

Perbandingan Kinerja Algoritma Random Forest dan Convolutional Neural Network (CNN) untuk Klasifikasi Citra Kucing

Hilaria Iwung ^{1,*}, Ben Rahman ²

Informatika, Fakultas Teknologi Komunikasi dan Informatika, Universitas Nasional, Indonesia.

¹hildahilaria8@gmail.com, ²benrahman@unas.ac.id

Info Artikel

Riwayat Artikel:

Received 2026-01-11

Revised 2026-01-26

Accepted 2026-02-06

Corresponding Author:

Hilaria Iwung

Email: hildahilaria8@gmail.com



This is an open access article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/) license.

Abstract – Cat breed classification presents a significant challenge in the field of Computer Vision due to high visual similarity between breeds (fine-grained classification) and pattern variations within a single breed. This study aims to compare the performance of two different machine learning approaches: Random Forest (RF) based on manual feature extraction and Convolutional Neural Network (CNN) based on automatic feature learning. The research focuses on three specific cat breeds: Bombay, Siamese, and Persian. The methodology utilizes a public dataset from Kaggle, partitioned into a ratio of 80:10:10. The RF pipeline applies manual feature extraction through a combination of Histogram of Oriented Gradients (HOG) and Color Histogram. Conversely, the CNN pipeline employs Transfer Learning techniques using the ResNet50V2 architecture. Experimental results demonstrate that CNN significantly outperforms RF, achieving an accuracy of 93.33%, whereas RF only reaches 68.33%. The analysis indicates that manual features in RF struggle to capture complex texture details in the Persian breed, while CNN demonstrates superior generalization capabilities. It is concluded that the Deep Learning (CNN) approach is substantially more effective than traditional methods for animal breed classification.

Keywords: Convolutional Neural Network, Fine-Grained Classification, Image Classification, Random Forest, ResNet50V2

Abstrak – Klasifikasi ras kucing merupakan tantangan signifikan dalam bidang Computer Vision akibat tingginya kemiripan visual antar-ras (fine-grained classification) dan variasi pola di dalam satu ras. Penelitian ini bertujuan untuk membandingkan kinerja dua pendekatan pembelajaran mesin yang berbeda, yaitu Random Forest (RF) berbasis fitur manual dan Convolutional Neural Network (CNN) berbasis fitur otomatis. Fokus penelitian adalah pada tiga ras kucing: Bombay, Siamese, dan Persian. Metodologi penelitian menggunakan dataset publik dari Kaggle yang dibagi dengan proporsi 80:10:10. Jalur RF menerapkan ekstraksi fitur manual melalui gabungan Histogram of Oriented Gradients (HOG) dan Color Histogram. Sebaliknya, jalur CNN menggunakan teknik Transfer Learning dengan arsitektur ResNet50V2. Hasil pengujian menunjukkan bahwa CNN secara signifikan mengungguli RF dengan akurasi mencapai 93,33%, sedangkan RF hanya mencapai 68,33%. Analisis memperlihatkan fitur manual pada RF kesulitan menangkap detail tekstur kompleks pada ras Persian, sementara CNN mampu melakukan generalisasi dengan baik. Disimpulkan bahwa pendekatan Deep Learning (CNN) jauh lebih efektif dibandingkan metode tradisional untuk klasifikasi ras hewan.

Kata Kunci: Convolutional Neural Network, Klasifikasi Citra, Klasifikasi Fine-Grained, Random Forest, ResNet50V2.

I. PENDAHULUAN

Kucing (*Felis catus*) merupakan salah satu hewan yang paling banyak dipelihara dan digemari di seluruh dunia. Daya tarik utamanya terletak pada penampilan fisik dan jenisnya yang sangat beragam. Namun, justru keragaman inilah yang seringkali membuat identifikasi ras kucing menjadi tugas yang tidak mudah. Dari keseluruhan populasi kucing, diperkirakan hanya sekitar 1% yang tergolong sebagai ras murni, sementara sisanya didominasi oleh kucing domestik atau hasil persilangan yang karakteristik fisiknya tidak spesifik [1]. Adanya kesulitan dalam mengidentifikasi ras, ditambah dengan kemiripan antar beberapa ras, mendorong perlunya pengembangan sebuah sistem yang dapat mengenali dan mengklasifikasikan citra kucing secara otomatis dan akurat. Di sinilah kemajuan teknologi kecerdasan buatan, khususnya pada bidang pengenalan citra, dapat memberikan solusi yang efektif.

Kemajuan teknologi di bidang kecerdasan buatan telah membawa perubahan besar dalam teknologi pengenalan citra. Berbagai metode yang dibangun di atas prinsip *machine learning* kini mampu mengenali dan mengelompokkan objek dari sebuah gambar digital dengan tingkat presisi yang tinggi. Penerapannya pun sangat luas, mulai dari analisis citra satelit untuk pemetaan tutupan lahan [2], [3], hingga membantu proses diagnosis penyakit melalui citra medis [4]. Kemampuan algoritma *machine learning* untuk mempelajari pola-pola kompleks dari data visual menjadikannya alat yang sangat potensial untuk diaplikasikan pada tugas klasifikasi citra kucing, yang menuntut ketelitian terhadap detail dan pola visual yang halus.

Salah satu metode *deep learning* yang telah menunjukkan keberhasilan luar biasa dalam bidang pengenalan citra adalah *Convolutional Neural Network* (CNN). CNN adalah arsitektur jaringan saraf tiruan yang dirancang secara khusus untuk memproses data berbentuk *grid* seperti gambar. Cara kerjanya terinspirasi dari korteks visual manusia, di mana arsitektur ini mampu secara otomatis mempelajari dan mengekstrak fitur dari sebuah citra secara bertingkat, mulai dari fitur dasar seperti garis dan sudut, hingga fitur yang lebih kompleks seperti tekstur dan bentuk objek [5]. Keampuhan CNN telah terbukti dalam banyak penelitian, salah satunya oleh [1] yang berhasil mencapai akurasi sebesar 95% dalam mengklasifikasikan sembilan ras kucing berbeda menggunakan arsitektur CNN.

Di sisi lain, terdapat pula metode *ensemble learning* yang tidak kalah populer dan tangguh, yaitu *Random Forest* (RF). Algoritma ini bekerja dengan cara membangun banyak pohon keputusan (*decision trees*) secara acak selama proses pelatihan, lalu menentukan kelas akhir dari suatu data berdasarkan suara mayoritas dari seluruh pohon yang ada [6]. RF memiliki beberapa keunggulan yang membuatnya banyak digunakan, di antaranya adalah proses pelatihan yang relatif cepat, akurasi klasifikasi yang tinggi, dan kemampuannya untuk menangani data berdimensi tinggi tanpa mudah mengalami *overfitting* [2]. Berkat keunggulan-keunggulan ini, RF telah menjadi salah satu algoritma andalan dalam berbagai macam tugas klasifikasi [3].

Perbedaan paling mendasar antara CNN dan RF terletak pada cara keduanya mengolah fitur. CNN memiliki kemampuan untuk melakukan ekstraksi fitur secara otomatis langsung dari data piksel mentah (*representation learning*). Sebaliknya, RF umumnya bekerja menggunakan fitur-fitur yang telah ditentukan dan diekstraksi terlebih dahulu (*hand-engineered features*) [7]. CNN memang menawarkan otomatisasi penuh dalam menemukan pola, namun proses pelatihannya seringkali membutuhkan waktu yang sangat lama dan dataset dalam jumlah besar [8]. RF, di sisi lain, jauh lebih cepat dan efisien secara komputasi, namun performanya sangat bergantung pada kualitas fitur yang kita berikan sebagai input [3].

Melihat adanya kelebihan dan kekurangan pada masing-masing algoritma, beberapa penelitian terbaru mulai mencoba menggabungkan keduanya ke dalam sebuah model hibrida. Idennya adalah memanfaatkan keunggulan CNN sebagai pengekstraksi fitur otomatis, lalu menyerahkan tugas klasifikasi akhir kepada RF yang dikenal robust dan efisien [6]. Fitur-fitur representasi tingkat tinggi yang dihasilkan oleh lapisan konvolusi pada CNN dijadikan sebagai input untuk dilatih oleh RF [2], [6]. Pendekatan ini terbukti berhasil meningkatkan performa klasifikasi secara signifikan dalam berbagai studi, seperti pada klasifikasi citra medis, citra serat hewan, dan citra penginderaan jauh beresolusi tinggi [4].

Meskipun penelitian sebelumnya telah membuktikan bahwa CNN dapat digunakan secara efektif untuk klasifikasi ras kucing, dan perbandingan antara RF dengan CNN juga telah banyak dilakukan pada domain lain seperti penginderaan jauh [3], namun perbandingan performa yang berfokus secara spesifik pada klasifikasi citra kucing masih sangat terbatas. Setiap domain klasifikasi memiliki tantangannya sendiri. Klasifikasi ras kucing tergolong sebagai masalah *fine-grained classification*, di mana perbedaan visual antar kelas (ras) bisa sangat tipis sehingga diperlukan metode yang mampu menangkap fitur detail tersebut [9]. Oleh karena itu, hasil perbandingan dari domain lain tidak serta-merta dapat diaplikasikan pada kasus ini, sehingga diperlukan sebuah analisis khusus.

Berdasarkan uraian latar belakang tersebut, teridentifikasi adanya celah penelitian (*research gap*) di mana studi komparasi langsung (*head-to-head*) antara pendekatan *feature engineering* manual (Random Forest) dan *feature learning* otomatis (CNN) secara spesifik pada kasus klasifikasi *fine-grained* ras kucing masih terbatas. Studi sebelumnya lebih banyak berfokus pada satu metode tunggal atau diterapkan pada domain yang berbeda. Oleh karena itu, penelitian ini merumuskan masalah secara eksplisit sebagai berikut: (1) Seberapa signifikan perbedaan kinerja akurasi, presisi, dan *recall* antara algoritma Random Forest dan CNN pada dataset yang sama? (2) Bagaimana karakteristik keunggulan dan kelemahan masing-masing algoritma dalam menangani kemiripan visual yang tinggi antar-ras kucing?


Mengacu pada rumusan masalah di atas, penelitian ini bertujuan untuk membandingkan secara komprehensif kinerja algoritma Random Forest dan CNN. Kedua algoritma akan dilatih dan diuji menggunakan dataset citra kucing yang sama, kemudian diukur menggunakan metrik evaluasi standar. Penelitian ini menawarkan kebaruan berupa studi komparatif empiris yang secara spesifik menginvestigasi efektivitas pendekatan *feature learning* (CNN) dibandingkan *feature engineering* (RF) pada domain citra hewan dengan kemiripan visual tinggi (*fine-grained*). Kontribusi utamanya terletak pada evaluasi mendalam mengenai trade-off antara akurasi dan biaya komputasi, serta analisis forensik terhadap kegagalan fitur manual dalam menangkap variasi intra-class ras kucing, yang belum dibahas secara komprehensif dalam penelitian sejenis.

II. METODE

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan membandingkan dua jalur pemrosesan citra yang berbeda: jalur Machine Learning Tradisional (RF) dan jalur Deep Learning (CNN). Tahapan penelitian meliputi pengumpulan data, *Preprocessing*, ekstraksi fitur, pelatihan model, dan evaluasi.

Secara rinci, alur penelitian diawali dengan akuisisi dataset citra kucing yang kemudian melalui tahap *preprocessing* untuk standarisasi dimensi dan normalisasi. Selanjutnya, proses eksperimen dibagi menjadi dua

skenario utama: (1) Ekstraksi fitur manual menggunakan HOG dan *Color Histogram* untuk algoritma Random Forest, dan (2) Pembelajaran fitur otomatis (*feature learning*) menggunakan arsitektur CNN ResNet50V2. Tahapan lengkap desain sistem penelitian diilustrasikan pada Gambar 1.



Gambar 1. Flowchart Desain Sistem

Berdasarkan Gambar 1, alur penelitian dimulai dengan pengumpulan dataset yang kemudian dibagi (*split*) menjadi data latih, validasi, dan uji. Tahap selanjutnya adalah *preprocessing* yang dibedakan berdasarkan algoritma; jalur RF melakukan *resize* ke 128x128 piksel dan *flattening*, sedangkan jalur CNN melakukan *resize* ke 224x224 piksel, normalisasi, dan augmentasi data. Proses dilanjutkan dengan ekstraksi fitur manual (HOG dan Color Histogram) untuk RF, dan ekstraksi fitur otomatis (*feature learning*) untuk CNN. Kedua model kemudian dilatih dan

diuji menggunakan data yang sama (*testing set*). Tahap akhir meliputi evaluasi kinerja menggunakan matriks konfusi serta analisis komparatif sebelum penarikan kesimpulan.

A. Hasil Pengumpulan Dan Pesiapan Data

Data penelitian ini bersumber dari dataset publik kaggle “*Cat Breeds Dataset*”. Sebanyak 3.000 citra dipilih dan didistribusikan secara merata ke dalam 3 kelas: Bombay, Siamese, dan Persian (1.000 citra per kelas). Dataset dibagi menggunakan teknik *stratified sampling* dengan rasio 80% *Training*, 10% *Validation*, dan 10% *Testing*.

B. Preprocessing Data

Terdapat dua alur *preprocessing* yang berbeda sesuai kebutuhan algoritma:

1. Jalur Random Forest: Citra diubah ukurannya (*resize*) menjadi 128x128 piksel untuk efisiensi komputasi, mengingat keterbatasan memori saat memproses vektor fitur manual yang besar.
2. Jalur CNN: Citra di-*resize* menjadi 224x224 piksel sesuai input standar ResNet, diikuti dengan normalisasi nilai piksel ke rentang [0,1]. Augmentasi data (*rotasi*, *zoom*, *flip*) diterapkan pada data latih CNN untuk mencegah *overfitting*.

C. Arsitektur Model Random Forest

Random Forest (RF) adalah metode ensemble learning yang kuat untuk klasifikasi dan regresi, bekerja dengan membangun banyak pohon keputusan (*decision trees*) [4], [10], [11]. Model RF dibangun menggunakan pendekatan fitur manual. Ekstraksi fitur dilakukan dengan menggabungkan dua metode:

1. *Histogram of Oriented Gradients* (HOG): Digunakan untuk menangkap fitur bentuk dan tekstur (orientasi tepi). Parameter yang digunakan adalah 9 orientasi, 16x16 piksel.
2. *Color Histogram*: Digunakan untuk menangkap distribusi warna (RGB), yang krusial untuk membedakan ras Bombay dan Siamese.

Vektor fitur gabungan dari kedua metode tersebut kemudian dilatih menggunakan algoritma RF dengan 100 *decision trees* ($n_estimators=100$). Kriteria pemisahan (*splitting criteria*) pada setiap *decision tree* menggunakan Gini Impurity untuk mengukur ketidakmurnian kelas dalam sebuah *node*. Rumus Gini Impurity didefinisikan pada Persamaan (1):

$$Gini = 1 - \sum_{i=1}^C (P_i)^2 \quad (1)$$

Di mana C adalah jumlah kelas total dan P_i adalah probabilitas sampel yang diklasifikasikan ke dalam kelas i pada *node* tersebut.

D. Arsitektur Model CNN (ResNet50V2)

Convolutional Neural Network (CNN) adalah jenis arsitektur deep learning yang sangat efektif untuk tugas pengolahan data berbentuk grid, terutama citra [1], [5], [10]. CNN meniru cara kerja sistem visual manusia [1], [12] dan mampu secara otomatis mempelajari fitur-fitur relevan dari data input secara hierarkis [2]. Model CNN menggunakan teknik *Transfer Learning* dengan arsitektur ResNet50V2 yang telah dilatih pada ImageNet. *Base layers* digunakan sebagai pengekstraksi fitur otomatis. Operasi dasar CNN untuk ekstraksi fitur (konvolusi) didefinisikan sebagai berikut pada rumus 2:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i - m, j - n) K(m, n) \quad (2)$$

Selanjutnya, untuk memperkenalkan non-linearitas ke dalam jaringan, digunakan fungsi aktivasi *Rectified Linear Unit* (ReLU) pada setiap output lapisan konvolusi, sebagaimana ditunjukkan pada Persamaan (3):

$$ReLU(x) = \max(0, x) \quad (3)$$

Di mana x adalah nilai input neuron. Fungsi ini akan mengubah nilai negatif menjadi nol dan mempertahankan nilai positif.

E. Evaluasi

Kinerja algoritma Random Forest dan CNN dievaluasi secara komparatif untuk menentukan model yang paling optimal dalam menangani tantangan klasifikasi *fine-grained* ras kucing. Proses evaluasi dilakukan menggunakan dataset uji (*testing set*) yang sama dan belum pernah dilihat oleh model selama proses pelatihan (*unseen data*), guna menjamin objektivitas dan validitas hasil pengujian.

Parameter utama yang digunakan sebagai tolak ukur meliputi Akurasi, Presisi, *Recall*, *F1-Score*, serta efisiensi komputasi. Metrik Akurasi Global dihitung berdasarkan rasio prediksi benar terhadap total data uji, sebagaimana didefinisikan pada Persamaan (4):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

Di mana *TP* adalah *True Positive*, *TN* adalah *True Negative*, *FP* adalah *False Positive*, dan *FN* adalah *False Negative*.

F. Lingkungan Implementasi

Penelitian ini diimplementasikan menggunakan platform *cloud* Google Colab dengan bahasa pemrograman Python 3.10. Pustaka utama yang digunakan meliputi TensorFlow dan Keras untuk pembangunan model CNN, serta Scikit-Learn untuk algoritma *Random Forest*. Untuk mendukung komputasi, lingkungan eksperimen ini didukung oleh spesifikasi perangkat keras berupa GPU NVIDIA Tesla T4 (16GB VRAM) dan RAM sistem sebesar 12 GB, yang digunakan untuk mempercepat proses pelatihan dan pengujian model.

III. HASIL DAN PEMBAHASAN

A. Hasil Persiapan Dataset dan Visualisasi Data


Penelitian ini mengimplementasikan dua pendekatan berbeda untuk klasifikasi citra ras kucing. Dataset yang digunakan terdiri dari 3.000 citra yang terbagi rata ke dalam 3 kelas ras kucing: Bombay, Siamese, dan Persien. Pembagian dataset mengikuti rasio 80:10:10 untuk data latih, validasi, dan uji seperti pada Tabel 1.

TABEL 1
PERBAGIAN DATASET


Subset	Jumlah Citra	Persentase
Training	2.400	80%
Validation	300	10%
Testing	300	10%

Visualisasi representatif dari setiap kelas disajikan pada tabel 2 untuk memperlihatkan variasi karakteristik visual antar-kelas.

TABEL 2
SAMPel CITRA DATASET

a)	Ras Bombay		Keterangan: Ras Bombay memiliki ciri khas bulu hitam solid (mengkilap) dan mata berwarna tembaga atau emas. Fitur warna menjadi penanda utama ras ini.
b)	Ras Siamese		Keterangan: Ras Siamese memiliki pola warna color-point yang khas, di mana telinga, wajah, kaki, dan ekor berwarna lebih gelap dibandingkan tubuhnya yang terang.

c) Ras Persian




Keterangan: Ras Persian diidentifikasi dari bulu panjang (long-hair) yang lebat dan struktur wajah yang datar (brachycephalic) atau pesek.

B. Hasil Pengujian Algoritma

1. Kinerja Random Forest (RF)

Pengujian model *Random Forest* yang berbasis fitur manual (HOG dan *Color Histogram*) pada 300 data uji menunjukkan hasil yang kurang optimal. Berdasarkan *Confusion Matrix* pada Gambar 2, terlihat terjadi kesalahan klasifikasi yang signifikan, terutama pada kelas Persian yang sering diprediksi sebagai Siamese.



Gambar 2. Confusion Matrix Random Forest


Laporan klasifikasi detail untuk RF di sajikan pada gambar 3. Rata-rata akurasi yang diperoleh hanya mencapai 68,33%. Nilai *F1-Score* terendah terdapat pada kelas Persian (0.56), yang mengindikasikan bahwa kombinasi fitur manual kesulitan dalam mendiskriminasi fitur unik ras tersebut.

	precision	recall	f1-score	support
Bombay	0.73	0.88	0.80	100
Persian	0.68	0.48	0.56	100
Siamese	0.64	0.69	0.66	100
accuracy			0.68	300
macro avg	0.68	0.68	0.67	300
weighted avg	0.68	0.68	0.67	300

Gambar 3. Laporan Klasifikasi Random Forest


2. Kinerja Convolutional Neural Network (CNN)

Sebaliknya, model CNN dengan arsitektur ResNet50V2 menunjukkan performa yang sangat stabil. Grafik pelatihan pada Gambar 4 memperlihatkan proses konvergensi yang baik selama 50 *epoch*, di mana akurasi validasi bergerak seiring dengan akurasi pelatihan, menandakan tidak terjadinya *overfitting*.



Gambar 4. Grafik Akurasi dan Loss Pelatihan CNN (ResNet50V2)

Model CNN menunjukkan performa yang sangat baik pada data uji. *Confusion matrix* pada Gambar 5 menunjukkan bahwa model mampu mengklasifikasikan hampir semua citra dengan benar, dengan kesalahan prediksi yang minimal di semua kelas.



Gambar 5. Confusion Matrix CNN - ResNet50V2

Laporan klasifikasi CNN pada Gambar 6 menunjukkan konsistensi performa yang tinggi di semua metrik evaluasi. F1-score untuk ketiga kelas berada di atas 0.90, dengan performa terbaik pada kelas Bombay (0.96).

	precision	recall	f1-score	support
Bombay	0.96	0.96	0.96	100
Persian	0.91	0.91	0.91	100
Siamese	0.93	0.93	0.93	100
accuracy			0.93	300
macro avg	0.93	0.93	0.93	300
weighted avg	0.93	0.93	0.93	300

Gambar 6. Laporan Klasifikasi CNN (ResNet50V2)

C. Pembahasan


Meskipun hasil eksperimen menunjukkan performa yang menjanjikan, perlu dicatat bahwa penelitian ini memiliki keterbatasan karena menggunakan dataset publik dengan jumlah variasi ras yang terbatas, sehingga belum mencakup representasi visual dari ras kucing lokal secara menyeluruh. Namun, analisis mendalam terhadap hasil klasifikasi memberikan wawasan penting mengenai karakteristik kedua algoritma.

Hasil pengujian kuantitatif menunjukkan perbedaan performa yang signifikan antara kedua metode. Perbandingan langsung antara *Random Forest* (Fitur Manual) dan CNN (ResNet50V2) disajikan secara lengkap pada Tabel 3. Data menunjukkan bahwa CNN unggul dengan selisih akurasi sebesar 25% dibandingkan RF (93.33% vs 68.33%).

TABEL 3
PERBANDINGAN KINERJA RF DAN CNN

Metrik Evaluasi	Random Forest (Fitur Manual)	CNN (ResNet50V2)
Akurasi (Accuracy)	68.33%	93.33%
Rata-rata Presisi	0.68	0.94
Rata-rata Recall	0.68	0.94
Rata-rata F1-Score	0.67	0.94

Untuk mempermudah analisis komparatif, visualisasi kinerja kedua algoritma ditampilkan dalam bentuk grafik batang. Sebagaimana diperlihatkan pada Gambar 7, metode CNN (batang oranye) menunjukkan dominasi kinerja yang konsisten di seluruh metrik evaluasi (Akurasi, Presisi, *Recall*, dan *F1-Score*) dibandingkan Random Forest.



Gambar 7. Grafik Perbandingan RF vs CNN.

Analisis terhadap kegagalan fitur manual pada Random Forest menyoroti kelemahan fundamental metode ini, terutama pada kelas Persian yang hanya mencapai F1-Score 0.56. Keterbatasan ini disebabkan oleh metode *Histogram of Oriented Gradients* (HOG) yang bekerja berdasarkan deteksi gradien tepi tegas. Pada ras Persian yang memiliki bulu panjang dan lebat (*fluffy*), garis tepi tubuh menjadi kabur sehingga HOG gagal membentuk deskriptor bentuk yang akurat. Selain itu, performa RF yang cukup baik pada ras Bombay (F1-Score 0.80) lebih disebabkan oleh dominasi fitur warna (hitam pekat) yang berhasil ditangkap oleh *Color Histogram*. Hal ini mengonfirmasi temuan Sothe et al. [7] bahwa performa *machine learning* konvensional sangat bergantung pada kualitas fitur input dan cenderung lemah pada fitur tekstur kompleks tanpa rekayasa fitur yang canggih.

Sebaliknya, superioritas CNN dengan akurasi 93.33% dapat diatribusikan pada mekanisme *feature learning* hierarkis dan invariansi spasial. Berbeda dengan pendekatan manual, arsitektur CNN memungkinkan model mengekstrak fitur dari level rendah (garis) hingga level tinggi (semantik) secara otomatis [1]. Dalam penelitian ini, ResNet50V2 berhasil menangkap fitur kompleks seperti struktur wajah datar (*brachycephalic*) pada Persian yang gagal dideteksi oleh HOG. Kemampuan CNN dalam mengidentifikasi karakteristik visual ini sejalan dengan

penelitian Putra et al. [13] yang menekankan pentingnya pengenalan pola citra yang unik dalam identifikasi jenis kucing. Efektivitas CNN dalam menangani variasi morfologi pada objek biologis juga telah dibuktikan dalam penelitian lain, seperti pada klasifikasi genus jamur yang menghasilkan akurasi signifikan [14]. Selain itu, mekanisme *pooling* dan augmentasi data memberikan kemampuan *spatial invariance*, memungkinkan model mengenali ras kucing secara akurat meskipun objek mengalami rotasi atau perubahan skala, sejalan dengan temuan Ramadhan & Wati [12].

Secara statistik, gap kinerja yang signifikan antara CNN (93.33%) dan RF (68.33%) telah divalidasi menggunakan Uji Beda Dua Proporsi (*Two-proportion Z-test*). Hasil pengujian menunjukkan nilai $p\text{-value} < 0.0001$, yang mengindikasikan bahwa perbedaan akurasi tersebut sangat signifikan secara statistik dan bukan merupakan kebetulan. Temuan ini memvalidasi teori Xi [8] bahwa pendekatan *Deep Learning* pada dasarnya lebih efektif dalam menangkap representasi data kompleks dibandingkan metode *ensemble* tradisional pada data mentah.

Implikasi utama dari temuan ini menegaskan bahwa fitur otomatis pada CNN (ResNet50V2) jauh lebih *robust* dibandingkan fitur manual (HOG + Color Histogram). Sebagaimana didukung oleh temuan Akbar [15], kedalaman jaringan ResNet50V2 sangat efektif untuk mengidentifikasi karakteristik tekstur halus. Sebaliknya, Random Forest menunjukkan keterbatasan dalam menangani variabilitas intra-kelas yang tinggi, konsisten dengan meta-analisis Sheykhmousa et al.[3]. Dengan demikian, CNN ditetapkan sebagai metode terbaik dalam penelitian ini, membuka peluang besar untuk implementasi sistem identifikasi otomatis *real-time* pada perangkat *mobile* [16].

D. Perbandingan Dengan Penelitian Terkait

Temuan penelitian ini sejalan dengan beberapa penelitian sebelumnya namun juga memberikan kontribusi spesifik. Karlita et al, [1] mencapai akurasi 95% untuk 9 ras kucing menggunakan EfficientNet-B0, sementara penelitian ini fokus pada perbandingan langsung dengan RF. Ramadhan & Wati [12] mencapai akurasi 90.87% untuk klasifikasi ras kucing dengan Xception. Hasil CNN dalam penelitian ini (93.33% untuk 3 ras) konsisten dengan standar tersebut. Di sisi lain, studi perbandingan oleh Latifah & Fendriani [17] di domain citra medis juga menemukan keunggulan CNN (97%) atas RF (95%), meskipun gap-nya lebih kecil dibandingkan penelitian ini (25% vs 2%), mungkin karena perbedaan kompleksitas domain.

Keterbatasan RF yang ditemukan dalam penelitian ini juga didukung oleh temuan Sothe et al. [7] yang menyatakan bahwa kinerja RF sangat bergantung pada kualitas fitur input. Dalam konteks citra kucing, fitur manual (HOG + *Color Histogram*) terbukti tidak memadai untuk menangkap variasi tekstur yang kompleks.

IV. SIMPULAN

Penelitian ini berhasil membandingkan kinerja dua pendekatan pembelajaran mesin yang berbeda untuk klasifikasi *fine-grained* ras kucing. Berdasarkan hasil eksperimen, dapat disimpulkan bahwa pendekatan *Deep Learning* menggunakan CNN dengan arsitektur ResNet50V2 jauh lebih unggul dibandingkan pendekatan *Machine Learning* tradisional (Random Forest) yang berbasis fitur manual. CNN terbukti mampu menghasilkan akurasi sebesar 93.33%, sedangkan Random Forest hanya mencapai 68.33%.

Kesenjangan kinerja ini menunjukkan bahwa ekstraksi fitur otomatis pada CNN lebih efektif dalam menangkap representasi visual yang kompleks, seperti tekstur bulu dan struktur wajah, dibandingkan kombinasi fitur manual (HOG dan *Color Histogram*). Kegagalan Random Forest terutama terlihat pada identifikasi ras dengan variasi tekstur tinggi (Persian), di mana deskriptor fitur manual tidak cukup *robust* untuk membedakan pola *fine-grained*. Dengan demikian, metode CNN direkomendasikan sebagai solusi terbaik untuk kasus klasifikasi citra biologis dengan kemiripan visual yang tinggi.

Mengingat penelitian ini masih memiliki keterbatasan pada penggunaan dataset publik, penelitian selanjutnya disarankan untuk memperluas variasi dataset dengan menambahkan citra kucing ras lokal guna meningkatkan representasi model terhadap kondisi riil. Selain itu, eksplorasi pendekatan metode *Hybrid* (CNN-RF) serta penerapan teknik augmentasi data yang lebih kompleks dapat dipertimbangkan di masa depan untuk meningkatkan efisiensi komputasi tanpa mengorbankan akurasi.

UCAPAN TERIMA KASIH

Terimakasih kepada Program Studi Informatika Universitas Nasional yang telah membimbing dan mengizinkan untuk mengajukan penulisan penelitian ini.

DAFTAR PUSTAKA

- [1] T. Karlita, N. A. Choirunisa, R. Asmara, and F. Setyorini, "Cat Breeds Classification Using Compound Model Scaling Convolutional Neural Networks.," *Proceedings of the International Conference on Applied Science and Technology on Social Science 2021 (iCAST-SS 2021)*, vol. 647, pp. 909–914, 2022, doi: 10.2991/assehr.k.220301.150.
- [2] L. Dong *et al.*, "Very High Resolution Remote Sensing Imagery Classification Using a Fusion of Random Forest and Deep Learning Technique-Subtropical Area for Example," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 13, pp. 113–128, 2020, doi: 10.1109/JSTARS.2019.2953234.
- [3] M. Sheykhoum, M. Mahdianpari, H. Ghanbari, F. Mohammadimanesh, P. Ghamisi, and S. Homayouni, "Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 13, pp. 6308–6325, 2020, doi: 10.1109/JSTARS.2020.3026724.
- [4] F. Khozeimeh *et al.*, "RF-CNN-F: random forest with convolutional neural network features for coronary artery disease diagnosis based on cardiac magnetic resonance," *Sci. Rep.*, vol. 12, no. 1, pp. 1–12, 2022, doi: 10.1038/s41598-022-15374-5.
- [5] E. C. Seyrek and M. Uysal, "Investigation of the performances of Support Vector Machine, Random Forest, and 3D-2D Convolutional Neural Network for Hyperspectral Image Classification," *Earth Sciences Research Journal*, vol. 28, no. 2, pp. 161–174, 2024, doi: 10.15446/esrj.v28n2.105296.
- [6] Y. Zhu, J. Duan, and T. Wu, "Animal fiber imagery classification using a combination of random forest and deep learning methods," *J. Eng. Fiber. Fabr.*, vol. 16, no. 58, 2021, doi: 10.1177/15589250211009333.
- [7] C. Sothe *et al.*, "Comparative performance of convolutional neural network, weighted and conventional support vector machine and random forest for classifying tree species using hyperspectral and photogrammetric data," *GLSci. Remote Sens.*, vol. 57, no. 3, pp. 369–394, 2020, doi: 10.1080/15481603.2020.1712102.
- [8] E. Xi, "Image Classification and Recognition Based on Deep Learning and Random Forest Algorithm," *Wirel. Commun. Mob. Comput.*, vol. 2022, 2022, doi: 10.1155/2022/2013181.
- [9] P. & Adam, "KLASIFIKASI RAS KUCING MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK," vol. 13, no. November, pp. 191–200, 2023.
- [10] R. Mardianto, Stefanie Quinevera, and S. Rochimah, "Perbandingan Metode Random Forest, Convolutional Neural Network, dan Support Vector Machine Untuk Klasifikasi Jenis Mangga," *Journal of Applied Computer Science and Technology*, vol. 5, no. 1, pp. 63–71, 2024, doi: 10.52158/jacost.v5i1.742.
- [11] M. Jeffry Setiawan, B. Nugroho, and A. Puspita Sari, "Klasifikasi Penyakit Daun Tanaman Menggunakan Algoritma CNN dan Random Forest," *Teknologi*, vol. 12, no. 1, pp. 1–8, 2022, [Online]. Available: <https://journal.unipdu.ac.id/index.php/teknologi/article/view/2403>
- [12] R. M. Ramadhan and L. Wati, "Klasifikasi Ras Kucing Menggunakan Algoritma Convolutional Neural Network," *Riset dan E-Jurnal Manajemen Informatika Komputer*, vol. 13, no. 3, pp. 851–860, 2025, doi: 10.23960/jitet.v13i3.7364.
- [13] S. Dwi Permana Putra, Fikri, and O. Tivani Kiki, "Identifikasi Jenis Kucing Berdasarkan Pola Citra Menggunakan Convolution Neural Network," *Universitas Nusantara PGRI Kediri. Kediri*, vol. 4, pp. 765–771, 2025, [Online]. Available: <https://proceeding.unpkediri.ac.id/index.php/stains/article/view/6694>
- [14] U. S. Rahmadhani *et al.*, "Klasifikasi Jamur Berdasarkan Genus Dengan Menggunakan Metode CNN," *Jurnal Informatika: Jurnal Pengembangan IT (JPIT)*, vol. 8, no. 2, pp. 169–173, 2023.
- [15] A. Akbar, M. N. Karim, and B. Imran, "Implementation of Conditional WGAN-GP, ResNet50V2, and HDBSCAN for Generating and Recommending Traditional Lombok Songket Motifs," vol. 9, no. 5, pp. 2040–2048, 2025.
- [16] R. Hidayatullah, E. Ariendy Widodo, and S. Riki Mustafa, "Penerapan Convolutional Neural Network (CNN) Pada Klasifikasi Ras Kucing Padigree Dengan Model Keras Sequential," *Riau Journal of Computer Science*, vol. 10, no. 2, pp. 156–166, 2024, [Online]. Available: www.kaggle.com
- [17] A. Latifah and Y. Fendriani, "MAMMOGRAM MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN) DAN RANDOM FOREST," vol. 10, no. 3, pp. 95–103, 2025.