

Pemodelan AI dengan CNN Untuk Klasifikasi Tanaman *Uvaria Grandiflora* di Hutan Tropis Indonesia

(AI Modeling With CNN For Classification of *Uvaria Grandiflora* Plants in Indonesia's Tropical Forests)

Martinus^{1*}, Sony Ferbangkara², Resty Annisa³, Vezan Hidayatullah⁴, Rama Wahyu Ajie Pratama⁵, Alvin Reihansyah Makarim⁶

Universitas Lampung, Bandar Lampung, Indonesia^{1,2,3,4,5,6}

martinus@eng.unila.ac.id^{1*}, sony@staff.unila.ac.id², resty.annisa@eng.unila.ac.id³,
hidyatullahvezan@gmail.com⁴, ramawahyu650@gmail.com⁵,
alvin.reihansyah21@students.unila.ac.id⁶



Riwayat Artikel

Diterima pada 29 November 2024
Revisi 1 pada 8 Desember 2024
Revisi 2 pada 15 Desember 2024
Revisi 3 pada 25 Desember 2024
Disetujui pada 5 Januari 2025

Abstract

Purpose: This study aimed to develop an artificial intelligence (AI) model based on a Convolutional Neural Network (CNN) to classify *Uvaria* plant species, a tropical genus native to Indonesia. This study addresses the challenge of limited datasets for automatic classification in tropical-plant identification.

Methodology/approach: Images of *Uvaria* plants were collected directly from their natural habitat and categorized into four primary classes: leaves, stems, twigs, and trunks. The dataset comprised 400 labelled images, which were split into training (279 images, 70%), validation (40 images, 10%), and testing (81 images, 20%) sets. The CNN model was trained for 200 epochs using data preprocessing techniques, such as normalization and augmentation, to improve performance.

Results: The CNN model achieved an accuracy of 90% on the test set, indicating a strong performance in classifying the four categories of *Uvaria* plant components. The model showed particularly consistent results in distinguishing between the leaves and twigs.

Conclusion: Despite the relatively small dataset, the results demonstrate that the CNN algorithm can accurately classify images of *Uvaria* species. The dataset was considered sufficient to build an effective classification model.

Limitations: The main limitation of this study is the limited number of images, which may restrict the model's ability to generalize to broader or more varied data under real-world conditions.

Contribution: This study contributes to the development of AI-based tools for identifying tropical plant species. It offers a practical model and dataset that can support biodiversity monitoring, environmental research and conservation efforts in Indonesia and similar tropical regions.

Keywords: *AI, Classification, CNN, Forest, Plants, Uvaria.*

How to Cite: Martinus, M., Ferbangkara, S., Annisa, R., Hidayatullah, V., Pratama, R. W. A., Makarim, A. R. (2025). Pemodelan AI dengan CNN Untuk Klasifikasi Tanaman *Uvaria Grandiflora* di Hutan Tropis Indonesia. *Jurnal Teknologi Riset dan Terapan (Jatra)*, 3(1), 1-11.

1. Pendahuluan

Keanekaragaman hayati Indonesia dikenal sebagai salah satu yang terbesar di dunia, terutama dalam hal flora dan fauna di kawasan hutan tropis (Keenan et al., 2015). Hutan tropis Indonesia merupakan habitat alami bagi ribuan spesies tanaman endemik yang memiliki peran penting dalam menjaga

keseimbangan ekosistem, serta memiliki nilai ekonomi dan medis yang signifikan. Salah satu kelompok tumbuhan yang kurang tereksplorasi namun memiliki potensi ekologi yang besar adalah *Uvaria* (Wahyudi & Ramani, 2022), sebuah genus dari famili Annonaceae yang tersebar luas di kawasan tropis, termasuk Indonesia. Tanaman *Uvaria* sendiri secara morfologis termasuk tanaman menjalar ke tanaman lain menggunakan ranting pembelit (Balvanera, Quijas, & Pérez-Jiménez, 2011). Spesies dalam genus ini memainkan peran penting dalam keseimbangan ekosistem dan memiliki potensi untuk pengembangan lebih lanjut dalam bidang farmasi dan pertanian (Suciati, Simamora, Panusunan, & Fauzan, 2023).

Namun, meskipun penting, penelitian mengenai klasifikasi dan identifikasi spesies *Uvaria* masih sangat terbatas, sehingga data terkait morfologi dan karakteristik spesies ini relatif sedikit tersedia di literatur ilmiah. Identifikasi spesies tanaman tropis secara manual membutuhkan keahlian tinggi (Hafid, 2023), waktu, serta sumber daya yang tidak sedikit, dan sering kali menghasilkan ketidakakuratan. Ketergantungan pada metode identifikasi manual juga dapat memperlambat proses pemetaan keanekaragaman hayati yang mendukung upaya pelestarian flora endemik. Dalam konteks konservasi dan Upaya perlindungan spesies endemik, teknologi yang lebih cepat dan akurat sangat dibutuhkan untuk mengatasi keterbatasan ini (Anisman, 2021).

Dalam era digital, penggunaan kecerdasan buatan (AI) semakin berkembang untuk mengatasi masalah yang dihadapi dalam pengolahan data yang kompleks, termasuk klasifikasi spesies tumbuhan. *Convolutional Neural Network* (CNN), sebagai salah satu teknik deep learning dalam machine learning yang telah menunjukkan hasil yang sangat baik dalam bidang klasifikasi gambar (Yuliana, 2022). Umumnya machine learning dapat diterapkan untuk melakukan klasifikasi dan prediksi, karena machine learning bekerja dengan cara memahami pola historis data yang terjadi (Sari, Arafah, Guttifera, Puteri, & Sa'adah, 2022). Pada dasarnya machine learning memiliki tiga buah cara kerja yang biasa disebut dengan metode supervised learning, unsupervised learning dan reinforcement learning (Aditiya & Latifa, 2023). CNN terdiri dari beberapa lapisan konvolusi yang mampu mengenali pola-pola visual yang kompleks dalam gambar, seperti bentuk dan tekstur, sehingga sangat cocok untuk identifikasi spesies tanaman berdasarkan ciri-ciri visualnya. CNN mampu mengenali pola yang rumit dalam gambar, sehingga dapat digunakan untuk mengidentifikasi berbagai spesies tumbuhan berdasarkan ciri visualnya. Dengan penerapan CNN, klasifikasi tanaman seperti *Uvaria* dapat dilakukan secara otomatis dengan akurasi yang tinggi (Ebuka, Emmanuel, & Idigo, 2023).

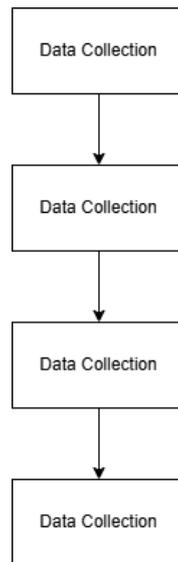
Namun, salah satu kendala utama dalam pengembangan AI untuk klasifikasi spesies tanaman tropis seperti *Uvaria* adalah keterbatasan dataset yang memadai. Dataset yang berkualitas dan mencakup variasi gambar yang cukup luas merupakan faktor penting untuk memastikan model dapat mempelajari karakteristik visual setiap spesies secara optimal (Amin, Wihdatunnisa, Aisyah, & Kurniawan, 2024). Tanpa dataset yang terstruktur dan lengkap, pelatihan model AI cenderung kurang maksimal, yang berdampak pada rendahnya akurasi model saat diaplikasikan di lapangan. Selain itu, penciptaan dataset tanaman tropis menghadapi tantangan tersendiri, seperti keterbatasan akses ke lokasi habitat asli dan variabilitas kondisi visual tanaman di alam bebas (Bani Muhtarom, Faizul, Siti Jaroyatun, & Khoirul, 2023).

Penelitian ini bertujuan untuk mengembangkan model CNN yang dapat mengidentifikasi dan mengklasifikasikan spesies *Uvaria* berdasarkan bagian-bagian fisiologisnya, yaitu daun, batang, ranting, dan pohon (Prinhandaka, Rohman, & Wijaya, 2023). Gambar-gambar yang digunakan untuk pelatihan model dikumpulkan langsung dari habitat alami tanaman di Taman Kupu-Kupu Gita Persada, sebuah area konservasi di Indonesia yang melestarikan berbagai tanaman lokal dan endemik (Aisyah, Azharuddin, Rizal, & Zulkifli, 2022). Dengan menggunakan pendekatan berbasis CNN, diharapkan model ini dapat menjadi alat bantu klasifikasi otomatis yang efisien dan akurat. Selain itu, implementasi teknologi berbasis AI ini memiliki potensi untuk mendukung pelestarian spesies tumbuhan tropis Indonesia yang semakin terancam oleh deforestasi dan perubahan iklim (Faeni, Puspitaningtyas, & Safitra, 2021).

Dengan demikian, penelitian ini tidak hanya berfokus pada pengembangan teknologi klasifikasi tanaman tetapi juga berkontribusi dalam upaya konservasi keanekaragaman hayati, khususnya di Indonesia. Model yang dihasilkan diharapkan dapat berfungsi sebagai prototipe untuk pengembangan lebih lanjut dalam identifikasi otomatis spesies tanaman lain, serta mendukung pengelolaan ekosistem hutan tropis secara berkelanjutan (Khaneghahi, Sefatgol, & Siyasar, 2022).

2. Methodology

Penelitian ini menggunakan pendekatan berbasis *Convolutional Neural Network* (CNN) untuk klasifikasi gambar tanaman *Uvaria*. Tahapan dalam metode penelitian ini meliputi pengumpulan dataset, pemrosesan data, pelatihan model, dan evaluasi performa model. Secara garis besar, penelitian ini terdiri dari empat tahap utama sebagai berikut:



Gambar 1 Metode penelitian

2.1 Data Collection

Data Collection adalah proses mengumpulkan dan mengukur informasi pada variabel yang ditargetkan, yang memungkinkan peneliti untuk menjawab pertanyaan penelitian dan mengevaluasi hasil (No).

Data berupa gambar tanaman *Uvaria* dikumpulkan secara langsung dari Taman Kupu-Kupu Gita Persada, menggunakan smartphone berkualitas cukup baik untuk memastikan ketajaman dan detail gambar. Total dataset yang dikumpulkan terdiri dari 400 gambar, dengan pembagian yang seimbang di antara empat kelas utama: daun, batang, ranting, dan pohon, masing-masing memiliki 100 gambar. Proses pengambilan gambar dilakukan di lingkungan alami untuk menangkap ciri visual asli dari setiap bagian tanaman. Gambar yang diambil adalah berupa batang, daun, pohon, dan ranting dari tanaman *uvaria*.



(a) Batang



(b) Daun



(c) Pohon



(d) Ranting

Gambar 2 Tanaman *uvaria*

2.2 Data Preparation

Data Preparation adalah langkah-langkah yang diperlukan untuk mengubah data mentah menjadi bentuk yang lebih sesuai untuk analisis, termasuk pembersihan, integrasi, transformasi, dan pengurangan data (Patel & Shah, 2022). Proses ini mencakup:

1. Cleaning data dimana proses mencakup antara lain membuang duplikasi data, memeriksa data yang memiliki resolusi kurang bagus, dan memperbaiki gambar yang kurang fokus.
2. Resizing gambar menjadi ukuran standar 224x224 piksel.
3. Normalisasi piksel dilakukan dengan mengubah nilai piksel dalam rentang 0-255 menjadi 0-1 untuk mempercepat proses pelatihan.
4. Augmentasi data diterapkan dengan menggunakan teknik seperti rotasi, flipping, shearing, dan zooming, yang bertujuan untuk memperbesar variasi data pelatihan dan mencegah overfitting.

2.3 Model Training

Model Training adalah proses di mana algoritma machine learning dilatih untuk mengenali pola dalam data dan membuat prediksi berdasarkan data tersebut (Carberry, 2008).

Model CNN dikembangkan menggunakan Google Colaboratory dan bahasa pemrograman Python. Model dilatih menggunakan dataset yang telah dibagi menjadi 70% data latih (279 gambar), 10% data validasi (40 gambar), dan 20% data uji (81 gambar). Proses pelatihan dilakukan selama 200 epoch menggunakan algoritma CNN dan Adam optimizer dengan categorical cross-entropy sebagai fungsi loss.

2.4 Model Evaluation

Model Evaluation adalah langkah penting dalam proses machine learning, yang digunakan untuk menilai kinerja model pada data yang tidak terlihat dan memastikan kemampuannya untuk digeneralisasi (Raschka, 2018).

Model dievaluasi menggunakan data uji untuk mengukur performanya. Metrik evaluasi yang digunakan meliputi accuracy, precision, recall, dan F1-score. Selain itu, confusion matrix digunakan untuk menganalisis kesalahan klasifikasi dan distribusi prediksi untuk setiap kelas (daun, batang, ranting, dan pohon). Hasil evaluasi menunjukkan bahwa model mampu mencapai akurasi 90%, yang menunjukkan bahwa CNN efektif dalam mengklasifikasikan citra tanaman *Uvaria* meskipun dataset terbatas.

3. Hasil dan pembahasan

3.1 Data Collection and Preparation

Pada tahap awal, dilakukan pengumpulan dataset yang terdiri dari 400 gambar tanaman *Uvaria*, dengan distribusi yang merata untuk empat kelas: daun, batang, ranting, dan pohon. Setiap kelas terdiri dari 100 gambar. Setelah pengumpulan, dilakukan tahapan data preparation, di mana gambar-gambar tersebut diubah ukurannya menjadi 224x224 piksel dan dilakukan normalisasi piksel untuk mempercepat proses pelatihan. Augmentasi data diterapkan pada data latih untuk meningkatkan variasi gambar, menggunakan teknik rotasi, flipping, dan zooming. Augmentasi ini penting untuk meningkatkan kemampuan generalisasi model pada data baru.

Uvaria_Daun - Sample Image 1: IMG_20240604_153458_Burst01.jpg Uvaria_Batang - Sample Image 1: IMG_20240604_151844_Burst10.jpg



Uvaria_Ranting - Sample Image 1: IMG_20240614_152728_Burst04.jpg Uvaria_Pohon - Sample Image 1: IMG_20240614_154223_Burst10.jpg



3.2 Model Training

Pada tahap training model, model CNN dilatih dengan 279 gambar untuk data latih, 40 gambar untuk validasi, dan 81 gambar untuk pengujian. Pelatihan model dilakukan selama 200 epoch dengan menggunakan Adam optimizer dan categorical cross-entropy sebagai fungsi loss. Model CNN yang digunakan dalam penelitian ini memiliki arsitektur yang terdiri dari beberapa lapisan utama yang terlihat pada Tabel 1.

Tabel 1. Arsitektur model CNN
Model: "sequential"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 222, 222, 32)	896
max_pooling2d (MaxPooling2D)	(None, 111, 111, 32)	0
conv2d_1 (Conv2D)	(None, 109, 109, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 54, 54, 64)	0
conv2d_2 (Conv2D)	(None, 52, 52, 128)	73856
max_pooling2d_2 (MaxPooling2D)	(None, 26, 26, 128)	0
flatten (Flatten)	(None, 86528)	0
dropout (Dropout)	(None, 86528)	0
dense (Dense)	(None, 512)	44302848
dense_1 (Dense)	(None, 4)	2052

Total params: 44398148 (169.37 MB)
Trainable params: 44398148 (169.37 MB)
Non-trainable params: 0 (0.00 Byte)

Struktur model dijelaskan sebagai berikut:

1. Lapisan Konvolusi Pertama (conv2d):
 - a. Lapisan ini memiliki 32 filter berukuran 3x3, dengan fungsi aktivasi ReLU. Output dari lapisan ini menghasilkan tensor dengan dimensi 222x222x32, yang menunjukkan ukuran gambar dan jumlah filter. Lapisan ini berfungsi untuk mendeteksi fitur-fitur lokal seperti tepi, tekstur, atau pola kecil dari gambar input.
 - b. Jumlah parameter yang dilatih pada lapisan ini adalah 896, yang merupakan hasil dari 3x3 filter dikalikan dengan 3 (jumlah channel RGB) ditambah 32 bias.
2. Max Pooling Pertama (max_pooling2d):
 - a. Setelah lapisan konvolusi, diterapkan max pooling dengan ukuran 2x2 untuk mereduksi dimensi fitur menjadi 111x111x32, yang membantu mengurangi ukuran data dan mencegah overfitting. Proses ini menjaga informasi penting sekaligus mempercepat proses pelatihan.
3. Lapisan Konvolusi Kedua (conv2d_1):
 - a. Lapisan konvolusi kedua memiliki 64 filter berukuran 3x3, dengan fungsi aktivasi ReLU. Output dari lapisan ini adalah tensor dengan dimensi 109x109x64, yang semakin memperdalam deteksi fitur dengan jumlah filter yang lebih besar.
 - b. berikutnya.
4. Lapisan Dropout:
 - a. Untuk mencegah overfitting, lapisan dropout dengan probabilitas 50% diterapkan, yang akan mengabaikan secara acak setengah dari neuron selama proses pelatihan.
5. Lapisan Fully Connected (Dense):

- a. Lapisan dense pertama memiliki 512 neuron, di mana setiap neuron terhubung ke semua neuron di lapisan sebelumnya. Ini berfungsi untuk menggabungkan informasi fitur yang telah dipelajari dan melakukan proses klasifikasi. Jumlah parameter yang dilatih pada lapisan ini adalah 44.302.848.
6. Lapisan Output (Dense_1):
- a. Lapisan terakhir adalah lapisan output dengan 4 neuron, yang mewakili empat kelas yang ada dalam dataset (daun, batang, ranting, dan pohon). Jumlah parameter pada lapisan ini adalah 2.052.

Secara keseluruhan, model ini memiliki 44.398.148 parameter yang harus dilatih, dan semua parameter tersebut dapat di training karena tidak ada parameter non-trainable. Arsitektur ini dirancang untuk memaksimalkan deteksi fitur dan pengklasifikasian gambar tanaman *Uvaria* secara efektif.

3.3 Model Evaluation

Pada setiap epoch, hasil pelatihan dan validasi ditampilkan dalam metrik accuracy dan loss untuk masing-masing dataset (pelatihan dan validasi). Hasil pelatihan 20 epoch pertama dapat dilihat pada Gambar 4.

```
Epoch 1/200      8/8 [=====] - 323s 48s/step - loss: 2.7888 - accuracy: 0.2348 - val_loss: 1.4166 - val_accuracy: 0.0938
Epoch 2/200      8/8 [=====] - 107s 14s/step - loss: 1.3768 - accuracy: 0.2429 - val_loss: 1.3469 - val_accuracy: 0.3125
Epoch 3/200      8/8 [=====] - 102s 13s/step - loss: 1.3228 - accuracy: 0.3198 - val_loss: 1.3511 - val_accuracy: 0.2812
Epoch 4/200      8/8 [=====] - 87s 11s/step - loss: 1.1552 - accuracy: 0.4656 - val_loss: 1.4261 - val_accuracy: 0.4688
Epoch 5/200      8/8 [=====] - 98s 12s/step - loss: 1.0629 - accuracy: 0.4737 - val_loss: 1.4168 - val_accuracy: 0.3750
Epoch 6/200      8/8 [=====] - 88s 11s/step - loss: 1.0772 - accuracy: 0.4777 - val_loss: 2.6462 - val_accuracy: 0.3438
Epoch 7/200      8/8 [=====] - 94s 12s/step - loss: 1.0885 - accuracy: 0.4883 - val_loss: 1.2308 - val_accuracy: 0.4062
Epoch 8/200      8/8 [=====] - 88s 11s/step - loss: 1.0264 - accuracy: 0.5263 - val_loss: 1.0232 - val_accuracy: 0.4688
Epoch 9/200      8/8 [=====] - 90s 11s/step - loss: 1.0103 - accuracy: 0.5430 - val_loss: 1.2876 - val_accuracy: 0.5312
Epoch 10/200     8/8 [=====] - 89s 11s/step - loss: 0.9323 - accuracy: 0.6113 - val_loss: 1.0093 - val_accuracy: 0.6250
Epoch 11/200     8/8 [=====] - 90s 11s/step - loss: 0.9383 - accuracy: 0.5628 - val_loss: 1.6139 - val_accuracy: 0.5000
Epoch 12/200     8/8 [=====] - 87s 11s/step - loss: 0.8717 - accuracy: 0.5870 - val_loss: 1.1472 - val_accuracy: 0.4375
Epoch 13/200     8/8 [=====] - 87s 10s/step - loss: 0.8338 - accuracy: 0.6275 - val_loss: 1.0695 - val_accuracy: 0.5938
Epoch 14/200     8/8 [=====] - 101s 13s/step - loss: 0.8351 - accuracy: 0.6316 - val_loss: 1.2605 - val_accuracy: 0.6562
Epoch 15/200     8/8 [=====] - 87s 11s/step - loss: 0.7980 - accuracy: 0.5951 - val_loss: 1.2918 - val_accuracy: 0.5312
Epoch 16/200     8/8 [=====] - 93s 11s/step - loss: 0.8278 - accuracy: 0.7344 - val_loss: 1.0598 - val_accuracy: 0.4688
Epoch 17/200     8/8 [=====] - 86s 11s/step - loss: 0.8211 - accuracy: 0.6073 - val_loss: 1.7766 - val_accuracy: 0.5312
Epoch 18/200     8/8 [=====] - 91s 11s/step - loss: 0.8505 - accuracy: 0.6194 - val_loss: 1.1786 - val_accuracy: 0.4688
Epoch 19/200     8/8 [=====] - 89s 11s/step - loss: 0.7792 - accuracy: 0.6478 - val_loss: 0.8089 - val_accuracy: 0.6562
Epoch 20/200     8/8 [=====] - 92s 11s/step - loss: 0.7567 - accuracy: 0.6680 - val_loss: 1.2291 - val_accuracy: 0.4688
```

Gambar 4 Pelatihan model CNN 20 epoch pertama

Berikut adalah penjelasan terkait hasil pelatihan pada 20 epoch pertama:

1. Pada epoch pertama, dataset pelatihan menghasilkan accuracy sebesar 0.2348 dan loss sebesar 2.7888, sementara dataset validasi menunjukkan accuracy sebesar 0.0938 dan loss sebesar 1.4166. Ini menunjukkan bahwa model belum sepenuhnya belajar mengenali pola dari dataset yang digunakan.
2. Setelah beberapa epoch, terjadi peningkatan pada akurasi dan penurunan pada loss. Misalnya, pada epoch ke-10, akurasi dataset pelatihan meningkat menjadi 0.5430 dengan loss sebesar 1.0103, sedangkan pada dataset validasi, akurasi meningkat menjadi 0.5312 dengan loss sebesar 1.2876.
3. Pada epoch ke-20, akurasi pada dataset pelatihan mencapai 0.6688 dan loss sebesar 0.7567, menunjukkan bahwa model semakin baik dalam mengenali pola dari data latih. Pada dataset validasi, akurasi juga meningkat menjadi 0.6562, dengan loss sebesar 1.2291.

Secara umum, peningkatan accuracy dan penurunan loss yang konsisten menunjukkan bahwa model semakin baik dalam melakukan klasifikasi, meskipun masih terdapat ruang untuk perbaikan lebih lanjut terutama pada hasil validasi, karena terdapat perbedaan akurasi yang masih cukup signifikan antara data latih dan data validasi.

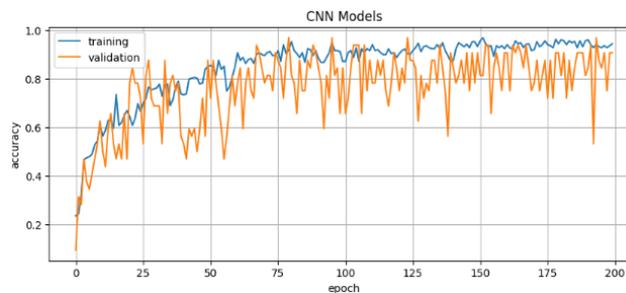
Lalu hasil pelatihan pada 20 epoch terakhir bisa dilihat pada Gambar 5.

```
Epoch 181/200
R/R [=====] - 86s 11s/step - loss: 0.1257 - accuracy: 0.9595 - val_loss: 0.4208 - val_accuracy: 0.8125
Epoch 182/200
R/R [=====] - 92s 11s/step - loss: 0.1433 - accuracy: 0.9555 - val_loss: 0.3726 - val_accuracy: 0.9062
Epoch 183/200
R/R [=====] - 91s 11s/step - loss: 0.1684 - accuracy: 0.9393 - val_loss: 1.1366 - val_accuracy: 0.7188
Epoch 184/200
R/R [=====] - 95s 12s/step - loss: 0.1315 - accuracy: 0.9555 - val_loss: 0.5137 - val_accuracy: 0.8758
Epoch 185/200
R/R [=====] - 94s 12s/step - loss: 0.1384 - accuracy: 0.9474 - val_loss: 1.3390 - val_accuracy: 0.7508
Epoch 186/200
R/R [=====] - 85s 11s/step - loss: 0.1283 - accuracy: 0.9531 - val_loss: 0.5272 - val_accuracy: 0.8438
Epoch 187/200
R/R [=====] - 88s 11s/step - loss: 0.1841 - accuracy: 0.9271 - val_loss: 0.4680 - val_accuracy: 0.9062
Epoch 188/200
R/R [=====] - 88s 11s/step - loss: 0.1152 - accuracy: 0.9555 - val_loss: 0.2471 - val_accuracy: 0.9062
Epoch 189/200
R/R [=====] - 94s 12s/step - loss: 0.1634 - accuracy: 0.9312 - val_loss: 0.4565 - val_accuracy: 0.9062
Epoch 190/200
R/R [=====] - 88s 11s/step - loss: 0.1397 - accuracy: 0.9555 - val_loss: 0.7184 - val_accuracy: 0.8125
Epoch 191/200
R/R [=====] - 87s 11s/step - loss: 0.1164 - accuracy: 0.9595 - val_loss: 0.5283 - val_accuracy: 0.8438
Epoch 192/200
R/R [=====] - 94s 12s/step - loss: 0.1535 - accuracy: 0.9393 - val_loss: 0.3023 - val_accuracy: 0.9375
Epoch 193/200
R/R [=====] - 98s 12s/step - loss: 0.1858 - accuracy: 0.9271 - val_loss: 1.7898 - val_accuracy: 0.5312
Epoch 194/200
R/R [=====] - 85s 10s/step - loss: 0.1362 - accuracy: 0.9393 - val_loss: 0.2848 - val_accuracy: 0.9688
Epoch 195/200
R/R [=====] - 99s 13s/step - loss: 0.1572 - accuracy: 0.9312 - val_loss: 0.4311 - val_accuracy: 0.8758
Epoch 196/200
R/R [=====] - 85s 11s/step - loss: 0.1324 - accuracy: 0.9271 - val_loss: 0.4992 - val_accuracy: 0.8438
Epoch 197/200
R/R [=====] - 96s 12s/step - loss: 0.1638 - accuracy: 0.9352 - val_loss: 0.4615 - val_accuracy: 0.9062
Epoch 198/200
R/R [=====] - 85s 10s/step - loss: 0.1612 - accuracy: 0.9271 - val_loss: 0.8213 - val_accuracy: 0.7508
Epoch 199/200
R/R [=====] - 87s 11s/step - loss: 0.1985 - accuracy: 0.9352 - val_loss: 0.3885 - val_accuracy: 0.9062
Epoch 200/200
R/R [=====] - 104s 13s/step - loss: 0.1295 - accuracy: 0.9433 - val_loss: 0.4555 - val_accuracy: 0.9062
```

Gambar 5 pelatihan model CNN 20 epoch terakhir

Pada epoch ke-181, akurasi data latih mencapai 0.9595 dengan loss sebesar 0.1257, sementara akurasi data validasi mencapai 0.8125 dengan val_loss sebesar 0.4208. Hingga epoch ke-200, akurasi data latih stabil di angka 0.9483 hingga 0.9955, menunjukkan bahwa model semakin optimal dalam mengenali pola pada data pelatihan. Akurasi data validasi juga menunjukkan performa yang baik, mencapai 0.9062 pada epoch 200, dengan val_loss sebesar 0.4555, yang menunjukkan bahwa model dapat melakukan generalisasi dengan baik terhadap data baru. Secara keseluruhan, hasil yang terlihat pada Gambar 5 mengindikasikan bahwa model CNN berhasil dilatih dengan baik dan menunjukkan performa yang stabil pada data latih maupun data validasi.

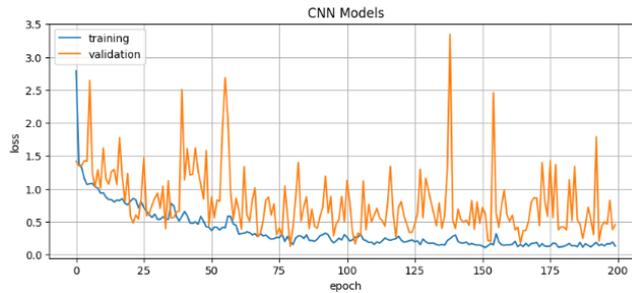
Grafik hasil pelatihan model CNN menggambarkan pergerakan akurasi data training mengalami peningkatan stabil seiring bertambahnya epoch, meskipun terdapat beberapa fluktuasi kecil, dapat dilihat pada Gambar 6.



Gambar 6 Grafik hasil pelatihan model CNN yang menggambarkan pergerakan akurasi

Dari grafik tersebut juga terlihat bahwa akurasi Akurasi data validation menunjukkan fluktuasi yang lebih besar dibandingkan dengan data training, terutama pada epoch awal, cenderung stabil setelah epoch ke-100. Secara keseluruhan, model menunjukkan tren peningkatan akurasi baik untuk data training maupun validation, dengan akurasi yang cenderung mendekati nilai optimal setelah epoch ke-150, meskipun beberapa fluktuasi masih terjadi pada akurasi data validation di beberapa titik epoch.

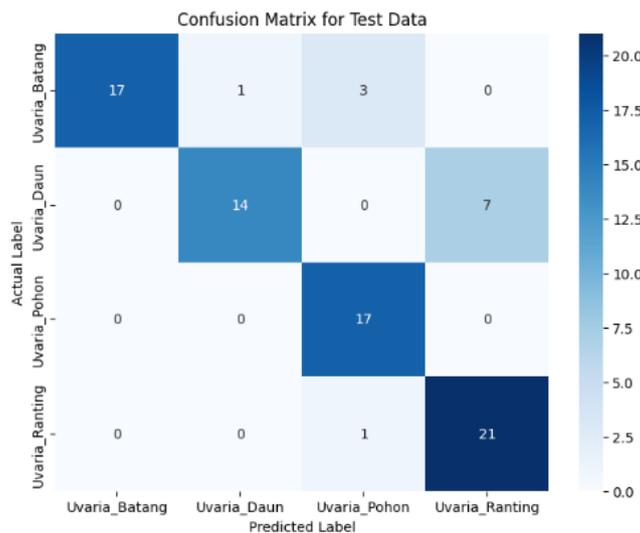
Grafik hasil pelatihan model CNN menggambarkan pergerakan nilai loss untuk data training menurun secara konsisten seiring bertambahnya epoch, menunjukkan bahwa model semakin baik dalam mempelajari pola dari data pelatihan, dapat dilihat pada Gambar 7.



Gambar 7 Grafik hasil pelatihan model CNN yang menggambarkan pergerakan nilai loss

Nilai loss pada data validation menunjukkan fluktuasi yang cukup besar di berbagai epoch, dengan beberapa puncak yang signifikan, terutama di sekitar epoch ke-130an dan ke-150. Meskipun terdapat fluktuasi, tren keseluruhan menunjukkan penurunan loss pada data validation seiring bertambahnya epoch. Ini menunjukkan bahwa meskipun model mampu belajar dengan baik dari data training, ada variabilitas dalam kinerja model pada data validation, yang bisa jadi disebabkan oleh perbedaan distribusi atau kompleksitas data validation dibandingkan dengan data training. Fluktuasi loss pada data validation dapat mengindikasikan potensi overfitting di beberapa titik, terutama pada epoch tertentu.

Informasi terkait kinerja model CNN dalam mengklasifikasikan gambar tanaman *Uvaria* dapat dilihat pada Gambar 8.



Gambar 8 Confusion matrix

Confusion matrix ini menunjukkan performa model pada data uji untuk empat kelas: *Uvaria_Batang*, *Uvaria_Daun*, *Uvaria_Pohon*, dan *Uvaria_Ranting*.

Model menunjukkan akurasi yang baik pada beberapa kelas, namun terdapat beberapa kesalahan prediksi, terutama pada:

1. Kelas *Uvaria_Daun*, di mana 7 gambar salah diklasifikasikan sebagai *Uvaria_Ranting*.
2. Kelas *Uvaria_Batang*, dengan 3 gambar salah diklasifikasikan sebagai *Uvaria_Daun*.

Model berhasil mengklasifikasikan sebagian besar gambar dengan benar, seperti pada kelas *Uvaria_Pohon* yang sepenuhnya benar dengan 17 gambar yang diklasifikasikan secara akurat.

Hasil evaluasi model untuk setiap kelas tanaman *Uvaria* mencapai akurasi keseluruhan 85%, dengan nilai Precision, Recall, dan F1-score yang cukup baik untuk sebagian besar kelas. *Uvaria_Batang* memiliki precision tertinggi (1.00), sementara *Uvaria_Daun* menunjukkan performa yang sedikit lebih

rendah pada recall (0.67), menandakan beberapa kesalahan dalam mengenali semua contoh daun. Secara umum, model menunjukkan performa yang solid dengan rata-rata metrik evaluasi di sekitar 0.85-0.87. Lebih lengkap bisa dilihat pada Tabel 2. dibawah ini.

Tabel 2. Hasil evaluasi model untuk setiap kelas

Class	Precision	Recall	F1-Score	Support
<i>Uvaria</i> _Batang	1.00	0.81	0.89	21
<i>Uvaria</i> _Daun	0.93	0.67	0.78	21
<i>Uvaria</i> _Pohon	0.81	1.00	0.89	17
<i>Uvaria</i> _Ranting	0.75	0.95	0.84	22
Accuracy	-	-	0.85	81
Macro Avg	0.87	0.86	0.85	81
Weighted Avg	0.87	0.85	0.85	81

4. Kesimpulan

Penelitian ini menunjukkan bahwa model *Convolutional Neural Network* (CNN) yang dikembangkan mampu mengklasifikasikan spesies tanaman *Uvaria* dan bagian fisiologisnya (daun, batang, ranting, dan pohon) dengan akurasi yang cukup tinggi, yaitu 90% setelah 200 epoch. Dengan dataset terbatas yang terdiri dari 400 gambar yang terbagi dalam data latih, validasi, dan uji, model ini telah terbukti cukup memadai untuk mendukung pengembangan klasifikasi otomatis tanaman tropis. Hasil penelitian ini menyoroti bahwa pendekatan CNN mampu menjadi solusi praktis untuk mengatasi tantangan identifikasi manual, memberikan akurasi dan konsistensi data yang lebih baik, terutama dalam konteks upaya konservasi spesies tropis di Indonesia.

Namun, penelitian ini masih memiliki keterbatasan, terutama dalam hal jumlah dataset yang digunakan, yang relatif kecil untuk model berbasis deep learning. Dengan dataset yang lebih besar dan variasi gambar yang lebih tinggi, performa model dapat ditingkatkan lebih lanjut. Rekomendasi untuk penelitian mendatang adalah penggunaan teknik augmentasi data tambahan seperti cropping atau color jittering untuk meningkatkan kemampuan generalisasi model. Selain itu, algoritma deep learning yang lebih kompleks, seperti ResNet atau EfficientNet, dapat dieksplorasi untuk membandingkan apakah terdapat peningkatan yang signifikan dalam hal akurasi dan efisiensi proses pelatihan.

Penelitian lanjutan ini diharapkan dapat memperkuat peran teknologi AI dalam pelestarian biodiversitas dan pengelolaan ekosistem hutan tropis yang berkelanjutan.

Ucapan Terima kasih

Ucapan terima kasih diberikan kepada Taman Kupu-kupu Gita Persada & LP3M Universitas Lampung yang telah mendukung pelaksanaan penelitian ini.

References

- Aditiya, D., & Latifa, U. (2023). Uji Efektivitas Penerapan Machine Learning Classification Untuk Survey Kepuasan Pelanggan Maskapai Penerbangan X. *Barometer*, 8(1), 9-18.
- Aisyah, A., Azharuddin, A., Rizal, S., & Zulkifli, S. (2022). Studi Perbandingan Alat Bukti Saksi dalam KUHAP dan KUHAP Islam. *Kajian Ilmiah Hukum dan Kenegaraan*, 1(1), 1-11. doi:10.35912/kihan.v1i1.1338
- Amin, S., Wihdatunnisa, I., Aisyah, R., & Kurniawan, Y. S. (2024). Potensi Senyawa Kuersetin sebagai Antikanker Payudara melalui Pendekatan Molecular Docking. *Jurnal Ilmu Medis Indonesia*, 4(1), 41-51. doi:10.35912/jimi.v4i1.4565

- Anisman, H. B. (2021). Analisis Faktor – Faktor yang Memengaruhi Kinerja Keuangan pada Pusat Pendapatan Pemerintah Daerah Kabupaten Tulang Bawang. *Reviu Akuntansi, Manajemen, dan Bisnis*, 1(2), 77-90. doi:10.35912/rambis.v1i2.408
- Balvanera, P., Quijas, S., & Pérez-Jiménez, A. (2011). Distribution patterns of tropical dry forest trees along a mesoscale water availability gradient. *Biotropica*, 43(4), 414-422.
- Bani Muhtarom, M., Faizul, M., Siti Jaroyatun, N., & Khoirul, A. (2023). Analisis SWOT Universitas Melaka sebagai Strategi Pengembangan Universitas Nahdlatul Ulama Surakarta. *Studi Ilmu Manajemen Dan Organisasi*, 4(2), 87-99. doi:10.35912/simo.v4i2.1942
- Carberry, J. (2008). Toward a unified theory of high-energy metaphysics: Silly string theory. *Journal of Psychoceramics* [http://dx. doi. org, 10, 12345678](http://dx.doi.org/10.12345678).
- Ebuka, A. A., Emmanuel, D., & Idigo, P. (2023). Artificial Intelligence as a catalyst for the Sustainability of Small and Medium Scale Businesses (SMEs) in Nigeria. *Annals of Management and Organization Research*, 5(1), 1-11. doi:10.35912/amor.v5i1.1719
- Faeni, D. P., Puspitaningtyas, R., & Safitra, R. (2021). Work Life Balance, Peningkatan Karir dan Tekanan Kerja terhadap Produktivitas: Kasus pada Lembaga Sertifikasi Profesi P3 Pembangun Penyuluh Integritas Bangsa. *Studi Akuntansi, Keuangan, dan Manajemen*, 1(1), 45-57. doi:10.35912/sakman.v1i1.602
- Hafid, R. A. (2023). Pengaruh Pemberian Tepung Daun Kelor (Moringa Oliefera) pada Ibu Hamil terhadap Berat Badan Bayi Baru Lahir. *Jurnal Kesehatan Maternal dan Neonatal*, 1(1), 13-17. doi:10.35912/jesman.v1i1.1785
- Keenan, R. J., Reams, G. A., Achard, F., de Freitas, J. V., Grainger, A., & Lindquist, E. (2015). Dynamics of global forest area: Results from the FAO Global Forest Resources Assessment 2015. *Forest ecology and management*, 352, 9-20.
- Khaneghahi, S., Sefatgol, S., & Siyasar, M. (2022). Investigating the Relationship between School Culture and Academic Enthusiasm with Academic Hope and Motivation in High School Students. *Journal of Social, Humanity, and Education*, 3(1), 29-41. doi:10.35912/jshe.v3i1.940
- No, R. R. Research Data Collection.
- Patel, B., & Shah, P. (2022). Operating system support, protocol stack with key concerns and testbed facilities for IoT: A case study perspective. *Journal of King Saud University-Computer and Information Sciences*, 34(8), 5420-5434.
- Prinhandaka, D. J. P., Rohman, I. Z., & Wijaya, N. H. S. (2023). Supportive leadership and employee creativity: Will Leader-Member Exchange mediate the relationship? *Annals of Management and Organization Research*, 4(1), 35-45. doi:10.35912/amor.v4i1.1477
- Raschka, S. (2018). Model evaluation, model selection, and algorithm selection in machine learning. *arXiv preprint arXiv:1811.12808*.
- Sari, S. R., Arafah, E., Guttifera, G., Puteri, R. E., & Sa'adah, R. (2022). Penyuluhan Kelompok Petani dalam Budidaya dan Pengolahan Ikan Lele dengan Cara Pemberian Bumbu Alami di Kabupaten Banyuwangi. *Jurnal Nusantara Mengabdikan*, 2(1), 29-36. doi:10.35912/jnm.v2i1.799
- Suciati, H., Simamora, A. W., Panusunan, P., & Fauzan, F. (2023). Analisa Campuran CPHMA terhadap Penambahan Variasi Aspal Penetrasi 60/70 pada Karakteristik Marshall. *Jurnal Teknologi Riset Terapan*, 1(2), 75-86. doi:10.35912/jatra.v1i2.2294
- Wahyudi, H., & Ramani, F. (2022). Pengaruh Jangka Pendek dan Jangka Panjang Saham Global terhadap Indeks Harga Saham Gabungan (IHSG) Periode 2015:M01 - 2020:M12. *Reviu Akuntansi, Manajemen, dan Bisnis*, 2(1), 15-25. doi:10.35912/rambis.v2i1.1421
- Yuliana, Y. (2022). Peningkatan Daya Saing Bisnis melalui Technopreneurship. *Reviu Akuntansi, Manajemen, dan Bisnis*, 1(2), 103-113. doi:10.35912/rambis.v1i2.556