

Klasifikasi Citra Hewan Khas Suku Dayak Menggunakan Convolution Neural Network

*Classification of Animal Images Typical of Dayak Tribe
Using Convolution Neural Network*

Jeki¹, Maura Widyaningsih^{2*}, Lili Rusdiana³

^{1,2,3}*Program Studi Teknik Informatika STMIK Palangkaraya*

*corr-author: maurawidya@gmail.com

ABSTRAK

Fauna khas Dayak, seperti Orangutan, Burung Tingang, Bekantan, Lutung Merah, dan Owa Kalimantan, memiliki peranan penting dalam menjaga keseimbangan ekosistem dan melestarikan budaya masyarakat Kalimantan Tengah. Namun, rendahnya tingkat kesadaran generasi muda terhadap keberadaan fauna tersebut menjadi hambatan utama dalam upaya pelestariannya. Penelitian ini bertujuan untuk mengembangkan teknologi berbasis *Convolutional Neural Network* yang mampu mendukung pelestarian fauna khas Dayak melalui sistem klasifikasi otomatis yang lebih efisien dan akurat. Metode yang digunakan adalah pendekatan *transfer learning* dengan arsitektur CNN *InceptionV3*, disertai pengumpulan *dataset* dari berbagai sumber. *Dataset* ini diproses melalui tahap *resizing*, normalisasi, dan augmentasi untuk meningkatkan kualitas dan keberagaman data. Hasil penelitian menunjukkan bahwa model yang dikembangkan mampu mengklasifikasikan fauna khas Dayak dengan tingkat akurasi hingga 99,5% dan *F1-Score* sebesar 1,00. Teknologi ini diharapkan dapat meningkatkan kesadaran masyarakat akan pentingnya menjaga kekayaan alam serta warisan budaya Dayak.

Kata-kata kunci: *Convolutional Neural Network; Klasifikasi Fauna Dayak; Transfer Learning; InceptionV3*

ABSTRACT

Dayak's distinctive fauna, such as the Orangutan, Hornbill (Burung Tingang), Proboscis Monkey (Bekantan), Red Langur (Lutung Merah), and Bornean Gibbon (Owa Kalimantan), play a crucial role in maintaining ecosystem balance and preserving the cultural heritage of the Central Kalimantan community. However, the low awareness among younger generations about these species poses a significant challenge to conservation efforts. This research aims to develop a Convolutional Neural Network based technology to support the conservation of Dayak's distinctive fauna through a more efficient and accurate automatic classification system. The method employed involves a transfer learning approach using the CNN InceptionV3 architecture, along with dataset collection from various sources. The dataset was processed through resizing, normalization, and augmentation stages to enhance its quality and diversity. The results of this study indicate that the developed model can classify Dayak's distinctive fauna with an accuracy of up to 99.5% and an F1-Score of 1.00. This technology is expected to raise public awareness of the importance of preserving natural wealth and the cultural heritage of the Dayak community.

Keywords: *Convolutional Neural Network; Dayak Fauna Classification; Transfer Learning; InceptionV3*

PENDAHULUAN

Teknologi informasi berkembang pesat setiap harinya dan membawa dampak besar pada berbagai aspek kehidupan manusia, termasuk pendidikan dan pelestarian budaya (Zhao *et al.*, 2024). Di Indonesia, salah satu tantangan besar yang dihadapi adalah kurangnya kesadaran generasi muda terhadap fauna lokal, terutama di wilayah Kalimantan Tengah, yang merupakan rumah bagi berbagai spesies hewan khas, seperti burung tingang, owa kalimantan, orangutan, lutung merah, dan bekantan. Fauna ini memiliki nilai ekologis dan budaya yang penting, terutama bagi masyarakat Dayak. Namun, minimnya materi pembelajaran berbasis teknologi yang menarik dan interaktif menyebabkan pengetahuan tentang fauna ini mulai memudar di kalangan generasi muda.

Sebagai solusi, teknologi kecerdasan buatan (AI), khususnya *Convolutional Neural Network* (CNN), dapat digunakan untuk membantu dalam klasifikasi dan pengenalan citra satwa liar. CNN telah terbukti sangat efektif dalam mengenali objek pada gambar dan mampu menangani klasifikasi objek yang kompleks, seperti hewan (Alzubaidi *et al.*, 2021). Penelitian ini memanfaatkan CNN, dengan pendekatan *transfer learning*, untuk mengembangkan model klasifikasi citra hewan khas Dayak. Pendekatan ini memungkinkan model yang dilatih pada *dataset* besar untuk digunakan pada *dataset* yang lebih kecil, sehingga meningkatkan akurasi dan kecepatan dalam proses pelatihan.


Metode yang digunakan meliputi beberapa tahapan kunci. Pertama, pengumpulan *dataset* citra hewan khas Dayak dari berbagai sumber. Tahapan selanjutnya adalah *preprocessing*, yang meliputi pemrosesan awal seperti *resizing* normalisasi, dan augmentasi data untuk meningkatkan variasi data dan mengurangi bias model. Implementasi model CNN dengan strategi *transfer learning* kemudian dilakukan untuk membangun model klasifikasi. Setelah model selesai dilatih, tahap evaluasi dilakukan dengan mengukur kinerja model menggunakan metrik seperti akurasi, presisi, *recall*, dan *F1-Score* untuk mendapatkan gambaran yang komprehensif tentang kemampuan model dalam melakukan klasifikasi.

Penelitian ini berfokus pada pengembangan model klasifikasi citra hewan Dayak yang efektif dengan memanfaatkan teknologi *Convolutional Neural Network* (CNN). Model ini akan dilatih untuk dapat mengenali karakteristik visual yang spesifik dari setiap spesies, seperti bentuk tubuh, pola warna, tekstur bulu, dan ciri-ciri morfologi unik lainnya untuk membedakan satu spesies dengan spesies lainnya. Misalnya, Burung Tingang dapat diidentifikasi dari bentuk paruh yang melengkung dan pola warna yang kontras pada bulunya. Melalui pelatihan terhadap *dataset* yang telah disiapkan, model CNN ini diharapkan dapat secara efektif mengidentifikasi dan mengklasifikasikan fauna lokal berdasarkan ciri-ciri fisik tersebut. Oleh karena itu, hasil penelitian ini ditargetkan tidak hanya memberikan kontribusi dalam pengembangan teknologi klasifikasi citra berbasis CNN, tetapi juga dapat menjadi landasan dasar untuk penelitian lebih lanjut di bidang konservasi dan pelestarian fauna lokal Kalimantan Tengah yang mempunyai nilai budaya dan ekologi yang tinggi.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan berbasis *Convolutional Neural Network* (CNN) untuk melakukan klasifikasi citra fauna khas Dayak. Penelitian dilakukan melalui

beberapa tahapan utama yang dimulai dari pengumpulan data, *preprocessing* data, pengembangan model klasifikasi, pelatihan dan validasi model, hingga evaluasi performa model berdasarkan metrik tertentu sebagaimana ditunjukkan pada Gambar 1. Setiap tahap dalam penelitian ini dirancang untuk memastikan bahwa model yang dikembangkan dapat mengidentifikasi fauna khas Dayak dengan tingkat akurasi yang tinggi.




Gambar 1. Tahapan penelitian

1. Pengumpulan Dataset

Dataset dalam penelitian ini diperoleh dari berbagai sumber, baik dari *platform* publik seperti *Kaggle*, *Image.CV*, dan *RoboFlow*, maupun melalui dokumentasi dari lembaga konservasi yang memiliki arsip citra fauna khas Dayak. *Dataset* yang digunakan dalam penelitian ini terdiri dari lima kategori utama yang merepresentasikan fauna khas Dayak, yaitu Orangutan, Burung Tingang, Bekantan, Lutung Merah, dan Owa Kalimantan. Data yang digunakan meliputi gambar fauna khas Kalimantan dalam format RGB untuk menjaga informasi warna yang penting bagi model klasifikasi *Convolutional Neural Network* (CNN). Penentuan spesies-spesies tersebut didasari oleh keunikan dan pentingnya spesies tersebut dalam budaya dan ekologi Kalimantan. *Dataset* yang digunakan memiliki rincian yaitu; jumlah data kelas Kahu : 1.367 gambar, kelas Burung Tingang : 1.487 gambar, kelas Bakara : 1.296 gambar, kelas Kalasi : 213, dan kelas Kalawet : 161 gambar.

2. Preprocessing

Setelah dilakukan pengumpulan *dataset* pada tahap ini, penulis melakukan beberapa langkah untuk mempersiapkan data sebelum pelatihan model. Terdapat tiga proses utama yaitu *resizing*, normalisasi, dan augmentasi yang dapat dilihat pada Gambar 2.




Gambar 2. Tahapan *preprocessing*

- Resizing*: Semua gambar yang terdapat dalam *dataset* diubah ukurannya menjadi 299x299 piksel agar sesuai dengan kebutuhan arsitektur *InceptionV3*.
- Normalisasi*: Nilai piksel dalam gambar dikonversi ke skala [0,1] agar model dapat melakukan proses pelatihan dengan lebih stabil dan konvergen dengan lebih cepat.
- Augmentasi*: Teknik augmentasi data seperti rotasi, *flipping horizontal*, dan *zoom* digunakan untuk memperkaya variasi data yang digunakan dalam pelatihan model, sehingga model dapat lebih *robust* dalam mengenali pola visual yang berbeda.

3. Pembagian *Dataset*

Setelah dilakukan *preprocessing*, *dataset* dibagi menjadi tiga bagian utama, yaitu *training set* (80%), *validation set* (10%), dan *testing set* (10%). Pembagian ini dilakukan untuk memastikan bahwa model dapat belajar, divalidasi, dan diuji dengan data yang berbeda, guna menghindari *overfitting*. Pembagian ini dilakukan secara merata, memastikan distribusi kelas dalam setiap *set* tetap seimbang dan mewakili seluruh data. Pembagian *dataset* dapat dilihat pada Gambar 3.



Gambar 3. Pembagian *dataset*

- Training set*: Digunakan untuk melatih model. Gambar-gambar dalam training set membantu model mengenali pola-pola visual, seperti bentuk tubuh, warna, atau tekstur, yang khas dari setiap fauna Dayak.
- Validation set*: Digunakan untuk memantau performa model selama proses pelatihan. Data ini tidak dilibatkan dalam pelatihan, sehingga memberikan gambaran objektif mengenai kemampuan model dalam mengenali pola pada data baru.
- Testing set*: Digunakan untuk mengevaluasi kinerja akhir model. Data ini hanya digunakan setelah proses pelatihan selesai, untuk memastikan bahwa model dapat mengenali pola dengan akurat pada data yang belum pernah dilihat sebelumnya.


Hasil pembagian dari ketiga *set* ini dapat dilihat pada Tabel 1 yang merupakan distribusi jumlah data pada masing-masing kelas.

Tabel 1. Distribusi Jumlah Data Semua Kelas

Kelas	Pelatihan	Validasi	Pengujian	Total
Kahiu	1,093	136	138	1,367
Burung Tandang	1,186	148	149	1,483
Bakara	1,036	129	131	1,296
Kalasi	170	21	22	213
Kalawet	127	16	18	161


4. Implementasi Model *InceptionV3*

Pada tahap ini, penulis menerapkan model *InceptionV3* sebagai dasar untuk membangun arsitektur *Convolutional Neural Network* (CNN). *InceptionV3* adalah salah satu model yang telah dilatih sebelumnya dan populer, karena telah dilatih pada *dataset* besar seperti *ImageNet*, sehingga memiliki kemampuan luar biasa dalam mengenali pola visual pada gambar. Implementasi model *InceptionV3* dapat dilihat pada Gambar 4.



Gambar 4. Implementasi model *InceptionV3*

- a. Memuat model *InceptionV3* : Langkah pertama adalah memuat arsitektur model *InceptionV3* yang telah dilatih sebelumnya (*pretrained model*) dengan menggunakan bobot dari *dataset ImageNet*. Bobot *pretrained* ini digunakan sebagai dasar bagi model untuk mengenali pola-pola visual dasar seperti tepi, tekstur, dan bentuk. Pada tahap ini, penulis juga menetapkan dimensi input model sebesar 299x299 piksel dengan 3 saluran warna (RGB), sesuai dengan kebutuhan model *InceptionV3* untuk memastikan konsistensi pemrosesan data.
- b. Menghapus *fully connected layer* : Setelah model dimuat, penulis menghapus *fully connected layer* bawaan dari model *InceptionV3*. Lapisan ini awalnya dirancang untuk klasifikasi pada *dataset* besar seperti *ImageNet*, yang memiliki lebih dari 1.000 kelas, sehingga tidak sesuai untuk tugas klasifikasi fauna khas Dayak yang hanya melibatkan beberapa kelas spesifik. Penghapusan lapisan ini memungkinkan penyesuaian arsitektur model.
- c. Membekukan layer model *InceptionV3* : Pada tahap selanjutnya, penulis membekukan (*freeze*) layer-layer awal pada model *InceptionV3* untuk memastikan bobot pada layer-layer *pretrained* tersebut tidak mengalami perubahan selama proses pelatihan. Layer-layer awal ini telah dilatih untuk mengenali fitur-fitur dasar seperti garis, sudut, dan pola tekstur, yang bersifat universal dan tidak bergantung pada *dataset* tertentu.
- d. Membuat *custom layer* : Setelah melakukan pembekuan penulis menambahkan beberapa layer seperti, *GlobalAveragePooling2D layer*, *Dropout layer*, dan *Dense layer*, karena hanya lapisan khusus (*custom layers*) yang akan dilatih, serta menjaga stabilitas model dengan mempertahankan fitur dasar yang sudah optimal. Penambahan *custom layer* dilihat pada Gambar 5.



Gambar 5. Arsitektur model

- e. Kompilasi Model : Setelah arsitektur model selesai disusun, langkah berikutnya adalah mengompilasi model dengan parameter yang dirancang khusus untuk tugas klasifikasi. Proses kompilasi ini bertujuan untuk mengintegrasikan arsitektur model dengan fungsi *loss*, *optimizer*, dan metrik evaluasi yang akan digunakan selama pelatihan. Beberapa parameter yang digunakan antara lain seperti; *Optimizer: Adam* (*learning rate* 0.001), *Loss Function: Categorical Crossentropy*, *Batch Size: 32*, dan *Epochs: 50*.

5. Training Model

Setelah proses implementasi model *InceptionV3* dan model dikompilasi, pelatihan dilakukan menggunakan *training set*. Penulis menerapkan *early stopping* untuk menghentikan pelatihan jika nilai *loss* pada *validation set* tidak mengalami perbaikan dalam 10 *epoch* berturut-turut, dengan tujuan untuk mencegah *overfitting* dan menghemat waktu pelatihan. Selama proses pelatihan, model belajar untuk mengenali pola visual khas dari setiap fauna Dayak. *Validation set* digunakan untuk memantau kinerja model, sehingga penulis dapat mengevaluasi apakah model hanya "menghafal" data training atau benar-benar mampu mengidentifikasi pola secara umum.

6. Evaluasi Model

Setelah tahap *training* selesai dijalankan maka tahap evaluasi dilakukan untuk mengukur kinerja akhir model menggunakan *testing set*. Penulis menggunakan metrik seperti akurasi, presisi, *recall*, dan *F1-Score* untuk menilai hasil model.

- Jika akurasi model lebih dari 90%, maka model dianggap sangat baik dan siap digunakan dalam aplikasi praktis, seperti pendidikan atau pelestarian budaya.
- Jika akurasi berada di antara 80% hingga 90%, model dianggap cukup baik, tetapi masih memerlukan perbaikan, seperti menambah data atau memperbaiki tahap *preprocessing*.
- Jika akurasi di bawah 80%, penulis akan meninjau kembali langkah-langkah sebelumnya, termasuk pemilihan parameter model, variasi data, atau strategi augmentasi.

Evaluasi ini memberikan gambaran yang jelas tentang seberapa baik model dalam mengenali fauna khas Dayak dan memastikan model mampu menghasilkan hasil yang akurat dalam implementasinya.

HASIL DAN PEMBAHASAN

1. Penyesuaian *Hyperparameter*

Dalam penelitian ini, dilakukan eksperimen terhadap berbagai kombinasi *hyperparameter* untuk menentukan konfigurasi terbaik. *Tuning hyperparameter* dilakukan

pada empat model dengan variasi parameter seperti *learning rate*, jumlah *batch*, L2 dan jumlah *epoch*. Untuk penyesuaian *hyperparameter* semua model dapat dilihat pada Tabel 2.

Tabel 2. Hyperparameter

Model	Batch Size		Learning Rate	L2	Epoch
	Training	Validation			
Pertama	32	16	0,001	-	20
Kedua	32	16	0,001	0,01	20
Ketiga	32	16	0,001	-	20
Keempat	64	32	0,0001	-	50

Model pertama menggunakan *learning rate* 0.001 dengan *batch size* untuk *training* 32, sedangkan model kedua *learning rate* dan *batch size* masih sama tetapi ada penambahan dengan L2 dengan nilai 0,01. Model ketiga dengan *learning rate* dan *batch size relative* sama dengan kedua mode sebelumnya tetapi ada perubahan dengan menghilangkan L2. Model keempat menggunakan *learning rate* 0.0001 dengan *batch size* 32.

2. Augmentasi Data

Selanjutnya, augmentasi data diterapkan untuk memperkaya variasi dataset dan meningkatkan kemampuan generalisasi model. Teknik augmentasi yang diterapkan pada setiap model tetap sama, kecuali pada bagian *zoom* dan rotasi yang berbeda, untuk mencegah *overfitting* dan membuat model lebih responsif terhadap berbagai pola (Tabel 3).

Tabel 3. Augmentasi Data

Model	Augmentasi Data	
	Zoom	Rotasi (Derajat)
Pertama	30%	60
Kedua	30%	40
Ketiga	30%	30
Keempat	20%	30

Berdasarkan Tabel 3 menggambarkan strategi augmentasi yang diterapkan pada setiap model. Teknik augmentasi ini disesuaikan untuk mencapai keseimbangan antara variasi data dan kompleksitas pelatihan.

3. Perbandingan Akurasi Model

Hasil pelatihan dari keempat model diukur berdasarkan akurasi data pelatihan, validasi, dan pengujian.


Tabel 4. Perbandingan Akurasi Semua Model

Model	Accuracy		
	Training	Validation	Testing
Pertama	98,2%	99,5%	99,3%
Kedua	96,9%	98,4%	98,6%
Ketiga	98,4%	99,1%	99,3%
Keempat	98,1%	99,3%	99,5%

Dapat dilihat pada Tabel 4 menyajikan hasil performa masing-masing model. Model keempat mencatatkan akurasi tertinggi pada data pengujian, yaitu 99,5%, dengan perbedaan akurasi yang sangat kecil antara pelatihan, validasi, dan pengujian.

4. Pengujian

Analisis berikut mengevaluasi performa dari model keempat berdasarkan konfigurasi *hyperparameter* dan teknik augmentasi data yang diterapkan. Analisis akan ditampilkan dalam bentuk grafik performa, *classification report*, dan *confusion matrix* (Gambar 6).



Gambar 6. Grafik performa

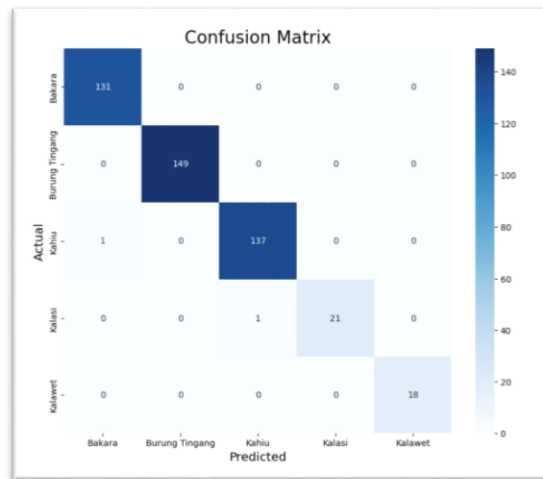
Pada Gambar 6 bagian *train loss* dan *validation loss*, peningkatan *batch size* menjadi 64 menghasilkan penurunan *loss* yang lebih stabil dan teratur. Dengan *learning rate* yang lebih rendah (0,0001) dan jumlah *epoch* yang diperpanjang hingga 50, model memiliki cukup waktu untuk belajar secara bertahap. Di akhir pelatihan, *loss* pada data pelatihan dan validasi hampir sejajar, menunjukkan bahwa model dapat belajar tanpa mengalami *overfitting*. Pada bagian *train accuracy* dan *validation accuracy*, akurasi pelatihan dan validasi mendekati angka 99% pada akhir pelatihan dan hampir identik. Hal ini menandakan bahwa model keempat memiliki kemampuan generalisasi terbaik dibandingkan model lainnya. Perbedaan yang sangat kecil antara akurasi pelatihan dan validasi, ditambah dengan tren yang stabil, merupakan hasil dari konfigurasi pelatihan yang dirancang dengan lebih optimal. Laporan hasil klasifikasi yang dilakukan oleh model ditunjukkan pada Gambar 7.

Classification Report:				
	precision	recall	f1-score	support
Bakara	0.99	1.00	1.00	131
Burung Tandang	1.00	1.00	1.00	149
Kahiu	0.99	0.99	0.99	138
Kalasi	1.00	0.95	0.98	22
Kalawet	1.00	1.00	1.00	18
accuracy			1.00	458
macro avg	1.00	0.99	0.99	458
weighted avg	1.00	1.00	1.00	458

Gambar 7. Classification report

Pada Gambar 7 model memberikan performa terbaik di antara semua model, dengan *precision*, *recall*, dan *F1-score* sempurna (1.00) untuk hampir semua kelas. Hal ini menunjukkan bahwa model dapat mendeteksi seluruh sampel dari semua kelas tanpa

kesalahan, termasuk kelas minoritas seperti Kalasi dan Kalawet. Akurasi keseluruhan mencapai 100%, dan nilai *macro average* serta *weighted average* juga mencapai angka sempurna (1.00). Ini menunjukkan bahwa model ini berhasil mengatasi ketidakseimbangan data dengan sangat baik. Berdasarkan grafik dan hasil evaluasi, stabilitas selama pelatihan serta jumlah *epoch* yang cukup berperan besar dalam peningkatan performa ini. Hasil evaluasi model dapat dilihat pada Gambar 8.



Gambar 8. Confusion Matrix

Pada Gambar 8 untuk model keempat menunjukkan performa terbaik dibandingkan semua model sebelumnya. Model ini berhasil mengklasifikasikan hampir seluruh kelas dengan akurasi tinggi, baik pada kelas mayoritas maupun minoritas. Untuk kelas Bakara, seluruh 131 sampel diklasifikasikan dengan benar tanpa kesalahan. Hal serupa terlihat pada kelas Burung Tingang, di mana semua 149 sampel berhasil dikenali dengan tepat. Pada kelas Kahiu, hanya satu kesalahan yang tercatat, yaitu satu sampel salah diklasifikasikan sebagai Kalasi, sementara 137 sampel lainnya diklasifikasikan dengan benar.

Kinerja model pada kelas minoritas juga menunjukkan hasil yang hampir sempurna. Untuk kelas Kalasi, 21 dari 22 sampel diklasifikasikan dengan benar, dengan hanya satu sampel yang salah diklasifikasikan sebagai Kahiu. Sementara itu, pada kelas Kalawet, model mencapai performa sempurna dengan semua 18 sampel diklasifikasikan dengan benar. Hasil ini mengindikasikan bahwa model keempat memiliki kemampuan generalisasi yang sangat baik, termasuk dalam menangani distribusi data yang tidak seimbang.

Peningkatan signifikan ini kemungkinan besar disebabkan oleh optimalisasi parameter pelatihan, seperti peningkatan *batch size*, penurunan *learning rate*, dan jumlah *epoch* yang lebih banyak, yang memberikan model waktu lebih lama untuk belajar secara mendalam dan stabil dari pola data yang ada. Hal ini menunjukkan bahwa model keempat tidak hanya efektif dalam mengenali pola dari data mayoritas tetapi juga mampu mengatasi tantangan klasifikasi pada kelas minoritas.

5. Prediksi

Pada tahap prediksi ini, model yang digunakan adalah model keempat karena model ini menunjukkan performa terbaik berdasarkan evaluasi sebelumnya. Pengujian dilakukan menggunakan *platform Google Colab*, yang menyediakan lingkungan berbasis cloud dengan dukungan GPU untuk mempermudah pelaksanaan proses. Proses ini dilakukan menggunakan 10 gambar, yang terdiri dari 2 sumber utama: gambar dari internet dan hasil jepretan kamera ponsel. Gambar-gambar ini mencakup 5 kelas fauna khas Dayak, dengan

distribusi sebagai berikut; Kahiu sebanyak 2 gambar, Burung Tingang sebanyak 2 gambar, Bakara sebanyak 2 gambar, Kalasi sebanyak 2 gambar, dan Kalawet sebanyak 2 gambar.

Setiap gambar diuji untuk memprediksi kelas fauna yang sesuai, dan hasil prediksi dibandingkan dengan label sebenarnya untuk menilai akurasi model. Hasil pengujian dapat dilihat pada Tabel 5.

Tabel 5. Hasil Prediksi

No	Kelas	Gambar	Prediksi	Keterangan
1	Kahiu	Gambar ke-1	Bakara	Tidak Sesuai
2	Kahiu	Gambar ke-2	Bakara	Tidak Sesuai
3	Burung Tingang	Gambar ke-1	Burung Tingang	Sesuai
4	Burung Tingang	Gambar ke-2	Burung Tingang	Sesuai
5	Bakara	Gambar ke-1	Kahiu	Tidak Sesuai
6	Bakara	Gambar ke-2	Kahiu	Tidak Sesuai
7	Kalasi	Gambar ke-1	Kalasi	Sesuai
8	Kalasi	Gambar ke-2	Kalasi	Sesuai
9	Kalawet	Gambar ke-1	Kalawet	Sesuai
10	Kalawet	Gambar ke-2	Kalawet	Sesuai

Informasi pada Tabel 5 menunjukkan bahwa kelas dengan jumlah data lebih besar, seperti Burung Tingang, memiliki performa yang baik karena variasi data yang cukup. Sebaliknya, kelas seperti Kahiu dan Bakara menunjukkan pola kesalahan yang konsisten akibat kesamaan karakteristik visual, yang membuat model kesulitan membedakannya. Kelas Kahiu sering diklasifikasikan sebagai Bakara karena pola visual yang mirip.

Kesalahan ini dapat dikurangi dengan menambah *dataset* atau menerapkan augmentasi data untuk meningkatkan variasi gambar. Sementara itu, kelas Burung Tingang memiliki akurasi tinggi karena *dataset* yang cukup serta karakteristik visual yang lebih khas, sehingga model dapat mempelajari pola dengan lebih baik. Di sisi lain, kelas Bakara juga sering diklasifikasikan sebagai Kahiu karena kesamaan pola visual dan ketidakseimbangan data. Untuk mengatasi hal ini, diperlukan penambahan *dataset* serta peningkatan variasi gambar agar model dapat membedakan kedua kelas dengan lebih baik. Kelas Kalasi menunjukkan hasil yang cukup baik meskipun *dataset* yang tersedia terbatas, namun masih terjadi beberapa kesalahan klasifikasi. Performa model pada kelas ini dapat ditingkatkan dengan menambah *dataset* serta memperluas variasi visual.

Adapun kelas Kalawet menunjukkan performa yang cukup konsisten, dengan sebagian besar sampel diklasifikasikan dengan benar. Namun, jumlah *dataset* yang terbatas dapat menjadi kendala, terutama jika gambar uji memiliki perbedaan signifikan dibandingkan dengan data pelatihan. Oleh karena itu, penambahan *dataset* dengan variasi yang lebih luas tetap diperlukan untuk menjaga performa model.

Dengan memanfaatkan teknologi kecerdasan buatan, pengawasan terhadap populasi fauna langka dapat dilakukan dengan lebih efisien dan akurat. Selain itu, model ini juga dapat diintegrasikan ke dalam sistem pemantauan berbasis aplikasi atau *platform* daring yang dapat digunakan oleh peneliti dan komunitas konservasi. Namun, penelitian ini masih memiliki beberapa keterbatasan, seperti keterbatasan jumlah dataset yang tersedia serta variasi latar belakang gambar yang dapat mempengaruhi hasil klasifikasi. Oleh karena itu, penelitian lanjutan dapat difokuskan pada pengumpulan *dataset* yang lebih luas serta eksplorasi arsitektur CNN yang lebih kompleks untuk meningkatkan performa model lebih lanjut.

Dengan demikian, penelitian ini tidak hanya memberikan kontribusi dalam bidang teknologi kecerdasan buatan, tetapi juga dalam aspek pelestarian lingkungan dan keanekaragaman hayati, khususnya bagi fauna khas Dayak di Kalimantan Tengah.

KESIMPULAN

Penelitian ini telah berhasil membangun model CNN yang dapat melakukan klasifikasi citra fauna khas Dayak dengan tingkat akurasi yang sangat tinggi. Dari empat model yang diuji, model keempat menunjukkan performa terbaik dengan akurasi mencapai 99,5%. Dengan hasil ini, dapat disimpulkan bahwa metode CNN dapat menjadi alat yang sangat efektif dalam mengidentifikasi dan mengklasifikasikan fauna khas Dayak. Keunggulan model ini terletak pada kombinasi *hyperparameter* yang optimal serta teknik augmentasi data yang diterapkan, yang memungkinkan model untuk belajar lebih baik dari *dataset* yang tersedia. Selain itu, penggunaan *confusion matrix* dan *classification report* telah membantu dalam mengevaluasi kesalahan klasifikasi yang terjadi, sehingga model dapat ditingkatkan lebih lanjut pada penelitian mendatang.

DAFTAR PUSTAKA

- Alzubaidi, L. *et al.* (2021) 'Review of deep learning: concepts, CNN architectures, challenges, applications, future directions', *Journal of Big Data*, 8(1), p. 53. Available at: <https://doi.org/10.1186/s40537-021-00444-8>.
- Azhar, K.M., Santoso, I. and Soetrisno, Y.A.A. (2021) 'Implementasi Deep Learning Menggunakan Metode Convolutional Neural Network Dan Algoritma Yolo Dalam Sistem Pendeteksi Uang Kertas Rupiah Bagi Penyandang Low Vision', *Transient: Jurnal Ilmiah Teknik Elektro*, 10(3), pp. 502–509. Available at: <https://doi.org/10.14710/transient.v10i3.502-509>.
- Ebbehoj, A. *et al.* (2022) 'Transfer learning for non-image data in clinical research: A scoping review', *PLOS Digital Health*, 1(2), p. e0000014. Available at: <https://doi.org/10.1371/journal.pdig.0000014>.
- Faruk Abdullah, R.R. and Hasan, M. (2022) 'Penerapan Convolutional Neural Network (CNN) Untuk Klasifikasi Penggunaan Masker', *Jurnal Ilmiah Ilmu Komputer Banthayo Lo Komputer*, 1(2), pp. 79–84. Available at: <https://doi.org/10.37195/balok.v1i2.164>.
- Huda, N. *et al.* (2023) 'Analisis Performa Inceptionv3 Convolutional Network Pada Klasifikasi Varietas Daun Grapevine', *Jurnal Sains Komputer dan Teknologi Informasi*, 5(2), pp. 47–53. Available at: <https://doi.org/10.33084/jsakti.v5i2.5022>.
- Kosman, A.W., Wahyuningsih, Y. and Mahendrasusila, F. (2024a) 'Penguujian Algoritma Inception V3 Dalam mengidentifikasi Penyakit Tuberculosis dan Pneumonia', *Jurnal Teknik Informatika dan Komputer*, 3(1), pp. 26–30. Available at: <https://doi.org/10.22236/jutikom.v3i1.13879>.
- Kosman, A.W., Wahyuningsih, Y. and Mahendrasusila, F. (2024b) 'Penguujian Metode Inception V3 dalam Mengidentifikasi Penyakit Kanker Kulit', *Jurnal Teknologi Informatika dan Komputer*, 10(1), pp. 132–142. Available at: <https://doi.org/10.37012/jtik.v10i1.1940>.
- Maulana, M.I., Nishom, M. and Af'idah, D.I. (2022) 'Pengolahan Citra untuk Identifikasi Pelat Nomor Kendaraan Mobil Menggunakan Metode Haar Cascade dan Optical Character Recognition', *Jurnal Bumigora Information Technology (BITE)*, 4(1), pp. 1–16. Available at: <https://doi.org/10.30812/bite.v4i1.1952>.
- Muftie, F., Yafi, K.M. and Addina, Q.M. (2024) 'Perbandingan performa deteksi cyberbullying dengan transformer, deep learning, dan machine learning', *Jurnal*

Pendidikan Informatika dan Sains, 13(1), pp. 75–87. Available at: <https://doi.org/10.31571/saintek.v13i1.4002>.

Nurkhasanah, N. and Murinto, M. (2022) ‘Klasifikasi Penyakit Kulit Wajah Menggunakan Metode Convolutional Neural Network’, *Sainteks*, 18(2), p. 183. Available at: <https://doi.org/10.30595/sainteks.v18i2.13188>.

Sahil Faizal and Sanjay Sundaresan (2022) ‘Wild Animal Classifier Using CNN’, *International Journal of Advanced Research in Science, Communication and Technology*, pp. 233–239. Available at: <https://doi.org/10.48175/IJARSCT-7097>.

Yu, C.H. *et al.* (2023) ‘RAF: Holistic Compilation for Deep Learning Model Training’.

Zeng, P. (2021) ‘Research on Similar Animal Classification Based on CNN Algorithm’, *Journal of Physics: Conference Series*, 2132(1), p. 012001. Available at: <https://doi.org/10.1088/1742-6596/2132/1/012001>.

Zhao, X. *et al.* (2024) ‘A review of convolutional neural networks in computer vision’, *Artificial Intelligence Review*, 57(4), p. 99. Available at: <https://doi.org/10.1007/s10462-024-10721-6>.