menjadikannya solusi yang menjanjikan untuk aplikasi pertanian cerdas (Shafik et al., 2025).

METODOLOGI

Kerangka Penelitian

Penelitian ini dilakukan melalui beberapa tahapan sistematis yang digambarkan dalam alur berikut:



Gambar 1. Kerangka Penelitian

Dataset Penelitian

Penelitian ini menggunakan dataset publik "Plants Type Datasets" yang bersumber dari Kaggle. Dataset ini berisi citra dari 30 kelas (jenis) tanaman yang berbeda. Dataset telah dibagi sebelumnya menjadi tiga direktori terpisah:

- `Train_Set_Folder`: Digunakan untuk melatih model.
- `Validation_Set_Folder`: Digunakan untuk memvalidasi kinerja model pada setiap *epoch* dan mencegah *overfitting*.
- `Test_Set_Folder`: Digunakan untuk pengujian akhir model setelah proses pelatihan selesai.

Data dimuat menggunakan utilitas `tf.keras.utils.image_dataset_from_directory` dengan konfigurasi *batch size* sebesar 32. Label dikodekan dalam format *categorical* (one-hot encoding).

Pra-pemrosesan dan Augmentasi Data

Sebelum dimasukkan ke dalam model, setiap citra melewati serangkaian tahap pra-pemrosesan dan augmentasi.

1. Penyesuaian Ukuran Citra: Semua citra, baik dari set pelatihan, validasi, maupun pengujian, diubah ukurannya menjadi 300×300 piksel. Ukuran ini dipilih untuk menyesuaikan dengan arsitektur model yang digunakan.
2. Augmentasi Data: Untuk meningkatkan generalisasi model dan mengurangi risiko *overfitting*, augmentasi data diterapkan secara *on-the-fly* hanya pada data pelatihan. Teknik augmentasi yang digunakan meliputi:
 - `Random Flip`: Membalik citra secara horizontal.
 - `Random Rotation`: Memutar citra secara acak hingga 0.2 radian.
 - `Random Zoom`: Melakukan perbesaran pada citra secara acak hingga 20%.
 - `Random Brightness`: Mengubah kecerahan citra secara acak dengan faktor hingga 0.2.
 - `Random Contrast`: Mengubah kontras citra secara acak dengan faktor hingga 0.2.
3. Normalisasi: Nilai piksel citra yang semula berada dalam rentang [0,255] dinormalisasi sesuai dengan standar yang dibutuhkan oleh arsitektur Xception. Proses ini dilakukan menggunakan fungsi `preprocess_input` dari Xception, yang umumnya mengubah skala piksel ke rentang [-1,1].

Arsitektur Model

Model yang diusulkan dalam penelitian ini dibangun menggunakan pendekatan transfer learning dengan arsitektur dasar Xception.

1. Model Dasar (Base Model): Arsitektur Xception yang telah dilatih sebelumnya pada dataset ImageNet digunakan sebagai ekstraktor fitur. Bobot dari ImageNet dimanfaatkan untuk mempercepat konvergensi dan meningkatkan kinerja. Lapisan klasifikasi asli dari Xception (`include_top=False`) dibuang untuk digantikan dengan lapisan kustom.
2. Kepala Klasifikasi Kustom (Custom Classification Head): Di atas output dari model dasar Xception, ditambahkan beberapa lapisan untuk melakukan klasifikasi akhir:

- GlobalAveragePooling2D: Mengubah feature map dari lapisan konvolusi terakhir menjadi sebuah vektor tunggal untuk mengurangi jumlah parameter secara signifikan.
- BatchNormalization: Menstabilkan dan mempercepat proses pelatihan.
- Dropout(0.5): Menerapkan regularisasi dengan menonaktifkan 50% neuron secara acak untuk mencegah overfitting.
- Dense(1024, activation='relu'): Lapisan tersembunyi (hidden layer) dengan 1024 neuron dan fungsi aktivasi ReLU.
- Dropout(0.3): Lapisan regularisasi kedua dengan rate 30%.
- Dense(30, activation='softmax'): Lapisan output dengan 30 neuron (sesuai jumlah kelas tanaman) dan fungsi aktivasi softmax untuk menghasilkan probabilitas klasifikasi untuk setiap kelas.

Skenario Pelatihan Model

Proses pelatihan dibagi menjadi dua tahap utama untuk memaksimalkan efektivitas transfer learning.

Tahap 1: Transfer Learning

- Tujuan: Melatih hanya lapisan kepala klasifikasi kustom yang baru ditambahkan.
- Konfigurasi:
 - Seluruh lapisan pada model dasar Xception dibekukan (`base_model.trainable = False`).
 - Optimizer: Adam dengan learning rate awal 0.001.
 - Fungsi Loss: `categorical_crossentropy`, karena ini adalah masalah klasifikasi multi-kelas.
 - Callback:
 - `EarlyStopping`: Menghentikan pelatihan jika `val_loss` tidak membaik setelah 5 epoch berturut-turut.
 - `ReduceLROnPlateau`: Mengurangi learning rate dengan faktor 0.2 jika `val_loss` tidak membaik setelah 3 epoch.

Tahap 2: Fine-Tuning

- Tujuan: Menyesuaikan sebagian bobot dari model dasar yang sudah terlatih agar lebih spesifik pada dataset tanaman.
- Konfigurasi:
 - Sebagian lapisan model dasar Xception dicairkan (`base_model.trainable = True`), yaitu 20 lapisan terakhir. Lapisan-lapisan awal yang mendeteksi fitur umum (seperti tepi dan tekstur) tetap dibekukan.
 - Optimizer: Adam dengan learning rate yang sangat rendah, yaitu 1×10^{-5} (0.00001). Hal ini penting untuk menghindari perubahan drastis pada bobot yang sudah terlatih (fenomena *catastrophic forgetting*).
 - Model dikompilasi ulang dan pelatihan dilanjutkan dari epoch terakhir Tahap 1.

- Callback yang sama (EarlyStopping dan ReduceLROnPlateau) tetap digunakan.

Metrik Evaluasi

Kinerja model dievaluasi menggunakan metrik standar untuk masalah klasifikasi. Evaluasi akhir dilakukan pada `test_data` untuk mendapatkan penilaian yang objektif. Metrik utama yang digunakan adalah:

- Akurasi (Accuracy): Metrik ini mengukur persentase prediksi yang benar dari keseluruhan data. Nilai akurasi diperoleh dengan cara membagi jumlah prediksi yang benar dengan jumlah total seluruh data.
- Loss (Categorical Crossentropy): Mengukur seberapa baik probabilitas prediksi model cocok dengan label sebenarnya. Nilai loss yang lebih rendah menunjukkan model yang lebih baik.

Selain evaluasi kuantitatif, analisis kualitatif juga dilakukan dengan memvisualisasikan grafik akurasi dan loss pelatihan versus validasi untuk setiap epoch. Grafik ini membantu dalam mengidentifikasi adanya overfitting atau underfitting dan efektivitas dari strategi fine-tuning.

Lingkungan Eksperimen dan Perangkat Keras

Seluruh proses eksperimen, mulai dari pemrosesan data, pelatihan model, hingga evaluasi, dijalankan pada platform komputasi awan Kaggle Notebooks. Untuk mengakselerasi proses pelatihan model deep learning yang intensif secara komputasi, penelitian ini memanfaatkan sumber daya Graphics Processing Unit (GPU). Secara spesifik, perangkat keras yang digunakan adalah NVIDIA Tesla T4.

Kerangka kerja perangkat lunak utama yang digunakan adalah TensorFlow dengan API level tinggi dari Keras. Pustaka pendukung lainnya meliputi NumPy dan Pandas untuk manipulasi data, serta Matplotlib untuk visualisasi hasil penelitian.

HASIL PENELITIAN

Hasil Pelatihan Model

Proses pelatihan model dibagi menjadi dua tahap utama: tahap *transfer learning* awal, diikuti oleh tahap *fine-tuning*. Total proses pelatihan berlangsung selama 35 *epoch*. Kinerja model pada setiap *epoch* dipantau menggunakan metrik akurasi dan *loss* pada data pelatihan (*training*) dan data validasi (*validation*).

Tahap 1: Pelatihan Transfer Learning (Epoch 1-20)

Pada tahap pertama, hanya lapisan kepala klasifikasi kustom yang dilatih, sementara seluruh bobot pada arsitektur dasar Xception dibekukan. Tahap ini bertujuan agar model dapat mempelajari fitur-fitur spesifik dari dataset tanaman tanpa mengubah pengetahuan umum yang sudah ada pada bobot pra-terlatih.

Dari log pelatihan, terlihat bahwa model menunjukkan kinerja yang sangat baik sejak awal. Pada *epoch* pertama, model sudah mencapai akurasi validasi sebesar 87,62% (`val_accuracy: 0.8762`), yang mengindikasikan bahwa

fitur-fitur yang diekstraksi oleh Xception sangat relevan untuk tugas klasifikasi tanaman.

Selama 20 *epoch*, performa model terus meningkat secara konsisten. Pada akhir tahap ini (*epoch* 20), model berhasil mencapai:

- Akurasi Pelatihan: 91,58% (accuracy: 0.9158)
- Akurasi Validasi: 96,60% (val_accuracy: 0.9660)
- Loss Validasi: 0.1017 (val_loss: 0.1017)

Pada *epoch* ke-19, *callback* ReduceLROnPlateau terpicu, menurunkan *learning rate* dari 0.001 menjadi 0.0002, yang membantu model mencapai konvergensi yang lebih baik di akhir tahap ini.

Tahap 2: Fine-Tuning (Epoch 21-35)

Setelah tahap pertama selesai, pelatihan dilanjutkan ke tahap fine-tuning. Pada tahap ini, 20 lapisan terakhir dari model dasar Xception "dicairkan" (unfrozen) dan dilatih bersama dengan kepala klasifikasi. Model dikompilasi ulang dengan *learning rate* yang sangat rendah, yaitu 1×10^{-5} , untuk menyesuaikan bobot secara halus tanpa merusak fitur yang telah dipelajari.

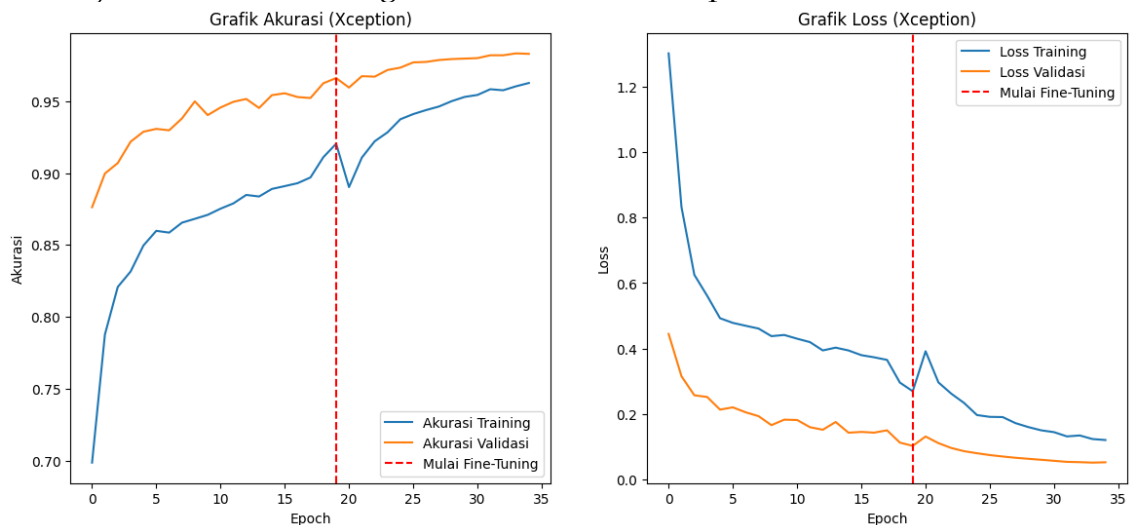
Proses fine-tuning dimulai pada *epoch* ke-21 dan berlangsung selama 15 *epoch* tambahan. Tahap ini terbukti sangat efektif dalam meningkatkan performa model lebih lanjut. Model terus menunjukkan peningkatan performa hingga akhir pelatihan. Pada *epoch* ke-35, model mencapai titik performa puncaknya pada data validasi dengan hasil:

- Akurasi Pelatihan: 95,96% (accuracy: 0.9596)
- Akurasi Validasi: 98,28% (val_accuracy: 0.9828)
- Loss Validasi: 0.0514 (val_loss: 0.0514)

Peningkatan akurasi validasi dari 96,60% menjadi 98,28% menunjukkan keberhasilan strategi fine-tuning dalam mengadaptasi model secara lebih mendalam pada dataset spesifik yang digunakan.

Analisis Grafik Akurasi dan Loss

Untuk visualisasi dan analisis lebih mendalam, performa model selama 35 *epoch* disajikan dalam bentuk grafik akurasi dan loss pada Gambar 2.



Gambar 2 Grafik Performa Model Selama Pelatihan

Analisis Grafik Akurasi (Kiri):

- Kurva biru (Akurasi Training) dan kurva oranye (Akurasi Validasi) menunjukkan tren kenaikan yang stabil sepanjang proses pelatihan, mengindikasikan bahwa model terus belajar dengan baik.
- Menariknya, selama tahap *transfer learning* (epoch 0-20), akurasi validasi secara konsisten sedikit lebih tinggi daripada akurasi pelatihan. Fenomena ini dapat terjadi dalam *deep learning*, sering kali disebabkan oleh penerapan teknik regularisasi yang kuat (seperti *Dropout*) yang hanya aktif selama fase pelatihan, sehingga sedikit "menekan" performa pada data training, namun tidak aktif saat evaluasi pada data validasi.
- Garis putus-putus merah menandai dimulainya tahap *fine-tuning*. Setelah titik ini, kedua kurva akurasi terus menanjak, menunjukkan bahwa penyesuaian bobot lapisan dalam Xception berhasil meningkatkan kemampuan model.

Analisis Grafik Loss (Kanan):

- Kedua kurva *loss* menunjukkan tren penurunan yang tajam di awal dan melandai seiring berjalannya *epoch*, yang merupakan perilaku ideal dari sebuah proses pelatihan.
- Nilai *validation loss* secara konsisten lebih rendah dari *training loss*, yang sejalan dengan hasil pada grafik akurasi.
- Setelah tahap *fine-tuning* dimulai, *validation loss* terus menurun hingga mencapai nilai terendah sekitar 0.05. Ini menunjukkan bahwa model tidak mengalami *overfitting* dan mampu melakukan generalisasi dengan sangat baik pada data yang belum pernah dilihatnya.

Evaluasi Model pada Data Uji

Tahap terpenting dari evaluasi adalah pengujian model pada **data uji** (*test set*), yaitu data yang sama sekali tidak digunakan selama proses pelatihan maupun validasi. Pengujian ini memberikan gambaran sebenarnya mengenai kemampuan generalisasi model di dunia nyata.

Berdasarkan log output, hasil evaluasi akhir model pada data uji adalah sebagai berikut:

Evaluasi akhir pada data Test:

94/94 ————— 30s 322ms/step - accuracy:
0.9805 - loss: 0.0675

Model berhasil mencapai:

- Akurasi Akhir: 98,05%
- Loss Akhir: 0.0675

Skor akurasi yang sangat tinggi ini (mendekati akurasi validasi puncak sebesar 98,28%) mengonfirmasi bahwa model yang dikembangkan memiliki kemampuan generalisasi yang sangat kuat dan tidak mengalami *overfitting*.

PEMBAHASAN

Hasil penelitian secara keseluruhan menunjukkan bahwa pendekatan yang digunakan – kombinasi arsitektur **Xception** dengan strategi pelatihan dua tahap (*transfer learning* dan *fine-tuning*) – sangat berhasil untuk tugas klasifikasi 30 jenis tanaman.

Tahap *transfer learning* awal berhasil membangun fondasi model yang kuat dengan memanfaatkan pengetahuan dari dataset ImageNet, yang terbukti dengan cepatnya model mencapai akurasi di atas 95% pada data validasi. Selanjutnya, tahap *fine-tuning* dengan *learning rate* yang rendah mampu menyempurnakan model, mendorong performanya hingga mencapai akurasi puncak.

Dengan akurasi akhir sebesar 98,05% pada data uji, dapat disimpulkan bahwa model yang diusulkan sangat andal dan akurat untuk melakukan identifikasi jenis tanaman berdasarkan citra. Keberhasilan ini didukung oleh pemilihan arsitektur yang kuat, penerapan teknik augmentasi data yang efektif, dan strategi pelatihan *fine-tuning* yang cermat. Model ini memiliki potensi besar untuk diaplikasikan dalam sistem identifikasi tanaman otomatis di berbagai bidang seperti pertanian, botani, dan pendidikan.

KESIMPULAN DAN REKOMENDASI

Penelitian ini berhasil menyimpulkan bahwa pengembangan model klasifikasi citra tanaman menggunakan arsitektur *deep learning* Xception sangatlah efektif. Melalui kombinasi strategi *transfer learning* dan *fine-tuning*, model yang diusulkan mampu mencapai akurasi akhir yang sangat andal sebesar 98,05% pada data uji. Keberhasilan ini menegaskan bahwa strategi pelatihan dua tahap, di mana *transfer learning* membangun fondasi yang kuat dan *fine-tuning* melakukan penyesuaian presisi, merupakan pendekatan yang optimal untuk tugas ini. Dengan kinerja yang terbukti, model ini menunjukkan potensi aplikasi yang besar sebagai solusi praktis untuk menjawab tantangan identifikasi keanekaragaman hayati, menjadikannya alat bantu yang kuat bagi masyarakat, pelajar, maupun praktisi di bidang pertanian dan botani.

Berdasarkan potensi tersebut, direkomendasikan agar model ini diimplementasikan ke dalam sebuah aplikasi *mobile* yang ramah pengguna, sehingga masyarakat dapat mengidentifikasi tanaman secara mudah menggunakan kamera ponsel. Lebih lanjut, model ini ideal untuk diintegrasikan ke dalam platform edukasi digital atau ensiklopedia interaktif guna mendukung proses pembelajaran. Bagi para peneliti botani, model ini juga dapat berfungsi sebagai alat bantu yang mempercepat proses identifikasi awal di lapangan, sehingga memungkinkan mereka untuk fokus pada analisis yang lebih mendalam.

PENELITIAN LANJUTAN

Meskipun penelitian ini berhasil, terdapat ruang untuk pengembangan di masa depan. Penelitian lanjutan disarankan untuk fokus pada perluasan dataset dengan menambah jumlah spesies, terutama tanaman obat endemik Indonesia, serta menggunakan citra dengan kondisi yang lebih beragam untuk meningkatkan ketangguhan model di dunia nyata. Selain itu, pengembangan

dapat diarahkan dari klasifikasi citra menjadi deteksi dan segmentasi objek, yang memungkinkan identifikasi bagian spesifik tanaman atau beberapa tanaman dalam satu gambar. Langkah selanjutnya yang sangat bermanfaat adalah mengintegrasikan output klasifikasi dengan basis data komprehensif untuk menyajikan informasi detail seperti manfaat dan cara budidaya. Terakhir, eksplorasi teknik optimasi model diperlukan untuk memastikan sistem dapat berjalan efisien secara *real-time* pada perangkat dengan sumber daya terbatas seperti *smartphone*.

DAFTAR PUSTAKA

- Abdel-Jaber, H., Devassy, D., Al Salam, A., Hidaytallah, L., & El-Amir, M. (2022). A Review of Deep Learning Algorithms and Their Applications in Healthcare. In *Algorithms* (Vol. 15, Issue 2). MDPI. <https://doi.org/10.3390/a15020071>
- Agarwal, N., Sondhi, A., Chopra, K., & Singh, G. (2021). Transfer learning: Survey and classification. *Advances in Intelligent Systems and Computing*, 1168, 145–155. https://doi.org/10.1007/978-981-15-5345-5_13
- Dwiatmoko, F., Utami, D., Sivi, N. A., Nahdlatul, U., & Lampung, U. (2024). *Klasifikasi Citra Sampah Organik dan Non Organik Menggunakan Algoritma CNN (Convolutional Neural Network)*.
- Mareta Tama, A., & Candra Noor Santi, R. (2023). Klasifikasi Jenis Tanaman Hias Menggunakan Metode Convolutional Neural Network (Cnn) Ornamental Plant Classification Using The Convolutional Neural Network (CNN) METHOD. *Journal of Information Technology and Computer Science (INTECOMS)*, 6(2).
- Mienye, I. D., & Swart, T. G. (2024). A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications. *Information (Switzerland)*, 15(12). <https://doi.org/10.3390/info15120755>
- Setiyono, B., Riv'an Arif, M., Aini, Q. Q., Soegianto, T. H., Ohanna, J., Andrean, R., Gunawan, F., & Rizkia, A. P. (2023). *Identifikasi Tanaman Obat Indonesia Melalui Citra Daun Menggunakan Metode Convolutional Neural Network (CNN)*. <https://doi.org/10.25126/jtiik.2023106809>
- Shafik, W., Tufail, A., Liyanage De Silva, C., & Awg Haji Mohd Apong, R. A. (2025). A novel hybrid inception-xception convolutional neural network for efficient plant disease classification and detection. *Scientific Reports*, 15(1), 3936. <https://doi.org/10.1038/s41598-024-82857-y>
- Xu, X., Zhao, M., Shi, P., Ren, R., He, X., Wei, X., & Yang, H. (2022). Crack Detection and Comparison Study Based on Faster R-CNN and Mask R-CNN. *Sensors*, 22(3). <https://doi.org/10.3390/s22031215>