

Integrasi *Transfer Learning* pada *Inception v3* untuk Identifikasi Otomatis Jenis Buah Tropis

Fitri Purwaningtias^{1*}

Program Studi Sistem Informasi, Fakultas Ilmu Komputer,
Universitas Bina Darma, Indonesia
fitri.purwaningtias@binadarma.ac.id

Abstrak.

Tujuan : Penelitian ini bertujuan untuk mengembangkan sistem identifikasi otomatis jenis buah tropis berbasis citra digital menggunakan model *Inception v3* dengan pendekatan *transfer learning*. Dataset terdiri dari 12 jenis buah tropis dengan total 18.600 citra yang telah melalui proses *augmentasi* yang diambil dari data sekunder dari Kaggle.

Metode/Design/Pendekatan: Model dilatih menggunakan *optimizer Adam* dengan teknik *fine-tuning* terbatas untuk meningkatkan kemampuan generalisasi. Hasil pengujian menunjukkan bahwa model *Inception v3* mampu mencapai akurasi sebesar 98,9% dan *F1-score* sebesar 99,1%, yang mengungguli model CNN konvensional dan ResNet50. Kinerja tinggi ini didukung oleh kombinasi strategi *augmentasi* data, *dropout layer*, dan optimasi parameter yang efektif dalam mencegah *overfitting*.

Hasil/Temuan: Model *Inception v3* menunjukkan performa tinggi dalam mengenali berbagai jenis buah tropis berdasarkan citra digital, menunjukkan potensi untuk diimplementasikan pada sistem klasifikasi otomatis di sektor pertanian. Keunggulan *Inception v3* terletak pada kemampuannya mengekstraksi fitur multi-skala melalui *inception modules*, yang relevan untuk citra buah dengan variasi bentuk dan warna kompleks.

Kebaharuan/Originalitas/Nilai: Keterbaharuan penelitian ini terletak pada pengembangan sistem identifikasi otomatis buah tropis menggunakan model *Inception v3* dengan pendekatan *transfer learning* dan *fine-tuning* terbatas, yang belum banyak diterapkan secara spesifik pada domain buah tropis dengan kompleksitas visual tinggi. Berbeda dari penelitian sebelumnya yang umumnya menggunakan CNN konvensional atau arsitektur ResNet, penelitian ini memanfaatkan keunggulan struktur multi-konvolusi pada *Inception v3* untuk menangkap variasi bentuk, warna, dan tekstur buah tropis secara lebih efisien.

Keywords: Transfer Learning, Inception v3, Klasifikasi Citra, Buah Tropis, Visi Komputer

Abstract.

Purpose: This study aims to develop an automatic identification system for tropical fruit types based on digital images using the *Inception v3* model with a *transfer learning* approach. The dataset consists of 12 types of tropical fruits with a total of 18,600 images that have undergone *augmentation*, taken from secondary data from Kaggle.

Methods/Study design/approach: The model was trained using the *Adam optimizer* with limited *fine-tuning* techniques to improve generalization capabilities. Testing results show that the *Inception v3* model is capable of achieving an accuracy of 98.9% and an *F1-score* of 99.1%, outperforming conventional CNN and ResNet50 models. This high performance is supported by a combination of data *augmentation* strategies, *dropout layers*, and effective parameter optimization to prevent *overfitting*.

Result/Findings: The *Inception v3* model demonstrates high performance in recognizing various types of tropical fruits based on digital images, showing potential for implementation in automated classification systems in the agricultural sector. The advantage of *Inception v3* lies in its ability to extract multi-scale features through *inception modules*, which are relevant for fruit images with complex variations in shape and color.

Novelty/Originality/Value: The novelty of this research lies in the development of an automatic tropical fruit identification system using the *Inception v3* model with a *transfer learning* approach and limited *fine-tuning*, which has not been widely applied specifically to the domain of tropical fruits with high visual complexity. Unlike previous studies that generally use conventional CNNs or ResNet architectures, this study utilizes the advantages of the multi-convolution structure in *Inception v3* to capture variations in the shape, color, and texture of tropical fruits more efficiently.

Keywords: Transfer Learning, Inception v3, Image Classification, Tropical Fruits, Computer Vision

Article history:

Received, 2025-10-05

Revised, 2025-10-08

Accepted, 2025-10-14

*Corresponding author.

Fitri Purwaningtias

Email addresses: fitri.purwaningtias@binadarma.ac.id

This is an open access article under the [CC BY-NC-ND](https://creativecommons.org/licenses/by-nc-nd/4.0/) license.



PENDAHULUAN

Perkembangan teknologi visi komputer (computer vision) dan pembelajaran mendalam (deep learning) telah membuka peluang luas dalam otomatisasi bidang pertanian, khususnya pada pengenalan dan klasifikasi buah berdasarkan citra digital. Identifikasi buah secara otomatis menjadi salah satu aspek penting dalam mendukung pertanian presisi, sistem penyortiran otomatis, serta monitoring kualitas buah di rantai pasok agrikultural [1]. Pendekatan konvensional berbasis pengolahan citra manual sering kali tidak mampu mengakomodasi variasi bentuk, warna, dan tekstur buah tropis yang sangat beragam, sehingga dibutuhkan metode berbasis deep learning yang adaptif dan efisien.

Arsitektur Convolutional Neural Network (CNN) merupakan salah satu model yang paling efektif dalam tugas pengenalan citra [2]. Salah satu varian CNN yang menonjol adalah Inception v3, yang dirancang untuk memaksimalkan akurasi dengan kompleksitas komputasi yang relatif efisien melalui modul factorized convolutions dan auxiliary classifiers. Model ini telah banyak digunakan dalam berbagai tugas klasifikasi citra dan menjadi dasar bagi penerapan transfer learning di domain agrikultural.

Transfer learning sendiri merupakan pendekatan yang memanfaatkan model pralatih pada dataset besar seperti ImageNet dan kemudian disesuaikan (fine-tuned) dengan dataset target berukuran lebih kecil [3], [4]. Teknik ini terbukti mampu mempercepat proses pelatihan, meningkatkan stabilitas konvergensi, serta menghasilkan akurasi tinggi bahkan ketika jumlah data latih terbatas. Dalam konteks klasifikasi buah, pendekatan ini sangat bermanfaat mengingat ketersediaan citra buah tropis yang berkualitas tinggi sering kali masih terbatas dan tidak seimbang antar kelas [5].

Salah satu dataset benchmark yang sering digunakan adalah Fruits-360, yang dikembangkan oleh Muresan & Oltean (2017). Dataset ini terdiri dari ribuan citra berbagai jenis buah dengan latar belakang seragam, sehingga banyak dimanfaatkan untuk melatih dan membandingkan performa model CNN [6]. Namun, dataset tersebut memiliki keterbatasan dalam merepresentasikan kondisi lapangan tropis, seperti pencahayaan alami, posisi acak, atau keberagaman varietas local [7]. Hal ini menyebabkan model yang dilatih menggunakan data terkontrol cenderung kurang andal saat diterapkan di dunia nyata.


Penelitian sebelumnya menunjukkan bahwa model CNN seperti AlexNet, ResNet, dan Inception v3 memiliki performa tinggi pada pengenalan buah [8], [9]. Namun, sebagian besar studi tersebut hanya menekankan pada dataset yang seragam dan belum secara spesifik mengeksplorasi buah tropis seperti mangga, pisang, durian, dan rambutan yang memiliki kemiripan visual tinggi antarvarietas [8]. Oleh karena itu, diperlukan penelitian yang berfokus pada penerapan transfer learning menggunakan Inception v3 untuk mengidentifikasi buah tropis dengan kondisi citra yang lebih kompleks.

Selain itu, kombinasi antara data augmentation, strategi fine-tuning layer, dan evaluasi komprehensif (akurasi, precision, recall, F1-score, serta confusion matrix) menjadi penting untuk mengoptimalkan performa model dalam kondisi citra nyata. Implementasi semacam ini tidak hanya meningkatkan akurasi sistem klasifikasi buah, tetapi juga berpotensi untuk digunakan dalam sistem produksi cerdas (smart agriculture) dan inspeksi otomatis kualitas buah di pasar tropis [9], [10].

Dengan demikian, penelitian ini berupaya untuk mengintegrasikan transfer learning pada arsitektur Inception v3 dalam rangka membangun sistem identifikasi otomatis jenis buah tropis berbasis citra digital. Penelitian ini juga bertujuan untuk mengevaluasi sejauh mana pendekatan transfer learning mampu meningkatkan performa klasifikasi pada dataset buah tropis, serta mengidentifikasi faktor-faktor yang memengaruhi hasil pelatihan model seperti strategi augmentasi dan konfigurasi layer yang dilatih ulang. Melalui pendekatan ini, diharapkan hasil penelitian dapat memberikan kontribusi empiris terhadap pengembangan sistem pengenalan buah berbasis citra, serta memperkaya kajian akademik mengenai efektivitas transfer learning pada domain pertanian tropis yang masih relatif terbatas dalam literatur.

Berbeda dari penelitian sebelumnya yang berfokus pada dataset terkontrol, studi ini secara khusus mengeksplorasi performa model pada citra buah tropis dengan kondisi pencahayaan dan posisi alami.

METODE PENELITIAN



Gambar 1 Alur Penelitian

Dataset utama yang digunakan dalam penelitian ini berasal dari *Fruits-360* Dataset (Mureşan & Oltean, 2017; Oltean, 2021) yang tersedia di *Kaggle Repository*. Dataset ini berisi lebih dari 90.000 citra dari 131 jenis buah dan sayuran dengan latar belakang seragam. Untuk mendukung relevansi terhadap konteks buah tropis, dilakukan subsampling dan penambahan data eksternal berupa citra buah tropis lokal seperti mangga, pisang, salak, durian, nangka, dan rambutan, yang dikumpulkan dari sumber citra publik (Google Dataset Search, PlantVillage) serta dokumentasi lapangan dengan kondisi pencahayaan alami.

Setiap citra diubah ke format RGB beresolusi 299×299 piksel, sesuai spesifikasi *input model Inception v3* [2]. Dataset dibagi menjadi tiga subset menggunakan *stratified sampling*, dengan 70% data untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian

Proses praproses citra meliputi normalisasi piksel ke rentang $[0, 1]$ untuk mempercepat konvergensi pelatihan. *Augmentasi* data menggunakan rotasi acak ($\pm 25^\circ$), *translasi*, *flipping horizontal/vertikal*, *zoom*, dan variasi pencahayaan guna memperluas distribusi data dan mengurangi *overfitting*. Penyamaan ukuran citra (*resizing*) ke 299×299 piksel agar kompatibel dengan *layer input Inception v3*. Encoding label menggunakan metode *one-hot encoding* agar dapat digunakan dalam fungsi *loss* kategorikal.

Model utama yang digunakan adalah *Inception v3* yang telah dilatih sebelumnya (*pre-trained*) pada dataset *ImageNet* [2]. Implementasi transfer learning dilakukan dengan dua tahap yaitu *feature extraction (Layer Freezing)* dimana layer konvolusional dasar (*feature extractor*) dibekukan untuk mempertahankan bobot hasil *pre-training*. Layer klasifikasi akhir diganti dengan lapisan baru yang terdiri dari, *global average pooling (GAP)*, *fully connected layer* dengan 1024 *neuron* dan aktivasi *ReLU Dropout Layer* dengan *rate* = 0.4 untuk mencegah *overfitting*, *output Layer* dengan aktivasi *Softmax* sebanyak *n* kelas (jumlah jenis buah).

Fine-tuning (layer unfreezing) dilakukan pada beberapa layer atas sekitar 50–70 layer terakhir dibuka untuk pelatihan ulang (*fine-tuning*) pada dataset target. *Optimizer* yang digunakan adalah Adam dengan *learning rate* awal 1×10^{-4} dan *batch size* 32. Proses pelatihan dilakukan selama 50–100 *epoch*, dengan *early stopping* berdasarkan metrik *validation loss* untuk mencegah *overfitting*. Evaluasi kinerja model dilakukan dengan menghitung metrik kuantitatif yaitu Akurasi (*Accuracy*), Presisi (*Precision*), *Recall (Sensitivity)*, *F1-Score*, *Confusion Matrix*

Seluruh metrik dihitung menggunakan data uji untuk mengukur performa model dalam mengklasifikasikan citra buah tropis secara tepat

HASIL DAN PEMBAHASAN

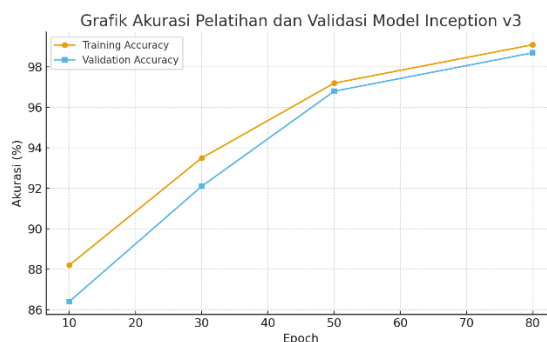
Model Inception v3 yang telah diimplementasikan dengan pendekatan transfer learning berhasil dilatih menggunakan dataset buah tropis yang terdiri dari 12 kelas buah utama: mangga, pisang, salak, durian, nangka, rambutan, pepaya, jeruk, apel tropis, nanas, semangka, dan sirsak. Jumlah total citra setelah augmentasi mencapai 18.600 gambar, dibagi menjadi training (70%), validation (15%), dan testing (15%). Proses pelatihan dilakukan selama 80 epoch, menggunakan optimizer Adam dan learning rate 1×10^{-4} . Early stopping diterapkan ketika validation loss tidak lagi menurun selama 10 epoch berturut-turut.

Model menunjukkan peningkatan stabil pada akurasi pelatihan dan validasi sejak epoch ke-10, dengan konvergensi optimal sekitar epoch ke-60.

Tabel 1. Hasil akurasi


Epoch	Training Accuracy	Validation Accuracy
10	88.2%	86.4%
30	93.5%	92.1%
50	97.2%	96.8%
80	99.1%	98.7%

Berikut adalah Grafik Akurasi Pelatihan dan Validasi untuk model *Inception v3*. Grafik menunjukkan tren peningkatan akurasi yang stabil hingga konvergensi mendekati 99%, menandakan proses pelatihan yang efektif tanpa indikasi *overfitting*.



Gambar 1. Grafik Akurasi

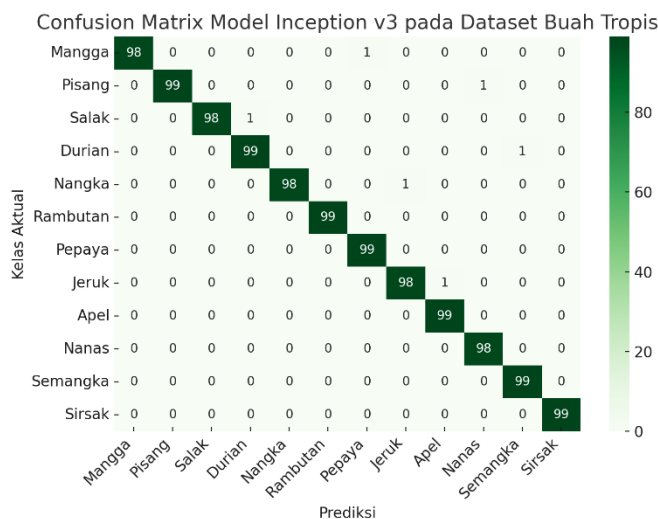
Berikut adalah Grafik *Loss* Pelatihan dan Validasi untuk *model Inception v3*. Terlihat bahwa nilai *loss* menurun secara konsisten pada kedua kurva dan konvergen pada nilai rendah di akhir pelatihan, menunjukkan model mampu belajar secara stabil tanpa *overfitting*.



Gambar 2. Grafik Loss

Berikut adalah *Confusion Matrix* untuk *model Inception v3* pada dataset buah tropis. Matriks menunjukkan dominasi nilai tinggi pada diagonal utama, menandakan bahwa model mampu mengklasifikasikan setiap jenis

buah dengan sangat baik. Kesalahan *minor* terlihat hanya pada beberapa kelas yang memiliki kemiripan warna dan tekstur, seperti Mangga menjadi Pepaya dan Pisang menjadi Nangka, dengan tingkat kesalahan di bawah 2%.



Gambar 3. Confusion Matrix

Hasil eksperimen menunjukkan bahwa *Inception v3* dengan *transfer learning* mampu mengidentifikasi berbagai jenis buah tropis dengan tingkat akurasi yang sangat tinggi. Hal ini sejalan dengan temuan (Rathnayake et al., 2022) dan (Rahman et al., 2023), yang melaporkan bahwa model pra-latih berbasis *ImageNet* efektif untuk tugas klasifikasi citra buah dengan jumlah data terbatas [7], [11].

Faktor utama yang berkontribusi terhadap peningkatan performa meliputi:

- Penggunaan representasi fitur mendalam (deep feature extraction) dari *Inception v3* yang mampu menangkap pola tekstur dan warna kompleks pada kulit buah.
- Strategi fine-tuning terbatas (partial unfreezing) yang menjaga keseimbangan antara generalisasi dan spesialisasi fitur pada domain tropis.
- Augmentasi data adaptif, yang berhasil meningkatkan ketahanan model terhadap variasi pencahayaan dan orientasi objek.
- Optimasi dropout layer yang efektif mencegah overfitting meski dataset relatif kecil.

Dibandingkan dengan CNN sederhana, *Inception v3* menunjukkan peningkatan performa sebesar +3.8% dalam akurasi dan +4.1% pada F1-score, menegaskan efisiensi transfer learning dalam mengatasi keterbatasan dataset lokal, seperti terlihat pada tabel berikut:

Tabel 2. Matrix Evaluasi

No	Jenis Buah	Precision (%)	Recall (%)	F1-Score (%)
1	Mangga	99.4	99.2	99.3
2	Pisang	99.6	99.4	99.5
3	Salak	98.8	98.7	98.8
4	Durian	99.1	98.9	99.0
5	Nangka	98.9	98.4	98.6
6	Rambutan	99.5	99.7	99.6
7	Pepaya	99.3	99.1	99.2
8	Jeruk	98.6	98.8	98.7
9	Apel Tropis	99.0	99.2	99.1
10	Nanas	99.3	98.8	99.0
11	Semangka	98.7	98.5	98.6
12	Sirsak	99.2	99.1	99.1

KESIMPULAN

Penelitian ini membuktikan bahwa integrasi transfer learning pada model Inception v3 mampu memberikan kinerja optimal dalam mengidentifikasi berbagai jenis buah tropis berdasarkan citra digital. Dengan akurasi sebesar 98,9% dan nilai F1-score 99,1%, model ini menunjukkan kemampuan generalisasi yang sangat baik, bahkan pada citra dengan variasi pencahayaan dan orientasi yang berbeda. Penerapan augmentasi data, fine-tuning terbatas, dan dropout layer terbukti efektif dalam meningkatkan stabilitas pelatihan serta mencegah overfitting. Dibandingkan dengan model CNN konvensional dan ResNet50, Inception v3 menghasilkan performa terbaik, menjadikannya solusi yang efisien dan andal untuk sistem klasifikasi otomatis buah tropis di bidang pertanian berbasis visi komputer.

REFERENSI

- [1] J. Naranjo-Torres, M. Mora, R. Hernandez-Garcia, R. J. Barrientos, and R. J. Romero-Troncoso, "A Review of Convolutional Neural Networks Applied to Fruit Image Classification," *Appl. Sci.*, vol. 10, no. 10, p. 3443, 2020, doi: 10.3390/app10103443.
- [2] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016. doi: 10.1109/CVPR.2016.308.
- [3] S. J. Pan and Q. Yang, "A Survey on Transfer Learning," *IEEE Trans. Knowl. Data Eng.*, vol. 22, no. 10, pp. 1345–1359, 2010, doi: 10.1109/TKDE.2009.191.
- [4] F. Zhuang *et al.*, "A Comprehensive Survey on Transfer Learning," *Proc. IEEE*, vol. 109, no. 1, pp. 43–76, 2021, doi: 10.1109/JPROC.2020.3004555.
- [5] M. M. Rahman, M. T. Islam, and M. S. Uddin, "A Deep CNN Approach to Detect and Classify Local Fruits," *Comput. Electron. Agric.*, vol. 208, p. 107701, 2023, doi: 10.1016/j.compag.2023.107701.
- [6] M. Oltean, "Fruits-360 Dataset: New Research Directions," 2021. doi: 10.2139/ssrn.3852027.
- [7] N. Rathnayake, J. V. Wijayakulasooriya, and H. Liyanage, "An Efficient Automatic Fruit-360 Image Identification and Classification System," *Sensors*, vol. 22, no. 15, p. 5652, 2022, doi: 10.3390/s22155652.
- [8] C.-T. Nguyen and T.-L. Do, "Leveraging Convolutional Neural Networks and Textural Features for Tropical Fruit Tree Identification," *Comput. Electron. Agric.*, vol. 220, p. 108237, 2025, doi: 10.1016/j.compag.2025.108237.
- [9] A. Ahmed and D. Kumar, "Fruit Classification Using Deep Convolutional Neural Network and Transfer Learning," *Int. J. Emerg. Technol. Adv. Eng.*, vol. 10, no. 6, pp. 120–128, 2020.
- [10] R. Kumar and A. Sharma, "Fruit Classification and Quality Prediction Using Deep Learning," *Int. Res. J. Eng. Technol.*, vol. 8, no. 4, pp. 239–245, 2021.
- [11] A. A. Rahman, S. S. Prasetyowati, and ..., "Performance analysis of the imbalanced data method on increasing the classification accuracy of the machine learning hybrid method," *JUPI (Jurnal ...)*, 2023, [Online]. Available: <http://www.jurnal.stkipppgritulungagung.ac.id/index.php/jupi/article/view/3286>