

Analisis Akurasi dan Optimalisasi Dataset untuk Klasifikasi Tanaman *Aristolochia acuminata* dengan Algoritma CNN

(Accuracy Analysis and Dataset Optimization for Aristolochia acuminata Plant Classification Using the CNN Algorithm)

Sony Ferbangkara¹, Yessi Mulyani², Mardiana³, Rama Wahyu Ajie Pratama⁴, Renatha Amelia Manggala Putri⁵, Muhammad Afif Rafi'syaiim⁶

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

sony@staff.unila.ac.id¹, yessi.mulyani@eng.unila.ac.id², mardiana@eng.unila.ac.id³,
ramawahyu650@gmail.com⁴, renatha.amelia23@gmail.com⁵, mafif729@gmail.com⁶



Riwayat Artikel

Diterima pada 1 Desember 2024
Revisi 1 pada 8 Desember 2024
Revisi 2 pada 20 Desember 2024
Revisi 3 pada 1 Januari 2025
Disetujui pada 15 Januari 2025

Abstract

Purpose: Purpose: *Aristolochia acuminata* is a rare plant species of significant conservation value. However, the accurate classification of its parts, such as leaves, stems, and twigs, remains a challenge. This study aimed to develop a reliable classification model to support conservation efforts using Convolutional Neural Network (CNN) technology.

Methodology/approach: A digital dataset was systematically collected from various parts of *Aristolochia acuminata*, forming the foundation for training a CNN-based classification model. To evaluate the model performance and determine the optimal training parameters, three experimental scenarios were conducted using 10, 100, and 200 training epochs. The impact of each training duration on the classification accuracy was analyzed.

Results: The model trained with 200 epochs achieved the highest accuracy, outperforming those trained with 10 epochs (68.89%) and 100 epochs (86.67%). This suggests that a longer training period enables the model to learn the visual features of each plant part better, leading to improved classification performance.

Conclusion: The results confirm the effectiveness of CNN in classifying the components of *Aristolochia acuminata*. Using 200 training epochs allowed for deeper feature learning without overfitting, proving optimal in this context.

Limitations: This study was limited by the dataset size and the number of classes involved. Further expansion of the dataset and class categories could improve the generalizability of the model.

Contribution: This study contributes to plant conservation technology by demonstrating how CNN and structured dataset collection can be applied to classify rare plant species, providing a valuable tool for biodiversity preservation.

Keywords: *Aristolochia acuminata*, Convolutional Neural Network (CNN), Classification, Conservation technology, Machine Learning.

How to Cite: Ferbangkara, S., Mulyani, Y., Mardiana, M., Pratama, R. W. A., Putri, R. A. M., Rafi'syaiim, M. A. (2025). Analisis Akurasi dan Optimalisasi Dataset untuk Klasifikasi Tanaman *Aristolochia acuminata* dengan Algoritma CNN. *Jurnal Teknologi Riset dan Terapan (Jatra)*, 3(1), 13-20.

1. Pendahuluan

Indonesia merupakan salah satu negara dengan keanekaragaman hayati terbesar di dunia, termasuk kekayaan flora yang tersebar di berbagai ekosistem tropis (Malik, Anggreany, Sari, & Walid, 2020). Banyak di antaranya adalah spesies tanaman langka yang memiliki nilai ekologis dan ilmiah tinggi, seperti *Aristolochia acuminata* (Battu, Parimi, & Chandra Shekar, 2011). Tanaman ini dikenal karena perannya dalam menjaga keseimbangan ekosistem hutan tropis dan potensinya dalam bidang pengobatan tradisional (Van Do, Wanke, Neinhuis, & Pooma, 2015). Namun, kelangkaan data dan dokumentasi digital tanaman ini menjadi tantangan dalam upaya pelestarian dan klasifikasi (Ledo & Seran, 2019). Sebagian besar spesies langka, termasuk *Aristolochia acuminata*, kurang teridentifikasi secara mendalam di ranah digital, sehingga menghambat usaha konservasi dan pengembangan penelitian lebih lanjut (Parameshwara & Riza, 2023). Oleh karena itu, penting untuk mengembangkan metode yang efektif dan berbasis teknologi untuk melakukan klasifikasi otomatis tanaman langka guna mendukung pelestarian dan penelitian yang berkelanjutan (Iskandar & Aqbar, 2019).

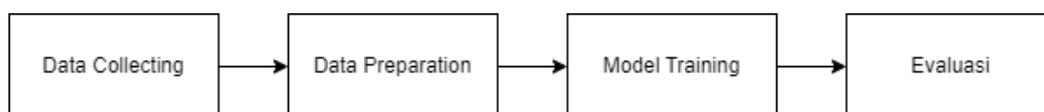
Kemajuan teknologi dalam bidang kecerdasan buatan, khususnya algoritma CNN, telah membuka peluang besar dalam mengatasi tantangan klasifikasi gambar tanaman secara otomatis (Holiyanti, Wati, Fahmi, & Rozikin, 2022). Algoritma CNN telah terbukti sangat efektif dalam pengenalan pola gambar, termasuk dalam bidang klasifikasi tanaman berdasarkan gambar daun, batang, dan bagian lainnya (Perwati, Suarna, & Suprapti, 2024). CNN mampu belajar dari dataset yang kaya dengan gambar untuk menghasilkan model prediksi yang akurat (Maulana, Putri, Amelia, Syahputra, & Ramadhani, 2024). Meskipun demikian, kualitas dan kuantitas dataset menjadi faktor kunci yang mempengaruhi performa algoritma ini. Di tengah keterbatasan dataset tanaman langka, optimalisasi dataset berbasis teknologi menjadi peluang untuk meningkatkan akurasi sistem klasifikasi tanaman (Agustina, 2023). Saat ini, pengumpulan dataset berbasis teknologi dan implementasi CNN pada spesies langka seperti *Aristolochia acuminata* menjadi salah satu solusi terdepan dalam usaha digitalisasi flora langka (Khaneghahi, Sefatgol, & Siyasar, 2022).

Untuk menghadapi masalah perlu dilakukan penelitian yang berfokus pada pengumpulan dataset berbasis teknologi dari tanaman *Aristolochia acuminata* dan penerapan algoritma CNN guna mengklasifikasikan bagian-bagian tanaman tersebut (Rauf & Andriyani, 2023). Proses penelitian melibatkan pengambilan gambar secara sistematis dari berbagai bagian tanaman seperti daun, batang, dan bunga, yang kemudian diolah dalam bentuk dataset yang representative (Faeni, Puspitaningtyas, & Safitra, 2021). Algoritma CNN digunakan untuk melatih model klasifikasi yang dapat mengidentifikasi dengan akurat gambar-gambar tanaman langka ini (Permana, Saldu, & Maulana, 2022). Optimalisasi dataset dilakukan melalui berbagai teknik preprocessing dan augmentasi data untuk meningkatkan performa model. Tujuan utama pengembangan model klasifikasi adalah menghasilkan sistem yang tidak hanya efisien (Pricillia, 2021), tetapi juga andal dalam mendukung pelestarian digital tanaman langka, sekaligus memberikan kontribusi signifikan terhadap kemajuan teknologi dalam konservasi biodiversitas (Suciati, Simamora, Panusunan, & Fauzan, 2023).

2. Metode penelitian

Metode penelitian yang digunakan terdiri dari empat tahap yaitu Data Collection, Data Preparation, Model Training, Model Evaluation yang dapat dilihat pada Gambar 1. Obyek pada penelitian adalah tanaman jengkol yang terbagi dalam lima kelas.

Dalam penelitian ini, diterapkan model CNN untuk mengotomatisasi proses klasifikasi bagian-bagian tanaman *Aristolochia acuminata*, yang dibagi menjadi 3 kelas: batang, daun, dan ranting.



Gambar 1. Metode Penelitian

2.1 Data Collecting

Data Collecting adalah kegiatan pengumpulan dataset digital dari berbagai bagian tanaman *Aristolochia acuminata* (Fajri, Malik, & Pratamasunu, 2022). Data dikumpulkan secara langsung di Taman Kupu-Kupu Gita Persada. Pengumpulan dilakukan dengan mengambil citra tanaman dari tiga bagian berbeda, yaitu batang (Gambar 2. Batang), daun (Gambar 3. Daun), dan ranting (Gambar 3. Ranting). Setiap bagian tanaman diambil dalam berbagai sudut dan kondisi cahaya untuk memastikan keragaman data yang digunakan dalam pelatihan model.



Gambar 2. Batang



Gambar 3. Daun



Gambar 4. Ranting

2.2 Data Preparation

Data Preparation merupakan tahap yang dilakukan untuk mempersiapkan dataset yang akan digunakan untuk klasifikasi, kemudian membersihkan data dan memilih data yang akan di proses untuk klasifikasi (Putra & Putri, 2022). Dalam penelitian ini, dataset terdiri dari total 450 citra, yang dibagi menjadi tiga set data: data latih, data validasi, dan data uji. Pembagian dilakukan secara acak dengan proporsi 70% (315 citra) sebagai data latih, 10% (45 citra) sebagai data validasi, dan 20% (90 citra) sebagai data uji (Prinhandaka, Rohman, & Wijaya, 2023).

2.3 Model Training

Pada proses pelatihan model klasifikasi citra berbasis CNN untuk dataset *Aristolochia acuminata* dilakukan dengan langkah-langkah sistematis. Dataset dibagi menjadi tiga bagian utama: 70% sebagai data pelatihan, 10% sebagai data validasi, dan 20% sebagai data pengujian. Kemudian dilakukan augmentasi data untuk meningkatkan keanekaragaman dataset, meliputi rotasi, flipping, dan perubahan kecerahan. Model dilatih selama 10, 100, dan 200 epoch untuk mengevaluasi kinerja pada berbagai konfigurasi.

2.4 Evaluasi

Setelah pelatihan, kinerja model dievaluasi menggunakan data uji yang telah disiapkan. Metrik evaluasi yang digunakan mencakup akurasi, precision, recall, dan F1-score (Arnandito & Sasongko, 2024). Proses evaluasi ini bertujuan untuk mengidentifikasi performa model dalam mengklasifikasikan setiap kelas, serta untuk menentukan area yang memerlukan optimalisasi lebih lanjut (Awaludin & Budiman, 2023).

3. Hasil dan pembahasan

Pada tahap mengembangkan model klasifikasi citra untuk mengidentifikasi bagian-bagian tanaman *Aristolochia acuminata* dengan menggunakan algoritma CNN berjalan lancar dan berhasil. Model ini dilatih menggunakan dataset yang terdiri dari gambar daun, batang, dan ranting. Setelah melalui berbagai konfigurasi pelatihan dengan 10, 100, dan 200 epoch, hasil terbaik dicapai pada 200 epoch dengan akurasi 88,89%.

3.1 Data Collecting

Proses pengumpulan data dilakukan dengan mengambil gambar tanaman *Aristolochia acuminata* di Taman Kupu-Kupu Gita Persada. Dataset yang dikumpulkan terdiri dari 450 gambar yang terbagi ke dalam tiga kelas berdasarkan bagian tanaman yaitu daun, ranting, dan batang dengan setiap kelas memiliki jumlah citra yang sama sejumlah 150 citra.



Gambar 2. Batang



Gambar 3. Daun



Gambar 4. Ranting

3.2 Data Preparation

Dalam data preparation ini data yang akan digunakan yaitu sebanyak 450 citra yang akan dibagi sebanyak 314 citra atau 70% dataset sebagai data latih, 45 citra atau 10% dataset sebagai data validasi, dan 91 citra atau 20% dataset sebagai data uji. Dataset tersebut terdiri dari 3 kelas berdasarkan 3 jenis bagian tanaman *Aristolochia acuminata*. Dalam 3 kelas ini memiliki jumlah dataset yang sama, seperti dalam kelas daun memiliki sebanyak 150 citra, kelas batang sebanyak 150 citra, dan kelas ranting sebanyak 150 citra.

3.3 Model Training

3.3.1 Spesifikasi Komputasi

Pelatihan model dilakukan menggunakan platform Google Colab dengan dukungan GPU, yang memungkinkan proses pelatihan berjalan lebih cepat dibandingkan menggunakan CPU. Ukuran batch yang digunakan adalah 32, yang merupakan ukuran standar untuk melatih model deep learning agar dapat mencapai keseimbangan antara kecepatan pelatihan dan penggunaan memori. Optimizer Adam dipilih karena kemampuannya dalam menangani data yang besar dan kompleks, serta memiliki keunggulan dalam konvergensi yang cepat. Selain itu, learning rate awal ditetapkan sebesar 0.001 untuk memastikan model dapat belajar secara stabil dan tidak melewati titik optimal.

3.3.2 Konfigurasi Pelatihan

Model dilatih dengan tiga konfigurasi jumlah epoch, yaitu 10, 100, dan 200 epoch, untuk mengevaluasi pengaruh jumlah epoch terhadap kinerja model. Berdasarkan hasil eksperimen, model yang dilatih dengan 200 epoch menunjukkan performa terbaik dengan akurasi tertinggi sebesar 88,89% pada dataset validasi. Penggunaan epoch yang lebih tinggi memungkinkan model untuk belajar lebih mendalam dari data, namun dengan tetap menghindari overfitting. Hasil ini menegaskan bahwa pelatihan dengan 200 epoch mampu mencapai keseimbangan antara akurasi dan generalisasi pada data validasi, dibandingkan konfigurasi dengan jumlah epoch yang lebih rendah.

3.4 Evaluasi

Berdasarkan hasil evaluasi model dataset pengujian pada Gambar 5 Hasil Akurasi 200 Epoch didapatkan metrik evaluasi sebagai berikut:

```

9/9 [=====] - 104s 11s/step - loss: 0.1202 - accuracy: 0.9468 - val_loss: 0.3453 - val_accuracy: 0.8438
Epoch 197/200
9/9 [=====] - 105s 11s/step - loss: 0.1226 - accuracy: 0.9514 - val_loss: 0.3803 - val_accuracy: 0.7812
Epoch 198/200
9/9 [=====] - 100s 11s/step - loss: 0.1209 - accuracy: 0.9539 - val_loss: 0.3680 - val_accuracy: 0.8750
Epoch 199/200
9/9 [=====] - 101s 11s/step - loss: 0.1394 - accuracy: 0.9433 - val_loss: 0.2741 - val_accuracy: 0.8750
Epoch 200/200
9/9 [=====] - 109s 12s/step - loss: 0.1089 - accuracy: 0.9610 - val_loss: 0.3297 - val_accuracy: 0.8750

# Evaluate the model
scores = model.evaluate(validation_generator)
print("%s%s: %.2f%%" % ("Evaluating the ", model.metrics_names[1], scores[1]*100))

2/2 [=====] - 9s 2s/step - loss: 0.2654 - accuracy: 0.8889
Evaluating the accuracy: 88.89%

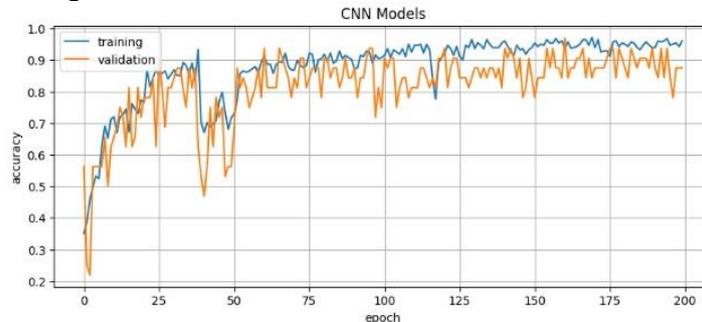
```

Gambar 5 Hasil Akurasi 200 Epoch

3.4.1 Grafik Akurasi dan Loss

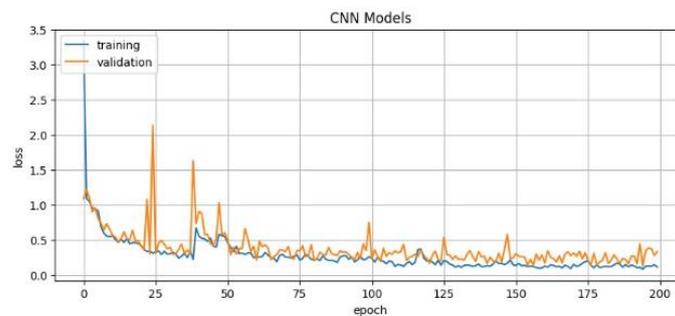
Grafik akurasi di atas menunjukkan kinerja model dalam memprediksi data secara benar, baik pada data pelatihan maupun validasi. Pada awal pelatihan, akurasi model berada di sekitar 20%-30%, namun seiring bertambahnya epoch, akurasi ini mengalami peningkatan yang signifikan. Setelah sekitar 25

epoch, akurasi pada data pelatihan mulai stabil di atas 90%, dan terus menunjukkan performa yang baik hingga akhir pelatihan. Akurasi pada data validasi juga mengalami peningkatan yang baik, namun lebih fluktuatif dibandingkan akurasi data pelatihan. Ini menunjukkan bahwa meskipun model bekerja dengan baik pada data latih, performa pada data validasi lebih bervariasi dan kurang stabil. Fluktuasi ini bisa jadi disebabkan oleh kompleksitas data validasi yang lebih tinggi atau data yang lebih sulit untuk diklasifikasikan dengan benar.



Gambar 6. Grafik Accuracy

Grafik loss memperlihatkan nilai kesalahan (loss) model selama proses pelatihan. Pada awal pelatihan, loss pada data pelatihan dan validasi berada di sekitar angka 3, yang menunjukkan bahwa model masih berada pada tahap awal pembelajaran dan belum mampu mengenali pola data dengan baik. Namun, setelah epoch pertama, loss mengalami penurunan yang cukup tajam dan stabil di sekitar angka 0.5 setelah sekitar 40 epoch. Pada data validasi, loss menunjukkan fluktuasi yang lebih signifikan dibandingkan data pelatihan, terutama pada epoch-epoch awal, yang mungkin disebabkan oleh variasi data validasi yang lebih menantang untuk diprediksi oleh model. Meskipun demikian, secara keseluruhan, model berhasil mengurangi kesalahan pada data pelatihan dan validasi, dengan fluktuasi loss validasi yang mengindikasikan tantangan dalam memprediksi beberapa sampel validasi. Fluktuasi ini juga bisa menjadi indikasi adanya kemungkinan overfitting pada model, di mana model terlalu menyesuaikan diri dengan data pelatihan namun kurang optimal pada data validasi.



Gambar 7. Grafik Loss

3.4.2 Precision, recall, dan f1-score

Berdasarkan hasil evaluasi model CNN yang digunakan untuk mengklasifikasikan bagian tanaman *Aristolochia acuminata*, model menunjukkan performa yang sangat baik dengan akurasi keseluruhan sebesar 96%. Metrik precision, recall, dan F1-score memperlihatkan kinerja model yang konsisten di berbagai kelas. Untuk kelas Batang, precision mencapai 0.88, yang berarti 88% dari prediksi batang adalah benar. Recall pada kelas ini mencapai 1.00, menunjukkan bahwa model berhasil mengenali seluruh gambar batang yang ada di dataset uji. F1-score untuk kelas batang adalah 0.94, yang mengindikasikan keseimbangan antara precision dan recall. Pada kelas Daun, model menunjukkan performa sempurna dengan precision, recall, dan F1-score semuanya bernilai 1.00, yang berarti semua prediksi untuk kelas daun adalah benar, tanpa ada kesalahan. Untuk kelas Ranting, precision mencapai 1.00, yang berarti semua prediksi ranting adalah benar. Namun, recall sedikit lebih rendah di angka 0.90, menunjukkan bahwa model tidak mengenali 10% gambar ranting yang ada. F1-score untuk kelas ranting adalah 0.95, yang menunjukkan performa yang baik secara keseluruhan untuk kelas ini. Secara

keseluruhan, model ini memiliki akurasi 96%, dengan macro average untuk precision, recall, dan F1-score masing-masing sebesar 0.96, 0.97, dan 0.96. Sementara itu, weighted average juga sangat baik dengan nilai precision, recall, dan F1-score masing-masing sebesar 0.97. Ini menunjukkan bahwa model bekerja dengan sangat baik di semua kelas meskipun ada sedikit perbedaan dalam jumlah data untuk setiap kelas.

Tabel 1. *Classification report*

	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>Support</i>
Batang	0.88	1.00	0.94	22
Daun	1.00	1.00	1.00	38
Ranting	1.00	0.90	0.95	31
<i>Accuracy</i>			0.97	91
<i>Macro avg</i>	0.96	0.97	0.96	91
<i>Weighted avg</i>	0.97	0.97	0.97	91

3.4.3 Confusion Matrix

Berdasarkan Confusion Matrix yang ditampilkan, kita dapat melihat performa model CNN dalam mengklasifikasikan data uji untuk bagian-bagian tanaman *Aristolochia acuminata*.

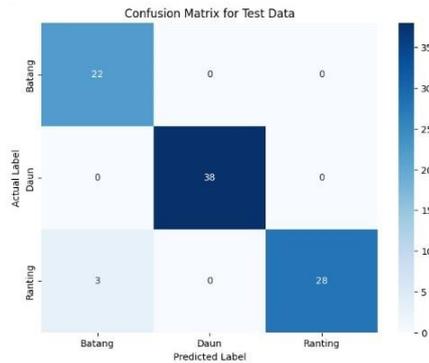
Struktur Confusion Matrix:

1. Sumbu Y (Actual Label): Ini adalah label yang benar atau ground truth, yaitu bagian tanaman sebenarnya yang ada dalam data uji.
2. Sumbu X (Predicted Label): Ini adalah hasil prediksi model berdasarkan klasifikasi yang dilakukan.
3. Diagonal matrix: Angka di diagonal menunjukkan jumlah prediksi yang benar untuk setiap kelas. Misalnya, pada kotak "Batang," angka 22 menunjukkan bahwa 22 citra batang diprediksi dengan benar sebagai batang.

Untuk kelas Batang, sebanyak 22 citra yang benar-benar merupakan batang diprediksi dengan benar sebagai batang, dan tidak ada kesalahan prediksi pada kelas ini, menunjukkan bahwa model sangat baik dalam mengenali citra batang. Kelas Daun menunjukkan performa sempurna dengan 38 citra daun yang diprediksi dengan benar sebagai daun, tanpa kesalahan prediksi. Ini menegaskan bahwa model memiliki performa yang sangat baik dalam mengklasifikasikan kelas daun. Untuk kelas Ranting, sebanyak 28 citra ranting diprediksi dengan benar sebagai ranting. Namun, ada 3 citra ranting yang salah diprediksi sebagai batang. Ini menunjukkan bahwa terdapat beberapa kesamaan visual antara ranting dan batang, yang membuat model kesulitan membedakan kedua kelas tersebut dalam beberapa kasus.

Tabel 2. *Confusion Matrix TP,FP,FN*

Class	<i>True Positive (TP)</i>	<i>False Positive (FP)</i>	<i>False Negativi (FN)</i>
Batang	22	3	0
Daun	38	0	0
Ranting	28	0	3



Gambar 8 Confusion Matrix

Sebagian besar kesalahan terjadi pada kelas ranting yang salah diprediksi sebagai batang. Hal ini mungkin disebabkan oleh kesamaan visual antara fitur ranting dan batang, sehingga model mengalami kesulitan dalam membedakan mereka. Secara keseluruhan, model menunjukkan performa yang sangat baik, terutama pada kelas daun, di mana prediksi benar sepenuhnya.

4. Kesimpulan

Penelitian ini telah berhasil mengembangkan model klasifikasi berbasis Convolutional Neural Network (CNN) untuk mengidentifikasi bagian-bagian tanaman *Aristolochia acuminata*. Tanaman ini merupakan salah satu spesies langka yang memiliki nilai konservasi tinggi, namun pengenalan otomatis dari bagian-bagian tanaman seperti daun, batang, dan ranting masih menjadi tantangan. Dengan menggunakan dataset yang mencakup 450 gambar dari bagian-bagian tanaman yang dikumpulkan secara langsung dari Taman Kupu-Kupu Gita Persada, model ini mampu dilatih untuk mengenali pola-pola visual dari ketiga kelas tersebut.

Hasil pelatihan menunjukkan bahwa jumlah epoch memainkan peran penting dalam meningkatkan performa model. Pada pengujian tiga skenario jumlah epoch (10 (68.89%), 100 (86.67%), dan 200 (88.89%), model yang dilatih dengan 200 epoch menunjukkan akurasi terbaik sebesar 88.89%. Hasil ini menegaskan bahwa pelatihan yang lebih lama memungkinkan model untuk lebih mendalam mempelajari karakteristik dari setiap bagian tanaman tanpa mengakibatkan overfitting, yang sering kali terjadi pada pelatihan dengan jumlah epoch yang terlalu tinggi. Meskipun model menunjukkan performa yang sangat baik pada data latih, variasi akurasi pada data validasi menunjukkan bahwa dataset yang lebih besar dan lebih beragam masih diperlukan untuk mencapai generalisasi yang lebih baik.

Ucapan terima kasih

Penulis mengucapkan terima kasih kepada Taman Kupu-Kupu Gita Persada dan LPPM Universitas Lampung yang telah memberikan dukungan serta hibah yang diberikan

References

- Agustina, E. (2023). Peran Pemerintah Daerah dalam Perizinan Pertambangan Timah dalam Pelaksanaan Reformasi Birokrasi. *Kajian Ilmiah Hukum dan Kenegaraan*, 2(1), 1-7. doi:[10.35912/kihan.v2i1.2254](https://doi.org/10.35912/kihan.v2i1.2254)
- Arnandito, S., & Sasongko, T. B. (2024). Comparison of EfficientNetB7 and MobileNetV2 in Herbal Plant Species Classification Using Convolutional Neural Networks. *Journal of Applied Informatics and Computing*, 8(1), 176-185. doi: [10.30871/jaic.v8i1.7927](https://doi.org/10.30871/jaic.v8i1.7927).
- Awaludin, Y. M., & Budiman, F. (2023). Optimasi Analisis Kesuburan Tanah Dengan Pendekatan Soft Voting Ensemble. *Jurnal SIMETRIS*, 14(2), 261-275. doi: [10.24176/simet.v14i2.11285](https://doi.org/10.24176/simet.v14i2.11285).
- Battu, G. R., Parimi, R., & Chandra Shekar, K. B. (2011). In vivo and in vitro pharmacological activity of *Aristolochia tagala* (syn: *Aristolochia acuminata*) root extracts. *Pharmaceutical biology*, 49(11), 1210-1214.

- 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
- Fajri, F. N., Malik, K., & Pratamasunu, G. Q. O. (2022). Metode Pengumpulan Data Pada Deteksi Pakaian Hijab Syar'I Berdasarkan Citra Digital Menggunakan Teachable machine Learning. *Justek: Jurnal Sains dan Teknologi*, 5(2), 194-203.
- Holiyanti, R., Wati, S., Fahmi, I., & Rozikin, C. (2022). Pendeteksi Sampah Metal untuk Daur Ulang Menggunakan Metode Convolutional Neural Network. *Jurnal Teknik Informatika dan Sistem Informasi*, 8(1), 261–274-261–274.
- Iskandar, A., & Aqbar, K. (2019). Green economy Indonesia dalam perspektif Maqashid Syari'ah. *Al-Mashrafiyah: Jurnal Ekonomi, Keuangan, dan Perbankan Syariah*, 3(2), 83-94.
- 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
- Ledo, S., & Seran, W. (2019). Keanekaragaman tumbuhan obat Taman Wisata Alam Baumata Kabupaten Kupang serta pemanfaatannya oleh masyarakat lokal. *Agrikan: Jurnal Agribisnis Perikanan*, 12(2), 299-310.
- Malik, A. A., Anggreany, R., Sari, M. W., & Walid, A. (2020). Keanekaragaman hayati flora dan fauna di kawasan taman nasional bukit barisan selatan (TNBBS) resort merpas bintuhan kabupaten kaur. *Diksains: Jurnal Ilmiah Pendidikan Sains*, 1(1), 35-42.
- Maulana, R., Putri, R. D. Z., Amelia, T. A., Syahputra, H., & Ramadhani, F. (2024). IDENTIFIKASI JENIS REMPAH-REMPAH INDONESIA DENGAN CONVOLUTIONAL NEURAL NETWORK (CNN) MENGGUNAKAN ARSITEKTUR VGG16. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(4), 6034-6039.
- Parameshwara, P., & Riza, K. (2023). Tindak Pidana Korupsi dalam Konteks Pertanggungjawaban Pidana Korporasi. *Jurnal Studi Multidisiplin Ilmu*, 1(1), 25-34. doi:10.35912/jasmi.v1i1.1973
- Permana, R., Saldu, H., & Maulana, D. I. (2022). Optimasi Image Classification Pada Jenis Sampah Dengan Data Augmentation Dan Convolutional Neural Network. *Jurnal Sistem Informasi dan Informatika (Simika)*, 5(2), 111-120.
- Perwati, I. G., Suarna, N., & Suprpti, T. (2024). Analisis Klasifikasi Gambar Bunga Lily Menggunakan Metode Convolutional Neural Network (Cnn) Dalam Pengolahan Citra. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(3), 2908-2915.
- Pricillia, T. (2021). Perbandingan metode pengembangan perangkat lunak (waterfall, prototype, RAD). *Jurnal Bangkit Indonesia*, 10(1), 6-12.
- 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
- Putra, M. Y., & Putri, D. I. (2022). Pemanfaatan Algoritma Naïve Bayes dan K-Nearest Neighbor Untuk Klasifikasi Jurusan Siswa Kelas XI. *J. Tekno Kompak*, 16(2), 176-187.
- Rauf, A., & Andriyani, D. (2023). Analisis Implementasi Good Governance terhadap Pelayanan Publik pada Dinas Kependudukan dan Catatan Sipil Kota Palembang. *Jurnal Studi Pemerintahan dan Akuntabilitas*, 2(2), 99-108. doi:10.35912/jastaka.v2i2.1850
- 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
- Van Do, T., Wanke, S., Neinhuis, C., & Pooma, R. (2015). *Aristolochia phuphathanaphongiana* sp. nov. from southwestern Thailand. *Nordic Journal of Botany*, 33(5), 567-571.