



## PENERAPAN ARSITEKTUR *CONVOLUTIONAL NEURAL NETWORK* UNTUK KLASIFIKASI BINER PADA OBJEK DAUN MANGGA DAN JAMBU

Lailan Sofinah Harahap<sup>1</sup>, Kaka Davi Dharmawan<sup>2</sup>

<sup>1</sup>lailansofinah@uinsu.ac.id, <sup>2</sup>kaka0701231028@uinsu.ac.id

<sup>1,2</sup>Ilmu Komputer, Universitas Islam Negeri Sumatera Utara

### Abstrak

Identifikasi klasifikasi jenis tumbuhan secara otomatis berdasarkan citra daun masih menjadi tantangan tersendiri di bidang botani dan pertanian. Untuk mengatasi masalah ini, arsitektur *Convolutional Neural Network* (CNN) diterapkan untuk melakukan tugas klasifikasi biner, yaitu membedakan antara objek daun mangga (*Mangifera indica*) dan daun jambu biji (*Psidium guajava*) berdasarkan citranya. Dataset terdiri dari 1004 citra (502 mangga dan 502 jambu), dibagi menjadi 80% data latih dan 20% data validasi. Arsitektur CNN yang dibangun mencakup tiga lapisan konvolusi untuk ekstraksi fitur otomatis, diikuti lapisan *pooling*, *flatten*, *dropout*, dan *dense* untuk klasifikasi. Model dilatih menggunakan data latih yang telah di augmentasi selama 15 *epoch* dengan *optimizer* Adam dan fungsi *loss binary crossentropy*. Hasil evaluasi pada data validasi menunjukkan model mencapai akurasi 95.02%, membuktikan kemampuan dalam mempelajari pola pembeda dan melakukan klasifikasi biner pada objek daun secara efektif.

**Kata kunci:** *Deep Learning*, CNN, Citra Daun.

### Abstract

*Automatic identification of plant species classification based on leaf images remains a challenge in botany and agriculture. To address this issue, a Convolutional Neural Network (CNN) architecture was applied to perform a binary classification task, namely distinguishing between mango leaves (Mangifera indica) and guava leaves (Psidium guajava) based on their images. The dataset consists of 1004 images (502 mango and 502 guava), divided into 80% training data and 20% validation data. The CNN architecture built includes three convolution layers for automatic feature extraction, followed by pooling, flatten, dropout, and dense layers for classification. The model was trained using augmented training data for 15 epochs with the Adam optimizer and binary cross-entropy loss function. Evaluation results on the validation data showed that the model achieved an accuracy of 95.02%, proving its ability to learn distinguishing patterns and perform binary classification on leaf objects effectively.*

**Keywords:** *Deep Learning, CNN, Leaf Images.*

### 1. Pendahuluan

Jaringan Saraf Tiruan (JST) dan *Deep Learning* telah mengubah secara signifikan kemampuan komputer dalam mengenali pola dari data yang rumit, termasuk data visual seperti gambar. Salah satu penerapannya yang penting adalah dalam klasifikasi objek, di mana sistem dilatih untuk mengelompokkan *input* berdasarkan kategori yang telah ditetapkan [1].

Meskipun teknologi telah berkembang pesat, penerapannya di beberapa bidang, khususnya botani dan pertanian untuk klasifikasi jenis objek masih menjadi tantangan tersendiri [2]. Banyak metode pembelajaran mesin tradisional masih bergantung dengan rekayasa alat dan fitur (*feature engineering*) manual yang rumit, membutuhkan biaya yang relatif mahal dan spesifik pada domain tertentu [3]. Padahal, identifikasi tanaman yang cepat dan andal berdasarkan karakteristik morfologis daun sangat dibutuhkan untuk mendukung manajemen pertanian dan pemantauan keanekaragaman hayati [4].

Hasil penelitian sebelumnya, seperti klasifikasi citra dalam hal penggunaan masker oleh Putra dan Saputra [5] menunjukkan bahwa *Convolutional Neural Network* (CNN) efektif dalam belajar representasi fitur untuk berbagai tugas klasifikasi citra. Meskipun demikian, terdapat kebutuhan khusus untuk penelitian yang menguji secara sistematis kemampuan model JST dalam membedakan spesies tumbuhan

yang memiliki variasi visual halus, sehingga muncul kesenjangan penelitian terkait penerapan dan evaluasi model untuk kasus spesifik seperti klasifikasi dua jenis daun yang umum di Indonesia [6].

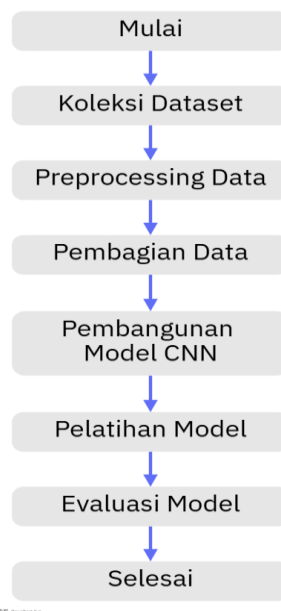
Pemilihan daun mangga dan jambu biji sebagai objek penelitian didasarkan pada kemiripan karakteristik visual yang dominan antara keduanya, khususnya pada bentuk helai yang memanjang serta struktur tulang daun yang identik (*venation*). Kemiripan karakteristik morfologi daun yang saling menyerupai ini juga menjadi tantangan pada identifikasi berbagai jenis tanaman obat maupun buah, sehingga sering menimbulkan kekeliruan dalam pengenalan manual berbasis pengamatan visual saja [7]. Maka dari itu, kasus ini sangat relevan digunakan untuk menguji tingkat sensitivitas dan presisi model CNN dalam melakukan klasifikasi biner.

Menimbang kesenjangan tersebut, penelitian ini penting karena bertujuan mengembangkan, melatih, dan mengevaluasi model CNN untuk klasifikasi biner antara daun mangga (*Mangifera indica*) dan daun jambu biji (*Psidium guajava*), dengan fokus pada prosedur yang sistematis untuk mencapai dan mengukur kinerja klasifikasi yang dapat dijadikan acuan empiris [8].

Secara metodologis, penelitian ini akan mengimplementasikan *pipeline* yang mencakup pengumpulan dan pra-pemrosesan citra daun, perancangan arsitektur CNN yang sesuai, proses pelatihan terkontrol, serta evaluasi menggunakan metrik kinerja yang relevan untuk menilai kemampuan diskriminasi model antara kedua kelas daun [9]. Kontribusi yang diharapkan adalah penyediaan bukti empiris mengenai efektivitas CNN pada klasifikasi biner daun mangga dan jambu biji serta dasar perbandingan bagi studi lanjutan [10]. Penelitian ini dibatasi pada dua spesies tersebut sehingga hasilnya memberi tolak ukur awal dan mendorong penelitian lanjutan untuk perluasan jenis dan kondisi data.

## 2. Metode

Metodologi penelitian ini menerapkan pendekatan *deep learning* berbasis *Convolutional Neural Network* (CNN) untuk klasifikasi biner, dengan alur kerja yang meliputi persiapan *dataset*, perancangan arsitektur CNN, pelatihan model, dan evaluasi kinerja klasifikasi [11]. Tahapan atau prosedur penelitian ini digambarkan dalam *flowchart* pada Gambar 1.



Gambar 1. Diagram Alir Prosedur Penelitian

Penelitian ini dimulai dengan pengumpulan 1004 citra daun mangga dan jambu biji. Selanjutnya dilakukan *preprocessing* data, yang meliputi penyesuaian ukuran gambar menjadi 150x150 piksel, normalisasi nilai piksel dari 0 hingga 1, serta augmentasi data untuk memperkaya data latih. *Dataset* kemudian dibagi menjadi 803 citra untuk pelatihan (80%) dan 201 citra untuk validasi (20%).

Tahap inti penelitian adalah pembangunan model CNN dengan arsitektur yang terdiri dari tiga lapisan konvolusi dan satu lapisan *dense*. Model ini dilatih menggunakan *optimizer* 'adam' selama 15 *epoch* untuk mengoptimalkan bobotnya berdasarkan data latih. Setelah pelatihan selesai, dilakukan evaluasi performa model dengan mengukur akurasi dan *loss* pada data validasi. Proses diakhiri setelah hasil evaluasi diperoleh, menandai selesainya seluruh rangkaian penelitian.

### 2.1. Dataset

*Dataset* terdiri dari citra daun mangga dan daun jambu biji yang dikumpulkan dari repositori publik (*Kaggle*), berjumlah total 1.004 citra (502 citra mangga dan 502 citra jambu biji). Untuk keperluan pelatihan dan penilaian, *dataset* dibagi menjadi data latih sebanyak 803 citra ( $\pm 80\%$ ) dan data validasi sebanyak 201 citra ( $\pm 20\%$ ) [12]. Pembagian ini digunakan untuk menilai kemampuan generalisasi model terhadap data tak dikenal yang dilampirkan pada Tabel 1 yang merangkum komposisi *dataset*.

Tabel 1. Komposisi *Dataset* Daun Mangga dan Jambu Biji

Kelas	Jenis Data	Jumlah Citra	Total
Mangga	Pelatihan ( <i>Training</i> )	402	502
	<i>Validation</i>	100	
Jambu	Pelatihan ( <i>Training</i> )	401	502
	<i>Validation</i>	101	

### 2.2. Persiapan *Input Model*

Persiapan *input model* dilakukan menggunakan *Image Data Generator* dari *TensorFlow Keras* dan mencakup penyesuaian dimensi, normalisasi, augmentasi pada data latih, serta pengelompokan *batch*.

1. Penyesuaian dimensi, di mana setiap citra diubah ukurannya menjadi  $150 \times 150$  piksel untuk menyesuaikan dengan dimensi *input* lapisan pertama CNN.
2. Normalisasi intensitas, nilai piksel yang awalnya pada rentang 0-255 diskalakan menjadi 0-1 untuk meningkatkan stabilitas dan laju konvergensi selama pelatihan.
3. Augmentasi data (data latih), pada data latih diterapkan transformasi acak seperti rotasi, pergeseran translasi, zoom, dan pembalikan horizontal untuk memperkaya variasi visual yang dipelajari model serta augmentasi tidak diterapkan pada data validasi.
4. *Batching*, data disajikan ke model dalam *batch* berukuran 32 citra untuk efisiensi pemrosesan dan kestabilan pembaruan bobot [13].

### 2.3. Arsitektur *Convolutional Neural Network*

Arsitektur yang dirancang dalam penelitian ini menggunakan model *Sequential Keras*. Adapun struktur lapisannya dijabarkan sebagai berikut:

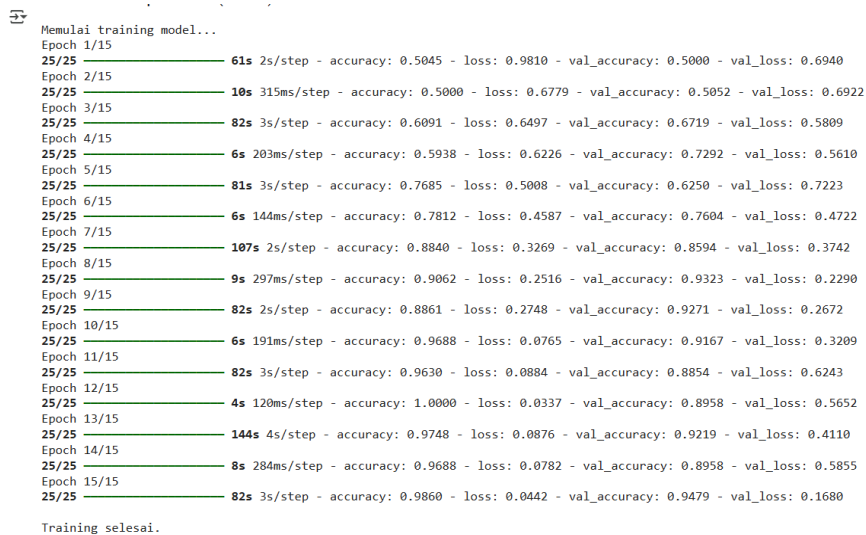
1. Tiga blok konvolusi-*pooling*, di mana setiap blok terdiri dari:
  - Lapisan Konvolusi (Conv2D) dengan filter 3x3 dan aktivasi ReLU (masing-masing 32, 64, dan 128 filter). Lapisan ini berfungsi untuk mengekstraksi fitur visual dari *input* secara hirarkis.
  - Lapisan *Max Pooling* (MaxPooling2D) dengan jendela 2x2 untuk mereduksi dimensi spasial.
2. Lapisan *Flatten*: Mengubah *output* dari blok konvolusi (yang berbentuk tensor multi-dimensi) menjadi vektor fitur satu dimensi.
3. Lapisan *Dropout*: Dengan *rate* 0.5, lapisan ini secara acak menonaktifkan sebagian *neuron* selama pelatihan untuk mencegah *overfitting*.
4. Lapisan *Dense (Fully Connected)* 1: Dengan 512 *neuron* dan aktivasi ReLU, memproses vektor fitur hasil *flatten*.
5. Lapisan *Dense (Output)*: Dengan 1 *neuron* dan aktivasi *Sigmoid*, menghasilkan probabilitas kelas (0 atau 1) untuk klasifikasi biner [14].

## 2.4. Proses Pelatihan

Model CNN disusun menggunakan *optimizer* 'Adam', dengan fungsi kerugian '*binary\_crossentropy*' dan metrik evaluasi berupa '*accuracy*'. Pelatihan model dilakukan dengan menjalankan fungsi *fit* yang memanfaatkan data pelatihan serta data validasi yang telah disiapkan sebelumnya [15]. Proses pelatihan berjalan selama 15 *epoch*, di mana model secara bertahap mempelajari pola dari data pelatihan melalui penyesuaian bobot di seluruh lapisan jaringan diatur oleh *optimizer* 'adam' untuk meminimalkan fungsi kerugian '*binary\_crossentropy*'. Sementara itu, kinerja model pada data validasi dipantau untuk mengukur kemampuannya dalam melakukan generalisasi [16].


## 3. Hasil dan Pembahasan

Data *training* model yang digunakan adalah 80% dari total gambar yang berarti ada 803 gambar yang terdiri dari 2 kelas. Proses ini menggunakan *optimizer* 'Adam', dengan fungsi *loss* '*binary\_crossentropy*' dan metrik evaluasi yaitu '*accuracy*'. Gambar 2 merupakan hasil *training* model yang sudah dilakukan.




Gambar 2. Hasil *Training* Model

Proses pelatihan model CNN menghasilkan kurva atau grafik yang menunjukkan peningkatan performa seiring berjalannya *epoch*. Terlihat pada gambar 3 yang menampilkan grafik akurasi pada data latih dan data validasi selama 15 *epoch*. Terlihat bahwa akurasi validasi (kurva oranye) meningkat secara signifikan pada *epoch* awal dan mencapai nilai yang relatif stabil di atas 90% pada *epoch-epoch* selanjutnya. Akurasi latih (kurva biru) juga terus meningkat dan cenderung lebih tinggi dari akurasi validasi, namun perbedaannya tidak terlalu besar. Hal inilah yang menandakan model memiliki kemampuan generalisasi yang baik.



Gambar 3. Grafik Akurasi Pelatihan dan Validasi Per *Epoch*

Kemudian, pada Gambar 4 menunjukkan grafik nilai *loss* selama pelatihan. Kurva *loss* baik pada data latih maupun data validasi menunjukkan tren penurunan, yang berkorelasi positif dengan peningkatan akurasi. Ini menandakan bahwa model berhasil meminimalisir *error* klasifikasi selama proses pembelajaran berlangsung.



Gambar 4. Grafik *Loss* Pelatihan dan Validasi Per *Epoch*

Tabel 2 menunjukkan hasil pengujian model CNN pada 201 data validasi mengindikasikan performa yang sangat baik. Terlihat, model mampu mengidentifikasi daun jambu dengan akurasi sempurna sebesar 100.00%, di mana 101 dari 101 gambar uji coba berhasil diprediksi dengan benar.

Untuk kelas daun mangga, model mampu menyentuh akurasi 90.00%, di mana 90 dari 100 gambar uji mangga diprediksi dengan benar. Terdapat 10 gambar daun mangga yang salah diklasifikasikan. Kesalahan prediksi pada daun mangga ini kemungkinan terjadi karena beberapa gambar mangga dalam dataset yang terlampir memiliki karakteristik visual (seperti bentuk atau pencahayaan) yang mirip dengan daun jambu, sehingga model terkecoh.

Tabel 2. Hasil Pengujian Akurasi Model CNN Per Kelas

Kelas Daun	Total Data	Prediksi Benar	Prediksi Salah	Akurasi
guava	101	101	0	100.00%
mango	100	90	10	90.00%

Meskipun demikian, akurasi keseluruhan model sebesar 95.02% serta akurasi per kelas yang tinggi ini yaitu 100% dan 90% sudah membuktikan bahwa model CNN yang diusulkan sangat efektif untuk tugas klasifikasi biner kedua objek daun ini.

## 4. Kesimpulan dan Saran

### 4.1. Kesimpulan

Penelitian ini berhasil mengaplikasikan *Convolutional Neural Network* (CNN) untuk melakukan klasifikasi biner pada gambar daun mangga dan jambu. Model CNN yang telah dikembangkan dan dilatih dengan *dataset* citra daun tersebut mencapai akurasi validasi sebesar 95.02% dari total 1004 *dataset* citra yang terbagi dari 2 kelas daun dengan format 80% data *training* (803 gambar) dan 20% data uji (201 gambar). Hasil ini menunjukkan bahwa pendekatan *deep learning* mampu secara otomatis mempelajari dan melakukan klasifikasi jenis visual dengan tingkat akurasi yang tinggi untuk kasus ini.

## 4.2. Saran

Adapun usulan-usulan bagi penelitian selanjutnya untuk lebih menyempurnakan hasil penelitian yang telah didapatkan adalah:

1. Memperluas model agar dapat melakukan klasifikasi multi-kelas dengan menambahkan lebih banyak jenis spesies daun.
2. Menggunakan *dataset* yang lebih besar dan beragam guna meningkatkan ketahanan dan keakuratan model.
3. Mengeksplorasi arsitektur CNN yang lebih maju atau memanfaatkan teknik *transfer learning* untuk meningkatkan performa.
4. Menganalisis fitur-fitur yang dipelajari oleh model untuk memperoleh pemahaman lebih dalam mengenai proses klasifikasi.

## Daftar Pustaka

- [1] J. Lian and T. Chen, "Research on Complex Data Mining Analysis and Pattern Recognition Based on Deep Learning," *J. Comput. Electron. Inf. Manag.*, vol. 12, no. 3, pp. 37–41, 2024, doi: 10.54097/i4jfi9aa.
- [2] P. Nethala, D. Um, N. Vemula, O. F. Montero, K. Lee, and M. Bhandari, "Techniques for Canopy to Organ Level Plant Feature Extraction via Remote and Proximal Sensing: A Survey and Experiments," *Remote Sens.*, vol. 16, no. 23, p. 4370, Nov. 2024, doi: 10.3390/rs16234370.
- [3] A. Awasthi, S. B. Rao, and K. Acharjya, "Efficient Image Feature Extraction using Convolutional Neural Networks," in *Proceedings of the ICONAT 2024*, 2024, pp. 1–5. doi: 10.1109/iconat61936.2024.10775088.
- [4] P. S. Prasad and A. Senthilrajan, "Advancing Plant Identification Through Leaf Image Analysis: A Comprehensive Review of Literature and Techniques," in *International Conference on Sustainable Emerging Innovations in Engineering and Technology (ICSEIET)*, IEEE, Sep. 2023, pp. 629–635. doi: 10.1109/ICSEIET58677.2023.10303450.
- [5] D. R. R. Putra and R. A. Saputra, "Implementasi Convolutional Neural Network (CNN) Untuk Mendeteksi Penggunaan Masker Pada Gambar," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 3, Aug. 2023, doi: 10.23960/jitet.v11i3.3286.
- [6] M. Diqi and S. H. Mulyani, "Implementation of CNN for Plant Leaf Classification," *Int. J. Informatics Comput.*, vol. 2, no. 2, p. 1, Mar. 2021, doi: 10.35842/ijicom.v2i2.28.
- [7] N. L. Marpaung, R. J. H. Butar-butur, and S. Hutabarat, "Implementasi Deep learning untuk Identifikasi Daun Tanaman Obat Menggunakan Metode Transfer learning," *J. Edukasi dan Penelit. Inform.*, vol. 9, no. 3, pp. 348–354, 2023, doi: <https://doi.org/10.26418/jp.v9i3.63895>.
- [8] S. Rahman, M. Ramli, F. Arnia, R. Muharar, M. Zen, and M. Ikhwan, *Convolutional Neural Network Untuk Visi Komputer*, 1st ed. Sleman: Deepublish, 2021. [Online]. Available: [https://books.google.co.id/books?hl=id&lr=&id=QxZSEQAAQBAJ&oi=fnd&pg=PR4&dq=buku+konvolusi+cnn+dan+canny&ots=YwU9cpE32X&sig=QwebSpf4O-ZrzQdr2Ey6OKEEym&redir\\_esc=y#v=onepage&q&f=false](https://books.google.co.id/books?hl=id&lr=&id=QxZSEQAAQBAJ&oi=fnd&pg=PR4&dq=buku+konvolusi+cnn+dan+canny&ots=YwU9cpE32X&sig=QwebSpf4O-ZrzQdr2Ey6OKEEym&redir_esc=y#v=onepage&q&f=false)
- [9] N. Althuniyan, A. R. Al-Shamasneh, A. Bawazir, Z. Mohiuddin, and S. Bawazir, "DeepLeaf: Automated Leaf Classification Using Convolutional Neural Networks," *Eur. Sci. Journal, ESJ*, vol. 20, no. 30, p. 22, Oct. 2024, doi: 10.19044/esj.2024.v20n30p22.
- [10] M. E. Irhebhude, "Classification Of Plants By Their Fruits And Leaves Using Convolutional Neural Networks," *Sci. Inf. Technol. Lett.*, vol. 5, no. 1, pp. 1–15, Oct. 2024, doi: 10.31763/sitech.v5i1.1364.
- [11] S. Dewi, F. Ramadhani, and S. Djasmayena, "Klasifikasi Jenis Jerawat Berdasarkan Gambar Menggunakan Algoritma CNN ( Convolutional Neural Network )," *Hello World*, vol. 3, pp. 4–9, 2024.
- [12] A. Ibnul Rasidi, Y. A. H. Pasaribu, A. Ziqri, and F. D. Adhinata, "Klasifikasi Sampah Organik dan Non-Organik Menggunakan Convolutional Neural Network," *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 1, Apr. 2022, doi: 10.28932/jutisi.v8i1.4314.

- 
- [13] G. Kaur, N. Sharma, S. Malhotra, S. Devlival, and R. Gupta, "Kidney Tumor Detection and Classification Using Convolutional Neural Network Architecture," in *2024 2nd World Conference on Communication & Computing (WCONF)*, IEEE, Jul. 2024, pp. 1–5. doi: 10.1109/WCONF61366.2024.10691954.
- [14] W. Setiawan, *Deep Learning Menggunakan Convolutional Neural Network : Teori dan Aplikasi*. Malang: Media Nusa Creative, 2020. [Online]. Available: <https://bintangpusnas.perpusnas.go.id/konten/BK22660/deep-learning-menggunakan-convolutional-neural-network-teori-dan-aplikasi#>
- [15] A. Zhang, Z. C. Lipton, M. Li, and A. J. Smola, *Dive into Deep Learning*, 1st ed. Melbourne: Cambridge University Press, 2023. [Online]. Available: <https://books.google.co.id/books?id=vfDiEAAAQBAJ>
- [16] E. L. Frannita and A. R. Prananda, "Penerapan Metode CNN (Convolutional Neural Network) untuk Mengklasifikasikan Jenis Cacat pada Kulit Hewan," *TIN Terap. Inform. Nusant.*, vol. 5, no. 2, pp. 125–134, Jul. 2024, doi: 10.47065/tin.v5i2.5390.