

Perbandingan Kinerja ANN dan CNN dalam Tugas Klasifikasi Citra Berbasis Pembelajaran Mesin

Faathir Akbar Nugroho^{a,1,*}, Ninuk Wiliani^{b,2}

^aUniversitas Pancasila, Jl. Lenteng Agung Raya No.56, RT.1/RW.3, Srengseng Sawah, Kec. Jagakarsa, Kota Jakarta Selatan, Daerah Khusus Ibukota Jakarta 12630

^bUniversitas Pancasila, Jl. Lenteng Agung Raya No.56, RT.1/RW.3, Srengseng Sawah, Kec. Jagakarsa, Kota Jakarta Selatan, Daerah Khusus Ibukota Jakarta 12630

¹4522210033@univpancasila.ac.id, ²ninuk.wiliani@univpancasila.ac.id

*Faathir Akbar Nugroho

Diterima	Direvisi	Disetujui	Dipublikasikan
5/1/2025	11/6/2025	13/6/2025	13/6/2025

ABSTRACT

Advances in machine learning have brought great impact on image recognition through Artificial Neural Network (ANN) and Convolutional Neural Network (CNN) approaches. This study compares the performance of both algorithms in image classification with a dataset of two classes, namely Green and Red Keychains. The dataset consists of 100 images processed through augmentation and data division of 65% for training and 35% for testing. The evaluation results show that CNN has higher accuracy, which is 88.24% to 93.94%, compared to ANN which reaches 62.12% to 67.65%. CNN is also more efficient in training time. The advantage of CNN lies in its ability to extract spatial features through convolution layers, while ANN is more suitable for simple data. This study concludes that CNN is superior for color-based image classification, although further research is needed with larger datasets.

KEYWORDS

Artificial Neural Network
Convolutional Neural Network
Classification
Image Processing
Machine Learning

ABSTRAK

Kemajuan dalam pembelajaran mesin telah membawa dampak besar pada pengenalan gambar melalui pendekatan Artificial Neural Network (ANN) dan Convolutional Neural Network (CNN). Penggunaan ANN dan CNN pada pemrosesan gambar perlu dilakukan analisis lebih lanjut dalam hasil kinerja, oleh karena itu penelitian ini bertujuan untuk membandingkan kinerja dua algoritma menggunakan dataset dua kelas, gambar yaitu Gantungan Kunci Hijau dan Merah. Dataset terdiri dari 100 gambar yang diproses melalui augmentasi dan pembagian data 65% untuk pelatihan dan 35% untuk pengujian. Hasil evaluasi menunjukkan bahwa CNN memiliki akurasi lebih tinggi, yaitu 87,9% hingga 95%, dibandingkan ANN yang mencapai 61,9% hingga 67,5%. CNN juga lebih efisien dalam waktu pelatihan. Keunggulan CNN terletak pada kemampuannya mengekstraksi fitur spasial melalui lapisan konvolusi, sedangkan ANN lebih cocok untuk data sederhana. Penelitian ini menyimpulkan bahwa CNN unggul untuk klasifikasi gambar berbasis warna.

KATA KUNCI

Jaringan Saraf Tiruan
Convolutional Neural Network
Klasifikasi
Pemrosesan Gambar
Pembelajaran Mesin

This is an open access article under the CC-BY-SA license.



1 PENDAHULUAN

Di era teknologi modern, kemajuan dalam *machine learning* telah memberikan dampak besar di berbagai bidang, termasuk pengenalan gambar [1]. Artificial Neural Network (ANN) dan Convolutional Neural Network (CNN) merupakan dua pendekatan utama dalam deep learning yang sering diterapkan untuk tugas klasifikasi gambar. ANN merupakan algoritma yang menyerupai cara kerja otak manusia dengan menghubungkan neuron-neuron secara berlapis, sedangkan CNN dirancang khusus untuk mengenali pola dalam data berbentuk gambar dengan memanfaatkan proses konvolusi.

Penelitian sebelumnya menunjukkan bahwa CNN memiliki keunggulan dalam tugas-tugas berbasis citra karena kemampuannya dalam mengekstraksi fitur spasial secara otomatis [2]. Namun, ANN tetap relevan karena kesederhanaannya dan kinerjanya yang efisien pada dataset kecil. Pada penelitian ini, *dataset* terdiri dari dua kelas utama, yaitu Gantungan Kunci Hijau dan Merah, yang dirancang untuk mengevaluasi performa kedua algoritma tersebut. Penelitian serupa menemukan bahwa akurasi CNN secara konsisten lebih tinggi dibandingkan ANN, tetapi waktu pelatihan dan kebutuhan sumber daya menjadi tantangan yang harus diatasi [3].

Menggabungkan kedua algoritma ini untuk perbandingan memberikan peluang untuk mengevaluasi efisiensi dan akurasi dari setiap metode, khususnya pada dataset dengan klasifikasi warna yang memiliki karakteristik unik. Penelitian ini bertujuan untuk memberikan pemahaman yang lebih mendalam tentang kelebihan dan kelemahan ANN dan CNN pada tugas pengklasifikasian citra dengan *dataset* spesifik.

2 METODE PENELITIAN

Penelitian ini bertujuan untuk membandingkan performa (*CNN*) *Convolutional Neural Network* dan (*ANN*) *Artificial Neural Network* dan dalam pengklasifikasian gambar. Metodologi yang diterapkan dijelaskan secara rinci dalam bagian ini, meliputi dataset, preprocessing, arsitektur model, metrik evaluasi, dan prosedur eksperimen.

1.1 Dataset

Dataset yang dipakai dalam penelitian ini terdiri atas 100 gambar dengan dua kelas utama, yaitu Gantungan Kunci Hijau dan Merah. Setiap kelas terdiri dari 50 gambar, yang merupakan hasil jepretan kamera ponsel dengan pengaturan standar. Data berupa gambar RGB dengan resolusi asli yang akan disesuaikan selama proses *preprocessing*. Dataset ini dibuat secara mandiri dan difokuskan untuk mengevaluasi performa model dalam klasifikasi berbasis warna.

1.2 Preprocessing Data

Untuk meningkatkan performa model, dilakukan langkah-langkah *preprocessing* yang disesuaikan dengan model latih yang akan digunakan, langkah *preprocessing* yang dikerjakan adalah sebagai berikut [4]:

Preprocessing pada ANN, Data untuk model ANN diproses menggunakan *ImageDataGenerator* dengan parameter sebagai berikut: **(1) Rescaling**: Nilai piksel gambar dinormalisasi ke rentang [0,1] dengan membagi nilai piksel dengan 255. **(2) Augmentasi Data**: Rotasi hingga 45 derajat, Pergeseran lebar (*width shift*) sebesar 20%, Pergeseran tinggi (*height shift*) sebesar 20%, Shear transformation hingga 20%, Zooming hingga 20%, Flipping secara horizontal. **(3) Validation Split**: Data dibagi dengan rasio 65% untuk pelatihan dan 35% untuk validasi.

Sementara itu untuk **Preprocessing pada CNN**, Data untuk model CNN diproses menggunakan *ImageDataGenerator* dengan parameter sebagai berikut: **(1) Rescaling**: Nilai piksel gambar dinormalisasi ke rentang [0,1] dengan membagi nilai piksel dengan 255. **(2) Augmentasi Data**: Rotasi hingga 50 derajat, Pergeseran lebar (*width shift*) sebesar 20%, Pergeseran tinggi (*height shift*) sebesar 20%, Shear transformation hingga 20%, Zooming hingga 20%, Flipping secara horizontal, Pengisian piksel dengan mode 'nearest' untuk bagian yang hilang akibat augmentasi. **(3) Validation Split**: Data dibagi dengan rasio 65% untuk pelatihan dan 35% untuk validasi.

1.3 Arsitektur Model

Model arsitektur yang diterapkan pada penelitian ini bervariasi didasarkan dari model yang digunakan [5]. **Model Artificial Neural Network (ANN)** dibangun berdasarkan arsitektur berikut: **Input Layer**: Menerima data gambar dengan ukuran (72, 72, 3), **Flatten Layer**: Meratakan data input menjadi vektor 1D. **Hidden Layer 1**: Layer Dense dengan 128 neuron menggunakan fungsi aktivasi ReLU, dilengkapi dengan Dropout sebesar 0.5 dan Batch Normalization untuk regularisasi. **Hidden Layer 2**: Layer Dense dengan 64 neuron menggunakan fungsi aktivasi ReLU. **Output Layer**: Layer Dense dengan 1 neuron menggunakan fungsi aktivasi Sigmoid untuk klasifikasi biner.

Sementara itu, untuk model **Convolutional Neural Network (CNN)** dibangun berdasarkan arsitektur berikut: **Convolutional Layer 1**: Layer Conv2D dengan 64 filter berukuran kernel 3x3, fungsi aktivasi ReLU, dan input shape (72, 72, 3). **Pooling Layer 1**: Layer MaxPooling2D dengan ukuran kernel 2x2 untuk mengurangi dimensi data. **Convolutional Layer 2**: Layer Conv2D dengan 128 filter berukuran kernel 3x3, fungsi aktivasi ReLU. **Pooling Layer 2**: Layer MaxPooling2D dengan ukuran kernel 2x2. **Flatten Layer**: Meratakan data menjadi vektor 1D. **Hidden Layer**: Layer Dense dengan 128 neuron menggunakan fungsi aktivasi ReLU, dilengkapi dengan Dropout sebesar 0.5 untuk regularisasi. **Output Layer**: Layer Dense dengan 2 neuron menggunakan fungsi aktivasi Softmax untuk klasifikasi dua kelas.

1.4 Pelatihan dan Evaluasi

Proses pelatihan yang dilakukan adalah membagi data menjadi dua bagian, yaitu 65% digunakan untuk data latih dan 35% untuk data uji [6]. Data pelatihan digunakan untuk melatih model, sedangkan data uji digunakan untuk mengevaluasi performa model. Model ANN dan CNN dilatih menggunakan framework TensorFlow dengan beberapa tahapan meliputi: (1) Pengaturan parameter awal, seperti *learning rate* dan *batch size* [7]. (2) Pelatihan model dengan *epoch* yang telah ditentukan. (3) Penggunaan fungsi kehilangan (*loss function*) *categorical crossentropy* [8]. Sementara itu untuk evaluasi menggunakan nilai metrik evaluasi yang digunakan untuk membandingkan performa ANN dan CNN meliputi [9]: **Precision**: Mengukur ketepatan prediksi positif terhadap total prediksi positif. **Recall**: Mengukur sensitivitas model dalam mendeteksi kelas tertentu. **F1-Score**: Rata-rata harmonis antara precision dan recall. **Akurasi**: Mengukur persentase prediksi yang benar dari seluruh data uji.

3 HASIL DAN PEMBAHASAN

Penelitian ini menggunakan TensorFlow sebagai framework utama untuk membangun dan melatih model ANN dan CNN [10]. Bahasa pemrograman Python digunakan sebagai alat untuk menyusun kode program, dengan pustaka pendukung seperti NumPy dan Matplotlib untuk analisis data dan visualisasi hasil. Berikut hasil evaluasi kinerja Convolutional Neural Network (CNN) dan Artificial Neural Network (ANN) dalam pengklasifikasian gambar berdasarkan dataset yang telah digunakan dapat dilihat pada Tabel 1 untuk hasil analisis ANN dan Tabel 2 untuk hasil analisis CNN, hasil tersebut dianalisis untuk menentukan keunggulan dari masing-masing metode.

Tabel 1. Hasil Evaluasi ANN

Kelas	Precision	Recall	F1-Score	Support
Gantungan Kunci Hijau	0.47	0.41	0.44	17
Gantungan Kunci Hijau	0.47	0.53	0.50	17
Macro Avg	0.47	0.47	0.47	34
Weighted Avg	0.47	0.47	0.47	34

Tabel 2. Hasil Evaluasi CNN

Kelas	Precision	Recall	F1-Score	Support
Gantungan Kunci Hijau	0.44	0.47	0.46	17
Gantungan Kunci Hijau	0.44	0.41	0.42	17
Macro Avg	0.44	0.44	0.44	34
Weighted Avg	0.44	0.44	0.44	34

Dari hasil di atas, ANN dan CNN memiliki performa yang hampir serupa dalam metrik precision, recall, dan F1-score pada dataset ini. Namun, akurasi keduanya menunjukkan bahwa ANN sedikit lebih baik daripada CNN, meskipun dengan selisih yang cukup kecil. Sementara itu untuk akurasi CNN menunjukkan performa yang lebih unggul dibandingkan ANN, dengan akurasi berada pada rentang 61,9% hingga 67,5% untuk ANN seperti pada Gambar 1, sedangkan CNN mencapai nilai akurasi sebesar 87,9% hingga 95% seperti pada Gambar 2. Hal ini menegaskan bahwa CNN memiliki keunggulan dalam mengenali pola-pola yang lebih kompleks pada data berbasis gambar

```
[ ] scores = model.evaluate(train_generator, verbose=1)
print("Accuracy: %.2f%%" % (scores[1]*100))

9/9 ----- 11s 1s/step - accuracy: 0.6190 - loss: 0.6260
Accuracy: 62.12%

[ ] scores = model.evaluate(validation_generator, verbose=1)
print("Accuracy: %.2f%%" % (scores[1]*100))

5/5 ----- 6s 1s/step - accuracy: 0.6751 - loss: 0.6372
Accuracy: 67.65%
```

Gambar 1. Hasil akurasi untuk ANN

```
[ ] scores = model.evaluate(train_generator, verbose=1)
print("Accuracy: %.2f%%" % (scores[1]*100))

3/3 ----- 10s 2s/step - accuracy: 0.9502 - loss: 0.1931
Accuracy: 93.94%

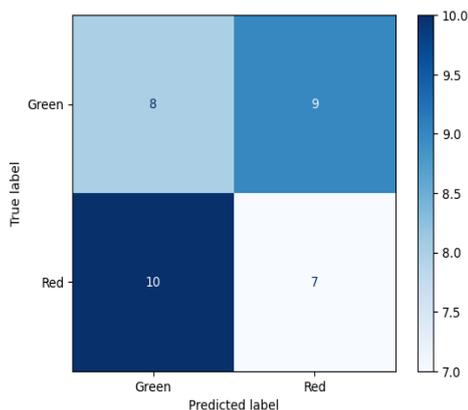
scores = model.evaluate(validation_generator, verbose=1)
print("Accuracy: %.2f%%" % (scores[1]*100))

2/2 ----- 6s 406ms/step - accuracy: 0.8799 - loss: 0.2605
Accuracy: 88.24%
```

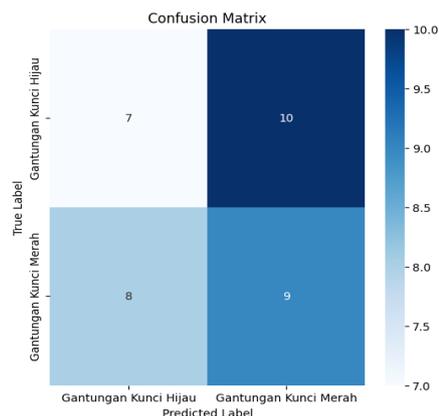
Gambar 2. Hasil akurasi untuk CNN

Walaupun menggunakan dataset yang sama, CNN menunjukkan hasil yang lebih baik dibandingkan ANN. Hal ini disebabkan oleh arsitektur CNN yang lebih unggul dalam mengekstraksi fitur spasial pada data gambar. CNN memiliki lapisan konvolusi yang dirancang untuk mendeteksi pola, seperti tepi dan tekstur, yang tidak dimiliki oleh ANN. Sebaliknya, ANN lebih cocok untuk data yang terstruktur atau memiliki fitur yang telah ditentukan sebelumnya. Sementara itu, berdasarkan hasil pengamatan, waktu pelatihan antara ANN dan CNN menunjukkan perbedaan yang cukup signifikan. Pada ANN, rata-rata waktu per epoch berada di kisaran 18 hingga 36 detik, sedangkan pada CNN waktu pelatihan per epoch berkisar antara 13 hingga 26 detik. Hal ini menunjukkan bahwa CNN cenderung membutuhkan waktu pelatihan yang lebih singkat dibandingkan ANN, meskipun memiliki arsitektur yang lebih kompleks.

Faktor yang memengaruhi perbedaan waktu pelatihan ini adalah ukuran batch yang digunakan serta kompleksitas komputasi pada tiap layer. CNN, meskipun memiliki lapisan konvolusi yang memproses data lebih kompleks, dapat dioptimalkan dengan baik untuk perangkat keras modern seperti GPU. Sebaliknya, ANN sering kali dipengaruhi oleh proses *flattening* dan pengelolaan layer yang lebih terhubung secara penuh (*fully connected*), yang dapat memengaruhi efisiensi waktu pelatihan. Hasil evaluasi divisualisasikan dalam bentuk confusion matrix yang dapat dilihat pada Gambar 3 dan Gambar 4.



Gambar 3. Confusion Matrix untuk CNN



Gambar 4. Confusion Matrix untuk ANN

Visualisasi confusion matrix menunjukkan bahwa terdapat beberapa kesalahan prediksi untuk kedua model, terutama dalam membedakan antara dua kelas (Gantungan Kunci Hijau dan Merah).

4 KESIMPULAN

Penelitian ini menunjukkan bahwa CNN memiliki performa yang lebih baik dalam klasifikasi gambar dibandingkan dengan ANN, terutama pada akurasi yang lebih tinggi. Keunggulan ini dapat dijelaskan oleh kemampuan CNN dalam mengekstraksi fitur spasial secara otomatis, sedangkan ANN cenderung kesulitan dalam memproses data yang memiliki dimensi kompleks seperti gambar. Namun, perlu dicatat bahwa performa kedua model sangat dipengaruhi oleh ukuran dataset yang relatif kecil, oleh karena itu, hasil ini belum dapat diterapkan secara umum pada dataset yang lebih besar atau lebih kompleks. Untuk penelitian mendatang, meningkatkan jumlah data dan menerapkan teknik augmentasi yang lebih beragam dapat menjadi solusi untuk meningkatkan kinerja model.

Perbandingan performa antara *Artificial Neural Network (ANN)* dan *Convolutional Neural Network (CNN)* dalam tugas klasifikasi gambar dengan menggunakan dataset yang terdiri dari dua kelas utama, yaitu Gantungan Kunci Hijau dan Merah. Berdasarkan hasil evaluasi, CNN menunjukkan keunggulan yang signifikan dalam mengenali pola-pola kompleks pada data gambar dengan akurasi berkisar antara 87,9% hingga 95% untuk CNN.

Walaupun CNN lebih unggul dari segi akurasi, waktu pelatihan menunjukkan bahwa CNN memiliki efisiensi yang lebih baik dengan rata-rata waktu per *epoch* antara 13 hingga 26 detik, dibandingkan ANN yang membutuhkan waktu antara 18 hingga 36 detik per *epoch*. Faktor ini dapat dijelaskan oleh kemampuan CNN dalam memanfaatkan optimasi perangkat keras modern seperti GPU. Sebaliknya, ANN lebih sederhana tetapi memiliki keterbatasan dalam mengekstraksi fitur spasial pada data gambar.

Hasil penelitian ini menegaskan bahwa CNN lebih sesuai untuk tugas klasifikasi berbasis gambar yang memerlukan pengenalan pola spasial yang kompleks. Namun, keterbatasan penelitian ini adalah ukuran dataset yang relatif kecil, sehingga hasilnya belum dapat digeneralisasi untuk dataset yang lebih besar. Penelitian mendatang disarankan untuk menggunakan dataset yang lebih variatif dan menerapkan teknik augmentasi yang lebih canggih untuk meningkatkan performa model.

5 KONTRIBUSI PENELITIAN

Penelitian ini memberikan kontribusi dalam membandingkan secara langsung performa *Artificial Neural Network (ANN)* dan *Convolutional Neural Network (CNN)* pada tugas klasifikasi citra berbasis warna, menggunakan dataset spesifik Gantungan Kunci Hijau dan Merah. Dengan mengevaluasi akurasi, efisiensi, dan keandalan kedua model, penelitian ini memberikan wawasan tentang pemilihan algoritma yang optimal untuk dataset kecil dengan karakteristik serupa. Selain itu, penelitian ini juga diharapkan menjadi referensi bagi pengembangan metode klasifikasi citra di masa depan, khususnya untuk kasus-kasus dengan keterbatasan sumber daya komputasi.

UCAPAN TERIMA KASIH

Penulis menyampaikan penghargaan dan rasa terima kasih yang mendalam kepada Ibu Ninuk Wiliani, selaku dosen Universitas Pancasila, atas bimbingan akademik yang telah diberikan selama pelaksanaan penelitian ini. Ucapan terima kasih juga disampaikan kepada keluarga yang telah memberikan dukungan penuh, baik dalam bentuk fasilitas maupun pembiayaan peralatan yang diperlukan untuk menyelesaikan penelitian ini. Dukungan ini sangat berarti dalam memastikan kelancaran penelitian dan penyelesaian jurnal ini.

DAFTAR PUSTAKA

- [1] A. Pratap and N. Sardana, "Machine learning-based image processing in materials science and engineering: A review," in *Materials Today: Proceedings*, 2022, pp. 7341–7347. doi: <https://doi.org/10.1016/j.matpr.2022.01.200>.
- [2] X. Zhao, L. Wang, Y. Zhang, X. Han, M. Deveci, and M. Parmar, "A review of convolutional neural networks in computer vision," *Artif. Intell. Rev.*, vol. 57, no. 4, p. 99, 2024, doi: [10.1007/s10462-024-10721-6](https://doi.org/10.1007/s10462-024-10721-6).
- [3] M. I. Vawda, R. Lottering, O. Mutanga, K. Peerbhay, and M. Sibanda, "Comparing the Utility of Artificial Neural Networks (ANN) and Convolutional Neural Networks (CNN) on Sentinel-2 MSI to Estimate Dry Season Aboveground Grass Biomass," *Sustainability*, vol. 16, no. 3, 2024, doi: [10.3390/su16031051](https://doi.org/10.3390/su16031051).
- [4] D. Anggraeni, A. Wulandari, T. Barasaruddin, and D. Yanti, "Enhancing CNN with preprocessing stage in automatic emotion enhancing CNN with preprocessing stage in automatic emotion recognition recognition," in *Procedia computer science*, 2017, pp. 523–529.
- [5] S. Walczak and N. Cerpa, "Artificial Neural Networks," in *Encyclopedia of Physical Science and Technology (Third Edition)*, Third Edition., R. A. Meyers, Ed., New York: Academic Press, 2003, pp. 631–645. doi: <https://doi.org/10.1016/B0-12-227410-5/00837-1>.
- [6] H. K. Jeong *et al.*, "Image Quality Assessment Using Convolutional Neural Network in Clinical Skin Images," *JID Innov.*, vol. 4, no. 4, p. 100285, 2024, doi: <https://doi.org/10.1016/j.xjidi.2024.100285>.
- [7] I. Kandel and M. Castelli, "The effect of batch size on the generalizability of the convolutional neural networks on a histopathology dataset," *ICT Express*, vol. 6, no. 4, pp. 312–315, 2020, doi: <https://doi.org/10.1016/j.icte.2020.04.010>.
- [8] K. Tong and Y. Wu, "Deep learning-based detection from the perspective of small or tiny objects: A survey," *Image Vis. Comput.*, vol. 123, p. 104471, 2022, doi: <https://doi.org/10.1016/j.imavis.2022.104471>.
- [9] M. Vakili, M. Ghamsari, and M. Rezaei, "Performance analysis and comparison of machine and deep learning algorithms for IoT data classification," *arXiv Prepr. arXiv2001.09636*, 2020.
- [10] O. Kembuan, G. Caren Rorimpandey, and S. Milian Tompunu Tengker, "Convolutional Neural Network (CNN) for Image Classification of Indonesia Sign Language Using Tensorflow," in *2020 2nd International Conference on Cybernetics and Intelligent System (ICORIS)*, 2020, pp. 1–5. doi: [10.1109/ICORIS50180.2020.9320810](https://doi.org/10.1109/ICORIS50180.2020.9320810).