

KLASIFIKASI RAS KUCING MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK

Divasetya Pratama Putri¹, Riza Ibnu Adam²

¹Informatika, Universitas Singaperbangsa Karawang; Jl. H.S Ronggowaluyo, Telukjambe Timur, Karawang, Indonesia

Keywords:

Convolutional Neural Network;
Klasifikasi Ras Kucing;
Deep Learning;
Pengolahan Citra;
TensorFlow

Correspondent Email:

2110631170009@student.unsika.ac.id

Abstrak. Identifikasi ras kucing sering kali menjadi tantangan karena kemiripan visual antar ras, padahal pengenalan yang akurat penting untuk perawatan yang tepat. Penelitian ini bertujuan untuk membangun sebuah sistem klasifikasi ras kucing yang akurat menggunakan algoritma Convolutional Neural Network (CNN) dengan pendekatan *transfer learning*. Model dibangun menggunakan arsitektur MobileNetV2 pada dataset yang terdiri dari 2.387 gambar dari 12 ras kucing. Tahapan penelitian meliputi pengumpulan data, pra-pemrosesan, pembangunan dan pelatihan model, hingga evaluasi. Hasil evaluasi pada data uji menunjukkan bahwa model yang dikembangkan berhasil mencapai akurasi sebesar 84.52%. Model menunjukkan performa unggul pada beberapa kelas dengan ciri visual unik, namun masih memiliki tantangan pada kelas lain yang visualnya mirip. Hasil ini membuktikan bahwa metode CNN dengan *transfer learning* sangat efektif dan kompetitif untuk tugas klasifikasi ras kucing, dengan ruang untuk pengembangan lebih lanjut guna meningkatkan performa pada kelas yang sulit dibedakan.



JITET is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License

Abstract. Cat breed identification is often challenging due to visual similarities between breeds, yet accurate recognition is crucial for proper care. This study aims to develop an accurate cat breed classification system using a Convolutional Neural Network (CNN) algorithm with a transfer learning approach. The model was built using the MobileNetV2 architecture on a dataset consisting of 2,387 images from 12 cat breeds. The research stages included data collection, pre-processing, model construction and training, and evaluation. Evaluation results on test data showed that the developed model achieved an accuracy of 84.52%. The model demonstrated superior performance in several classes with unique visual characteristics, but still faced challenges in other classes with similar visual characteristics. These results demonstrate that the CNN method with transfer learning is highly effective and competitive for cat breed classification tasks, with room for further development to improve performance in difficult-to-distinguish classes.

1. PENDAHULUAN

Kucing merupakan hewan menggemaskan yang digemari banyak orang. Hal ini menyebabkan banyak orang sering memelihara kucing untuk dijadikan sebagai teman karena kucing mampu membentuk ikatan emosional dengan pemiliknya. Kucing memiliki banyak

ras dengan berbagai kepribadian yang unik. Ada sekitar 142 ras kucing yang dapat dijumpai [1]. Kepribadian unik tersebut mampu memberikan kegembiraan dan mengurangi rasa stress bagi pemiliknya. Umumnya, masyarakat Indonesia tidak menghiraukan perbedaan jenis ras dari kucing yang mereka jumpai. Sering kali

kucing yang memiliki bulu yang lebat disebut sebagai kucing ras Anggora, padahal bisa saja ras dari kucing tersebut adalah Maine Coon [2]. Perbedaan ras kucing perlu diperhatikan karena perawatan yang diperlukan setiap ras kucing ini berbeda.

Seiring berkembangnya zaman, teknologi juga ikut berkembang. Tidak sedikit pengembangan teknologi bertujuan untuk menolong kegiatan manusia. Klasifikasi objek merupakan topik umum yang sering kali muncul pada bidang Computer Vision. Computer Vision merupakan sebuah model yang dibuat berdasarkan sistem visual manusia sehingga sistem dapat melakukan tugas seperti yang dilakukan oleh sistem visual manusia. Untuk mengembangkan sistem yang mampu mengklasifikasikan objek, metode deep learning yang sering digunakan salah satunya ada metode Convolutional Neural Network (CNN). Sistem klasifikasi ini awalnya akan mengolah data dari grid piksel pada gambar masukan. Setelah itu akan diperoleh nilai berdasarkan tingkat terang dan warna. Pada proses klasifikasi, gambar masukan akan melalui rangkaian lapisan, lalu objek yang sudah diketahui akan diklasifikasikan ke kelompok yang sudah ada sebelumnya. Pada metode CNN, proses ini memerlukan proses pelatihan dan pengujian.

Beberapa penelitian telah melibatkan CNN sebagai teknik untuk melakukan klasifikasi objek. Penelitian oleh Ramadhayani dan Lusiana bertujuan untuk mengklasifikasi gambar kucing melalui tahap analisis citra asli, biner, dan grayscale. Ekstraksi ciri RGB dan HSV dilakukan untuk digunakan sebagai masukan bagi algoritma Principal Component Analysis (PCA) dan K-Nearest Neighbor (KNN). Dengan menggunakan 34 data citra (24 data latih dan 10 data uji) dari 3 jenis kucing (Anggora, Persia, dan Scottish Fold), penelitian ini berhasil mencapai tingkat akurasi klasifikasi sebesar 80% [3].

Lalu Hadi, et al melakukan penelitian yang mengklasifikasikan jenis ras kucing menggunakan algoritma Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF). Jenis ras kucing yang digunakan sebagai data adalah Bengal, Ragdoll, Russian Blue, Siamese, dan Persia. Penelitian ini memanfaatkan ekstraksi fitur Local Binary Patterns (LBP) setelah melalui proses pra-

pemrosesan seperti cropping, resizing, grayscale, dan unsharp masking. Dengan dataset gabungan 2250 sampel (1400 latih, 600 validasi, 250 uji), model SVM berhasil mencapai tingkat akurasi 86%, presisi 87%, recall 86%, dan F1-score 86% [4].

Pada penelitian yang dilakukan oleh Karim dan Herlangga, Convolutional Neural Network (CNN) digunakan untuk mengklasifikasikan senjata tradisional Jawa Barat menggunakan EfficientNetB0 sebagai model dasar dalam metode Transfer Learning. Studi ini memberikan dataset sebanyak 754 gambar dari 5 jenis senjata tradisional kepada sistem yang dibangun. Hasil evaluasi model menunjukkan akurasi mencapai 98,44%, dengan nilai loss rendah, meskipun akurasi validasi tidak melampaui 0.9794. Kekurangan teridentifikasi pada kelas "gacok" dengan nilai presisi 0.93, sementara kelas lainnya menunjukkan performa yang baik [5].

Penerapan algoritma CNN juga dilakukan pada penelitian yang dilakukan oleh Pratama, et al. CNN dan Faster R-CNN digunakan untuk klasifikasi kualitas biji kopi Arabika, Robusta, dan Liberica. Akurasi yang didapatkan sebesar 86% untuk algoritma CNN VGG-16 dan 93% untuk Faster R-CNN, dengan presisi 93%, recall 92%, dan skor F1 92% [6].

Berdasarkan penelitian sebelumnya, ras kucing dapat dikelompokkan dengan melihat bentuk wajah, jenis bulu, atau warna bulu dari kucing tersebut. Identifikasi ras kucing dapat dilakukan dengan algoritma deep learning, misalnya menggunakan algoritma Convolutional Neural Network (CNN) seperti yang akan dikembangkan pada penelitian ini. Penelitian ini bertujuan untuk membangun sistem yang dapat mengklasifikasikan ras kucing menggunakan Convolutional Neural Network (CNN) dan menganalisis efektivitasnya dalam mengatasi tantangan variasi visual antar ras, sebagai upaya meningkatkan akurasi identifikasi dibandingkan metode sebelumnya dan memanfaatkan potensi CNN yang terbukti unggul dalam klasifikasi objek.

2. TINJAUAN PUSTAKA

2.1 Klasifikasi

Klasifikasi adalah bahasa serapan yang diambil dari kata "classificatie" pada bahasa Belanda. Berdasarkan Kamus Besar Bahasa

Indonesia (KBBI), klasifikasi dapat diartikan sebagai suatu proses mengelompokkan data atau objek ke dalam kategori-kategori tertentu berdasarkan serangkaian kriteria atau standar yang telah didefinisikan sebelumnya [7].

2.2 Deep Learning

Deep Learning adalah cabang dari machine learning yang menggunakan algoritma yang terinspirasi oleh struktur otak manusia [8]. Deep Learning dapat mengubah representasi gambar sederhana menjadi konsep yang lebih kompleks secara otomatis, tanpa mengandalkan aturan kode atau pengetahuan manusia dalam domain tersebut. Oleh karena itu, model Deep Learning dapat mempercepat dan menyederhanakan tugas - tugas seperti deteksi objek, pengenalan suara, terjemahan bahasa, dan berbagai pekerjaan kecerdasan buatan lainnya.

2.3 TensorFlow

Tensorflow adalah framework Machine Learning yang sering digunakan oleh penggemar bidang AI (artificial intelligence), atau deep learning dalam hal bekerja dengan data. Tensorflow membantu membuat jaringan syaraf skala besar (jaringan buatan yang terlihat seperti otak manusia) [8]. TensorFlow bersifat Open Source dan didukung oleh Google dalam pengembangannya. Tensorflow memungkinkan pengguna untuk memilih berbagai macam algoritma Machine Learning melalui antarmuka yang cukup fleksibel dan mendukung penggunaan di beragam sistem [9].




Gambar 2.1 TensorFlow
(Sumber: [10])

2.4 Convolutional Neural Network

Salah satu metode Deep Learning adalah Convolutional Neural Network (CNN), yang merupakan turunan dari metode Artificial Neural Network (ANN). Meskipun CNN dan ANN memiliki arsitektur dan model yang serupa, namun ada perbedaan mencolok antara keduanya. Pada metode ANN, setiap node dalam jaringan berdiri sendiri, sementara pada CNN, node-node tersebut saling terhubung. Kelebihan ini membuat metode CNN lebih efisien dalam komputasi dibandingkan dengan

ANN, sehingga CNN lebih unggul dalam memindai bagian terkecil dari gambar [11].




Gambar 2.2 Arsitektur Convolutional
(Sumber: [12])

Dari Gambar 2.2, tahap pertama CNN adalah Feature Learning yang mengubah input menjadi fitur berdasarkan cirinya. Feature learning adalah proses encoding dari sebuah gambar menjadi feature yang berupa nilai-nilai yang merepresentasikan gambar tersebut. Proses ini terdiri dari beberapa layer yang saling bekerjasama untuk mengambil ciri dari sebuah gambar [13]. Lapisan feature learning terdiri dari convolution layer (menggunakan filter untuk mendeteksi karakter objek), fungsi aktivasi ReLU, dan pooling layer untuk menghasilkan feature maps. Tahap selanjutnya adalah klasifikasi yang mengklasifikasikan neuron dari feature maps. Terdiri dari flatten untuk me-reshape fitur, fully connected untuk mentransformasi data, dan softmax untuk menghitung kemungkinan kategori target [2].

2.5 Convolutional Layer


Arsitektur CNN tersusun atas berbagai lapisan, di mana salah satunya adalah Convolutional Layer. Di dalam lapisan ini juga terdapat beberapa filter konvolusi atau kernel yang berperan dalam memproduksi peta fitur yang dihasilkan. Gambar masukan akan melalui tahap ekstraksi fitur, di mana gambar dibagi menjadi beberapa bagian berdasarkan parameter piksel yang telah ditentukan. Proses konvolusi ini dapat menghasilkan gambar dengan ukuran yang lebih kecil atau ukuran yang sama namun dengan tingkat kedalaman yang berbeda. Konvolusi dapat dilihat sebagai perkalian matriks antara input citra dan kernel, dengan keluaran dihitung menggunakan dot product [14].



Gambar 2.3 Ilustrasi Perhitungan Konvolusi
(Sumber: [15])

2.6 Rectified Linear Unit

ReLU atau Rectified Linear Unit merupakan lapisan pada arsitektur CNN yang menerapkan fungsi $f(x) = \max(0, x)$ yang berperan dalam melakukan thresholding pada nilai input piksel citra. Fungsi aktivasi ini bertanggung jawab menormalisasi nilai yang dihasilkan oleh Convolutional Layer, memastikan tidak ada nilai di bawah nol. Nilai ReLU untuk suatu matriks input x ditentukan oleh persamaan $(x) = \max(0, x)$ [16]. ReLU berfungsi untuk mengonversi nilai nol menjadi nol, tapi mempertahankan nilai yang positif. ReLU dapat mempercepat proses pelatihan, sehingga performa model dalam mengklasifikasikan objek menjadi lebih efisien dan akurat [17].




Gambar 2.4 Contoh Grafik ReLU
(Sumber: [18])

2.7 Pooling Layer

Pooling berfungsi dalam mengubah ukuran matrik pada citra menjadi lebih kecil supaya mesin dapat melakukan komputasi dan pelatihan model dengan lebih cepat. Pooling memiliki lebih dari satu jenis, namun yang lebih

sering diterapkan pada model klasifikasi objek adalah max pooling dan average pooling. Max pooling menyederhanakan ukuran matriks dengan cara memilih nilai yang paling besar dalam sebuah matrik, sedangkan average pooling akan memilih nilai rata-rata dalam sebuah matrik [19].



Gambar 2.5 Proses Pada Pooling Layer
(Sumber: [19])

2.8 Softmax Classifier

Softmax Classifier adalah lapisan terakhir dalam model CNN yang berfungsi untuk melakukan klasifikasi multi-kelas. Lapisan ini akan menghasilkan output berupa nilai probabilitas atau peluang untuk setiap kelas, dimana nilai probabilitas tertinggi merupakan kelas prediksi akhir. Tujuannya adalah untuk memprediksi kelas output dalam bentuk peluang yang telah dinormalisasi, sehingga output lebih intuitif dan memiliki interpretasi probabilistik yang jelas. Dengan demikian, hasil akhir klasifikasi dapat ditentukan berdasarkan kelas dengan nilai peluang tertinggi. Hasil yang diberikan dengan menggunakan softmax lebih mudah dipahami dengan interpretasi peluang yang lebih baik. [2].

3. METODE PENELITIAN

3.1 Pengumpulan dan Persiapan Data

Pada tahapan ini, penulis mengumpulkan dataset dari situs Github yang digunakan untuk melatih dan menguji model sistem dalam mengklasifikasikan ras kucing. Dataset yang dikumpulkan pada penelitian ini berupa gambar digital dari 12 ras kucing. Jumlah dataset yang digunakan sebanyak 2.387 gambar dengan format jpg. Gambar awalnya dilabeli dengan cara menempatkan gambar dari setiap ras kucing ke folder yang berbeda. Lalu pada kode, kelas ras kucing diurutkan secara manual untuk memastikan konsistensi dan reproduibilitas eksperimen.

Dataset dibagi ke dalam dua jenis, yaitu dataset untuk pelatihan dan pengujian. Dataset yang digunakan untuk data latih sebanyak 80% sedangkan untuk data uji digunakan sebanyak 20%.

3.2 Pra-Pemrosesan Data

Gambar diolah terlebih dahulu sebelum dijadikan sebagai masukan untuk pelatihan model CNN. Ukuran pada setiap dataset diubah menjadi 160×160 piksel untuk mengurangi beban komputasi dan menyelaraskan masukan bagi model CNN. Nilai piksel dari masing-masing gambar dinormalisasikan ke rentang 0 hingga 1 dari yang sebelumnya adalah 0-255. Normalisasi dilakukan dengan cara membagi setiap piksel dengan angka 255.

Selain pemrosesan citra, label kelas untuk setiap ras kucing juga melalui tahap pra-pemrosesan one-hot encoding. Proses ini mengubah representasi label kategori (misalnya, 'Anggora', 'Persia') menjadi vektor biner, di mana setiap vektor memiliki satu nilai '1' pada posisi indeks ras yang sesuai dan '0' pada posisi lainnya. Misalnya, label 'Anggora' dapat direpresentasikan sebagai $[1, 0, 0, \dots, 0]$ dan 'Persia' sebagai $[0, 1, 0, \dots, 0]$. Hal ini penting karena model Convolutional Neural Network (CNN) memerlukan label dalam format numerik untuk pelatihan dan evaluasi, terutama saat menggunakan fungsi loss seperti categorical crossentropy.

3.3 Arsitektur Model

Pendekatan transfer learning dipilih sebagai arsitektur model pada sistem dengan memanfaatkan MobileNetV2 sebagai model dasar. Strategi fine-tuning diimplementasikan dengan membekukan sebagian besar lapisan awal dari model MobileNetV2 dan hanya melatih 30 lapisan terakhir. Lapisan asli dari MobileNetV2 yang bertugas untuk mengklasifikasi digantikan dengan kepala klasifikasi kustom, yaitu GlobalAveragePooling2D, Dropout, dan Dense (Softmax).

3.4 Pelatihan dan Evaluasi Model

Pada tahap ini, model dikonfigurasi terlebih dahulu dengan menggunakan optimizer Adam dengan learning rate $1e-4$ dan loss function categorical_crossentropy yang cocok untuk fine-tuning. Sebagian kecil data latih

dialokasikan sebagai data validasi guna mengendalikan proses pelatihan. Kemudian, model dilatih menggunakan data latih dan data validasi selama maksimal 20 epoch. Selain itu, mekanisme EarlyStopping diimplementasikan untuk memantau performa pada data validasi. Jadi, saat performa model tidak menunjukkan peningkatan setelah beberapa epoch, pelatihan akan berhenti, lalu model akan mengembalikan bobot dari epoch dengan performa terbaik.

Evaluasi model dilakukan dengan mengukur performa final model menggunakan data uji yang disisihkan pada tahap persiapan data. Hasilnya akan menampilkan nilai akurasi dan loss.


3.5 Pengujian Prediksi

Pengujian prediksi dilakukan dengan membuat fungsi yang mampu menerima gambar baru sebagai masukan, menerapkan seluruh langkah pra-pemrosesan, dan melakukan prediksi. Gambar dimasukkan ke dalam model CNN yang menghasilkan nilai probabilitas untuk setiap kelas klasifikasi. Terakhir, sistem menentukan prediksinya dengan cara mengidentifikasi kelas dengan nilai probabilitas tertinggi. Hasil prediksi berupa gambar asli yang diberi judul nama ras kucing yang diprediksi serta tingkat confidence dari prediksi tersebut.


4. HASIL DAN PEMBAHASAN

4.1 Hasil Pelatihan dan Evaluasi Model

Proses pelatihan berjalan selama 20 epoch penuh. Visualisasi dari metrik akurasi dan loss disajikan pada Gambar 4.1 dan Gambar 4.2.



Gambar 4.1 Hasil Akurasi dari Proses Pelatihan



Gambar 4.2 Hasil Loss dari Proses Pelatihan

Berdasarkan Gambar 4.1, kurva akurasi pelatihan menunjukkan peningkatan drastis hingga mencapai 100%, sedangkan kurva akurasi validasi menunjukkan peningkatan yang konsisten dan stabil hingga mencapai 84,29%. Pada Gambar 4.2, kurva loss pelatihan menurun secara drastis hingga mencapai angka nol, sedangkan kurva loss validasi menurun secara lebih lambat dan stabil di sekitar nilai 0,47.

Setelah pelatihan, evaluasi akhir dilakukan dengan menggunakan data uji dan menunjukkan akurasi sebesar 84,52%. Rangkuman metrik performa model disajikan pada Tabel 4.1.

Tabel 4.1 Hasil Performa Model

Kelas	Precision	Recall	F1-score	Support
Sphynx	0,94	1,00	0,97	34
Birman	0,74	0,77	0,75	30
Egyptian Mau	0,85	1,00	0,92	35
Ragdoll	0,62	0,81	0,70	47
Abyssinian	0,90	0,78	0,84	36
Siamese	0,96	0,92	0,94	51
Maine Coon	0,96	0,67	0,79	33
Bengal	0,94	0,77	0,85	39
British Shorthair	0,80	0,85	0,82	47
Bombay	0,95	0,97	0,96	37
Russian Blue	0,72	0,74	0,73	38
Persian	0,91	0,84	0,88	51
Akurasi	84,52%			478

4.2. Pembahasan

Jika dilihat dari hasil akurasi pelatihan (100%) dan validasi (84,29%), model terindikasi mengalami overfitting. Meski

begitu, akurasi yang didapatkan pada data uji sebesar 84,52%. Model menunjukkan performa yang sangat unggul dalam mengidentifikasi beberapa ras dengan ciri khas yang kuat, seperti Sphynx (F1-score 0.97), Bombay (F1-score 0.96), dan Siamese (F1-score 0.94). Di sisi lain, model menunjukkan tantangan lebih besar dalam membedakan ras Ragdoll (F1-score 0.70) dan Russian Blue (F1-score 0.73). Performa yang lebih rendah pada kelas-kelas ini mengindikasikan adanya kemiripan visual yang signifikan dengan ras lain di dalam dataset, yang menjadi area potensial untuk perbaikan pada penelitian selanjutnya.

Performa model pada penelitian ini dievaluasi dengan membandingkannya terhadap penelitian sebelumnya yang menggunakan metode berbeda. Tingkat akurasi sebesar 84.52% berhasil melampaui penelitian Ramadhayani dan Lusiana yang menggunakan metode K-Nearest Neighbor (KNN) dengan akurasi 80% pada 3 kelas kucing. Hasil ini juga sangat kompetitif jika dibandingkan dengan penelitian Hadi, et al. yang mencapai akurasi 86% menggunakan Support Vector Machine (SVM) pada 5 kelas kucing. Pencapaian ini terbilang signifikan mengingat penelitian ini menangani tantangan klasifikasi dengan jumlah kelas yang lebih banyak (12 ras), yang menunjukkan kekuatan dan kemampuan generalisasi dari model CNN yang dikembangkan [3], [4].

Untuk memahami performa model, dilakukan perbandingan dengan penelitian berbasis CNN pada domain lain. Hasil akurasi sebesar 84.52% pada penelitian ini kompetitif dengan penelitian klasifikasi kualitas biji kopi oleh Pratama, et al. yang mencapai 86%. Meskipun hasil ini masih di bawah akurasi 98.44% yang diperoleh Karim dan Herlangga pada klasifikasi senjata tradisional, perlu diperhatikan bahwa tantangan dalam mengklasifikasikan 12 ras kucing memiliki kompleksitas yang berbeda. Variasi visual yang tinggi dan kemiripan antar-kelas pada ras kucing dapat menjadi faktor yang membuat tugas klasifikasi lebih sulit dibandingkan objek dengan ciri yang lebih tegas seperti senjata tradisional [5], [6].

4.3. Hasil Pengujian Prediksi

Untuk melengkapi evaluasi kuantitatif dan mendemonstrasikan performa model pada

kasus-kasus individual, dilakukan tahap pengujian kualitatif. Pengujian ini bertujuan untuk melihat bagaimana sistem memberikan output prediksi saat dihadapkan pada gambar tunggal yang belum pernah dilihat sebelumnya. Untuk tujuan ini, sebuah fungsi prediksi dirancang untuk menerima gambar masukan, melakukan pra-pemrosesan yang diperlukan, dan menghasilkan label prediksi beserta nilai keyakinan (confidence score).

Dua gambar sampel dari ras yang berbeda, yaitu Persia dan Bengal, digunakan sebagai studi kasus. Seperti yang divisualisasikan pada Gambar 4.3, model mampu mengidentifikasi gambar kucing Persia dengan prediksi yang benar dan tingkat keyakinan maksimal, yaitu sebesar 100%. Performa serupa juga ditunjukkan pada Gambar 4.4, di mana gambar kucing Bengal berhasil diklasifikasikan dengan benar, disertai tingkat keyakinan yang sangat tinggi, yaitu sebesar 95%.



Gambar 4.3 Hasil Prediksi Gambar Masukan Pertama



Gambar 4.4 Hasil Prediksi Gambar Masukan Kedua

Tingkat keyakinan yang tinggi pada kedua prediksi yang benar ini mengindikasikan bahwa

model tidak hanya akurat, tetapi juga memiliki 'kepastian' yang kuat dalam membuat keputusan klasifikasi, terutama untuk contoh-contoh dengan ciri visual yang jelas. Pengujian kualitatif ini secara efektif memvalidasi penerapan praktis dari model yang telah dikembangkan.

5. KESIMPULAN

- Penelitian ini berhasil membangun dan menerapkan model klasifikasi ras kucing menggunakan algoritma Convolutional Neural Network (CNN) dengan metode transfer learning yang mencapai akurasi akhir sebesar 84.52% pada data uji.
- Model menunjukkan kelebihan dalam mengidentifikasi ras dengan ciri visual yang sangat khas seperti Sphynx (F1-score 0.97) dan Bombay (F1-score 0.96). Performa model juga terbukti kompetitif dan mampu melampaui beberapa metode klasifikasi konvensional dari penelitian sebelumnya.
- Kekurangan yang teridentifikasi adalah adanya indikasi overfitting selama proses pelatihan dan performa model yang lebih rendah pada kelas-kelas dengan kemiripan visual yang tinggi, seperti Ragdoll (F1-score 0.70) dan Russian Blue (F1-score 0.73).
- Pengembangan selanjutnya dapat difokuskan pada penerapan teknik augmentasi data yang lebih beragam dan metode regularisasi tambahan untuk mengurangi overfitting, serta memperkaya dataset pada kelas-kelas yang sulit dibedakan untuk meningkatkan kemampuan generalisasi model.

UCAPAN TERIMA KASIH

Ucapan syukur, penulis panjatkan kepada Tuhan Yang Maha Esa atas limpahan rahmat dan karunia-Nya, sehingga penulis bisa menyelesaikan jurnal ini. Tidak lupa, penulis ucapkan banyak terima kasih kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini.

DAFTAR PUSTAKA

- [1] K. D. Linda, Kusriani, and A. D. Hartanto, "Studi Literatur Mengenai Klasifikasi Citra Kucing Dengan Menggunakan Deep Learning: Convolutional Neural Network

- (CNN),” *J. Electr. Eng. Comput.*, vol. 6, no. 1, pp. 129–137, 2024, doi: 10.33650/jeecom.v6i1.7480.
- [2] R. Gunawan, D. M. I. Hanafie, and A. Elanda, “Klasifikasi Jenis Ras Kucing Dengan Gambar Menggunakan Convolutional Neural Network (CNN),” *J. Interkom J. Publ. Ilm. Bid. Teknol. Inf. dan Komun.*, vol. 18, no. 4, pp. 1–8, 2024, doi: 10.35969/interkom.v18i4.318.
- [3] A. N. Ramadhayani and V. Lusiana, “Klasifikasi Jenis Kucing Menggunakan Algoritma Principal Component Analysis dan K-Nearest Neighbor,” *J. Inf. dan Komput.*, vol. 10, no. 2, pp. 257–263, 2022, doi: 10.35959/jik.v10i2.333.
- [4] P. D. Hadi, D. A. Widhining K, and F. A. Fiolana, “Identifikasi Jenis Ras Pada Kucing Menggunakan Algoritma Support Vector Machine (SVM),” *JASIEK (Jurnal Apl. Sains, Informasi, Elektron. dan Komputer)*, vol. 6, no. 1, pp. 77–86, 2024, doi: 10.26905/jasiek.v6i1.10989.
- [5] R. R. Karim and A. Herlangga, “Implementasi Klasifikasi Senjata Tradisional Jawa Barat Menggunakan Convolutional Neural Network (Cnn) Dengan Metode Transfer Learning,” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 2, pp. 1210–1216, 2024, doi: 10.23960/jitet.v12i2.4166.
- [6] G. A. Pratama, E. Y. Puspaningrum, and H. Maulana, “Convolutional Neural Network Dan Faster Region Convolutional Neural Network Untuk Klasifikasi Kualitas Biji Kopi Arabika,” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, pp. 2776–2785, 2024, doi: 10.23960/jitet.v12i3.4887.
- [7] A. Herlangga, R. R. Karim, and M. K. Nurwijaya, “Penerapan Transfer Learning Efficientnetb3 Untuk Pengenalan Senjata Tradisional Sumatera Barat Menggunakan Convolutional Neural Network (Cnn),” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 2, pp. 1416–1423, 2024, doi: 10.23960/jitet.v12i2.4256.
- [8] R. Aryanto, M. A. Rosid, and S. Busono, “Penerapan Deep Learning untuk Pengenalan Tulisan Tangan Bahasa Akasara Lota Ende dengan Menggunakan Metode Convolutional Neural Networks,” *J. Inf. dan Teknol.*, vol. 5, no. 1, pp. 258–264, 2023, doi: 10.37034/jidt.v5i1.313.
- [9] I. B. A. Peling, I. M. P. A. Ariawan, and G. B. Subiksa, “Deteksi Bahasa Isyarat Menggunakan Tensorflow Lite dan American Sign Language (ASL),” *J. Krisnadana*, vol. 3, no. 2, pp. 90–100, 2024, doi: 10.58982/krisnadana.v3i2.534.
- [10] TensorFlow, “What’s new in TensorFlow 2.19,” TensorFlow Blog. Accessed: Jul. 01, 2025. [Online]. Available: https://blog.tensorflow.org/2025/03/whats-new-in-tensorflow-2-19.html?_gl=1*m3zt84*_ga*MTU3NzE3NzcZLjE3NTEzNjE1OTc.*_ga_W0YLR4190T*cZlE3NTEzNjE1OTYkbzEkZzAkdDE3NTEzNjE1OTYkajYwJGwwJGgw
- [11] A. Akram, S. A. Rachmadinasya, F. H. Melvandino, and H. Ramza, “Klasifikasi Aktivitas Olahraga Berdasarkan Citra Foto Dengan Menggunakan Metode Convolutional Neural Network,” *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 3, pp. 1081–1086, 2023, doi: 10.23960/jitet.v11i3s1.3496.
- [12] P. Raghav, “No Title Understanding of Convolutional Neural Network (CNN) — Deep Learning,” Medium. Accessed: Jul. 01, 2025. [Online]. Available: <https://medium.com/@RaghavPrabhu/understanding-of-convolutional-neural-network-cnn-deep-learning-99760835f148>
- [13] E. D. Sefrila, B. Rahmat, and A. N. Sihananto, “Implementasi Arsitektur Inception V3 Dengan Optimasi Adam, SGD dan RMSP Pada Klasifikasi Penyakit Malaria,” *Bridg. J. Publ. Sist. Inf. dan Telekomun.*, vol. 2, no. 2, pp. 69–84, 2024, doi: 10.62951/bridge.v2i2.62.
- [14] F. Ramadhani, A. Satria, and Salamah, “Implementasi Algoritma Convolutional Neural Network dalam Mengidentifikasi Dini Penyakit pada Mata Katarak,” *sudo J. Tek. Inform.*, vol. 2, no. 4, pp. 167–175, 2023, doi: 10.56211/sudo.v2i4.408.
- [15] D. L. Z. Astuti, Samsuryadi, and D. P. Rini, “Real-Time Classification of Facial Expressions Using A Principal Component Analysis and Convolutional Neural Network,” *SINERGI*, vol. 23, no. 3, pp. 239–244, 2019, [Online]. Available: https://www.researchgate.net/publication/336895977_REAL-TIME_CLASSIFICATION_OF_FACIAL_EXPRESSIONS_USING_A_PRINCIPAL_COMPONENT_ANALYSIS_AND_CONVOLUTIONAL_NEURAL_NETWORK
- [16] Sriani, Armansyah, and A. Nabila, “Implementasi Deep Learning Untuk Mengidentifikasi Umur Manusia Menggunakan Convolutional Neural Network (CNN),” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, pp. 1836–1843, 2024, doi: 10.23960/jitet.v12i3.4457.
- [17] A. R. Dani and I. Handayani, “Klasifikasi Motif Batik Yogyakarta Menggunakan

- Metode GLCM dan CNN,” *J. Teknol. Terpadu*, vol. 10, no. 2, pp. 142–156, 2024, doi: 10.54914/jtt.v10i2.1451.
- [18] P. Chima, “Activation Functions: ReLU & Softmax,” Medium. Accessed: Jul. 01, 2025. [Online]. Available: <https://medium.com/@preshchima/activation-functions-relu-softmax-87145bf39288>
- [19] I. Bakti and M. Firdaus, “Classification of Image Files of Lung X-Ray Results with Architecture Convolution Neural Network (CNN),” *J. Inf. Technol.*, vol. 3, no. 1, pp. 26–34, 2023, doi: 10.46229/jifotech.v3i1.590.