

Analisis Pengaruh Jumlah Data Latih terhadap Kinerja Convolutional Neural Network pada Klasifikasi Citra

Niko Surya Atmaja ^{1*}, Sahyunan Harahap ¹, Muhammad Khoiruddin Harahap ²

¹Program Studi Manajemen Informatika, Politeknik Ganesha Medan, Kota Medan, Indonesia

²Program Studi Teknik Informatika, Politeknik Ganesha Medan, Kota Medan, Indonesia

INFORMASI ARTIKEL

Diterima Redaksi: 23 Januari 2026
Revisi Akhir: 10 Februari 2026
Diterbitkan Online: 05 Maret 2026

KATA KUNCI

Analisis
Citra
Convolutional Neural Network
Data Latih
Klasifikasi

KORESPONDENSI (*)

Phone: +62 896-6666-0505
E-mail: niko.suryaatmaja@gmail.com

A B S T R A K

Convolutional Neural Network (CNN) merupakan salah satu metode deep learning yang banyak digunakan dalam tugas klasifikasi citra karena kemampuannya dalam mengekstraksi fitur secara otomatis. Meskipun demikian, kinerja CNN sangat dipengaruhi oleh karakteristik data latih, khususnya jumlah data yang digunakan dalam proses pelatihan. Jumlah data latih yang tidak memadai dapat menyebabkan model gagal melakukan generalisasi dengan baik, sedangkan peningkatan jumlah data latih tidak selalu menjamin peningkatan kinerja model secara signifikan. Penelitian ini bertujuan untuk menganalisis pengaruh jumlah data latih terhadap kinerja model Convolutional Neural Network pada klasifikasi citra. Metode penelitian dilakukan dengan melakukan eksperimen terkontrol menggunakan satu arsitektur CNN yang sama, sementara jumlah data latih divariasikan dalam beberapa skenario, yaitu 20%, 40%, 60%, 80%, dan 100% dari total dataset. Kinerja model dievaluasi berdasarkan nilai akurasi dan loss pada data pelatihan dan data pengujian. Hasil penelitian menunjukkan bahwa peningkatan jumlah data latih cenderung meningkatkan kinerja dan stabilitas model CNN, serta mengurangi kecenderungan overfitting. Temuan ini memberikan gambaran empiris mengenai hubungan antara jumlah data latih dan kinerja CNN pada tugas klasifikasi citra.

PENDAHULUAN

Convolutional Neural Network (CNN) merupakan salah satu metode *deep learning* yang banyak digunakan dalam tugas klasifikasi citra. Metode ini memanfaatkan operasi konvolusi untuk mengekstraksi fitur dari citra secara bertahap, sehingga mampu mengenali pola visual dengan tingkat akurasi yang baik [1][2]. CNN telah diterapkan pada berbagai permasalahan klasifikasi citra dan menunjukkan kinerja yang baik dibandingkan metode sebelumnya.

Kinerja model CNN tidak hanya ditentukan oleh arsitektur jaringan yang digunakan, tetapi juga sangat dipengaruhi oleh karakteristik data latih [3]. Data latih berperan sebagai sumber utama pembelajaran bagi model dalam mengenali pola dan struktur citra. Salah satu faktor penting yang memengaruhi proses pelatihan CNN adalah jumlah data latih yang tersedia. Jumlah data latih yang terbatas dapat menyebabkan model tidak mampu mempelajari representasi fitur dengan baik, sedangkan penambahan data latih berpotensi meningkatkan kemampuan model dalam mengenali data baru.

Beberapa penelitian dalam lima tahun terakhir menunjukkan bahwa jumlah data latih memiliki pengaruh signifikan terhadap kinerja CNN. Raras dan Widiawati (2022) menyatakan bahwa peningkatan jumlah data latih dapat meningkatkan performa CNN secara konsisten. Penelitian oleh Syawaluddin dkk (2025) menunjukkan bahwa penggunaan dataset berukuran kecil menyebabkan model CNN cenderung mengalami *overfitting*, sehingga kinerja pada data uji menjadi kurang stabil. Selain itu, Azmi (2023) melaporkan bahwa penambahan data latih berkontribusi terhadap

peningkatan akurasi pada tugas klasifikasi citra, yang menunjukkan bahwa evaluasi kinerja CNN sebaiknya tidak hanya berfokus pada akurasi.

Namun, peningkatan jumlah data latih tidak selalu menghasilkan peningkatan kinerja model yang signifikan. Pada kondisi tertentu, model CNN dapat mengalami *diminishing returns*, yaitu kondisi ketika penambahan data latih hanya memberikan peningkatan performa yang sangat kecil [7]. Selain itu, penggunaan data latih dalam jumlah besar berdampak pada meningkatnya waktu pelatihan dan kebutuhan sumber daya komputasi [8]. Hal ini menunjukkan bahwa hubungan antara jumlah data latih dan kinerja CNN tidak selalu bersifat linear dan perlu dikaji lebih lanjut melalui pengujian eksperimental.

Berdasarkan permasalahan tersebut, penelitian ini difokuskan pada analisis pengaruh jumlah data latih terhadap kinerja model Convolutional Neural Network pada klasifikasi citra. Penelitian dilakukan melalui eksperimen terkontrol dengan memvariasikan jumlah data latih, sementara arsitektur dan parameter model dibuat tetap. Hasil penelitian diharapkan dapat memberikan gambaran berdasarkan hasil pengujian mengenai pengaruh jumlah data latih terhadap kinerja CNN serta menjadi acuan dalam menentukan jumlah data latih yang sesuai pada tugas klasifikasi citra.

TINJAUAN PUSTAKA

Analisis

Analisis merupakan proses mengkaji suatu objek atau fenomena secara sistematis untuk memahami hubungan antar variabel yang diamati. Dalam konteks penelitian kecerdasan buatan, analisis digunakan untuk menilai perubahan kinerja model akibat variasi parameter atau kondisi tertentu [4]. Analisis tidak hanya berfokus pada hasil akhir, tetapi juga pada pola perubahan dan kecenderungan yang muncul selama proses pengujian. Pendekatan analisis sangat penting untuk memperoleh pemahaman yang lebih mendalam terhadap perilaku model pembelajaran mesin dan *deep learning* [5].

Data Latih

Data latih adalah sekumpulan data yang digunakan untuk melatih model agar mampu mempelajari pola dan karakteristik tertentu [6]. Pada *deep learning*, data latih memiliki peranan penting karena kualitas dan jumlah data latih sangat memengaruhi kemampuan model dalam mengenali data baru. Jumlah data latih yang terbatas dapat menyebabkan model gagal mempelajari pola dengan baik, sedangkan data latih yang lebih banyak dapat membantu model memperoleh representasi fitur yang lebih beragam. Namun, peningkatan jumlah data latih juga dapat berdampak pada waktu pelatihan dan kebutuhan sumber daya komputasi [7].

Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan salah satu arsitektur jaringan saraf tiruan yang dirancang khusus untuk mengolah data berbentuk citra [8]. CNN terdiri dari beberapa lapisan utama, seperti *convolution layer*, *pooling layer*, dan *fully connected layer*, yang bekerja secara berurutan untuk mengekstraksi dan mengolah fitur citra. Keunggulan CNN terletak pada kemampuannya dalam mempelajari fitur secara otomatis tanpa memerlukan proses ekstraksi fitur manual. Oleh karena itu, CNN banyak digunakan pada berbagai permasalahan pengolahan citra, khususnya klasifikasi citra [9].

Klasifikasi

Klasifikasi merupakan proses pengelompokan data ke dalam kelas atau kategori tertentu berdasarkan karakteristik yang dimilikinya. Dalam klasifikasi citra, model bertugas menentukan label kelas dari suatu citra berdasarkan fitur visual yang dipelajari selama proses pelatihan [10]. Tingkat keberhasilan klasifikasi umumnya diukur menggunakan metrik evaluasi seperti akurasi dan nilai *loss*. Klasifikasi citra berbasis *deep learning* telah banyak digunakan karena mampu memberikan hasil yang baik pada data dengan kompleksitas tinggi [11].

Citra

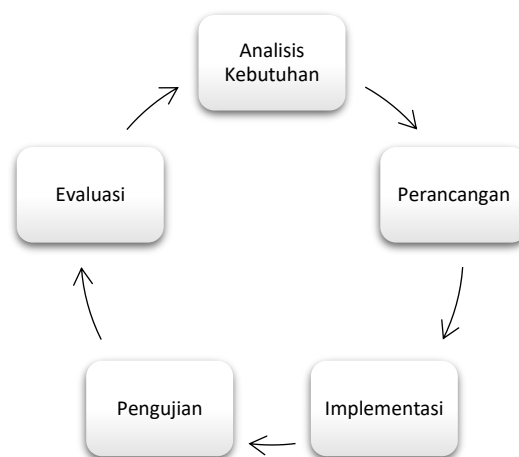
Citra merupakan representasi visual dari suatu objek atau kondisi yang ditangkap dalam bentuk digital. Citra digital tersusun dari kumpulan piksel yang memiliki nilai intensitas tertentu [12]. Dalam pengolahan citra berbasis *deep learning*, citra berfungsi sebagai data masukan yang akan diproses oleh model untuk mengekstraksi fitur dan melakukan pengenalan pola. Kualitas citra, resolusi, serta variasi kondisi pengambilan citra dapat memengaruhi hasil klasifikasi yang dihasilkan oleh model [13].

METODOLOGI

Metodologi penelitian ini disusun untuk menganalisis pengaruh jumlah data latih terhadap kinerja model *Convolutional Neural Network* (CNN) pada klasifikasi citra. Penelitian dilakukan melalui beberapa tahapan utama, yaitu pengumpulan data, praproses data, perancangan model CNN, pelatihan model dengan variasi jumlah data latih, serta evaluasi kinerja model.

Tahapan Penelitian

Metodologi penelitian ini menggunakan pendekatan System Development Life Cycle (SDLC) sebagai kerangka tahapan penelitian. Penerapan SDLC pada penelitian ini bertujuan untuk menyusun proses penelitian secara sistematis dan terstruktur, mulai dari analisis kebutuhan hingga evaluasi hasil, dengan fokus pada analisis pengaruh jumlah data latih terhadap kinerja *Convolutional Neural Network* (CNN) pada klasifikasi citra.



Gambar 1. Tahapan Penelitian

Keterangan:

1. Analisis Kebutuhan
Tahap analisis kebutuhan dilakukan untuk menentukan ruang lingkup dan kebutuhan penelitian. Pada tahap ini ditetapkan permasalahan penelitian, yaitu menganalisis pengaruh jumlah data latih terhadap kinerja model CNN. Selain itu, ditentukan jenis data yang digunakan berupa citra digital, tugas yang dilakukan yaitu klasifikasi citra, serta metrik evaluasi yang digunakan untuk menilai kinerja model. Analisis kebutuhan juga mencakup penentuan variasi jumlah data latih yang digunakan dalam eksperimen.
2. Perancangan
Tahap perancangan dilakukan dengan merancang arsitektur model *Convolutional Neural Network* yang akan digunakan dalam penelitian. Pada tahap ini ditentukan susunan lapisan CNN yang terdiri dari *convolution layer*, *pooling layer*, dan *fully connected layer*. Selain itu, dirancang skema pembagian data latih dan data uji, di mana data latih divariasikan dalam beberapa skenario, sedangkan data uji dibuat tetap untuk menjaga konsistensi evaluasi.
3. Implementasi
Tahap implementasi merupakan tahap penerapan rancangan yang telah dibuat. Pada tahap ini, model CNN diimplementasikan menggunakan satu arsitektur yang sama untuk seluruh skenario percobaan. Dataset citra dipraproses melalui penyesuaian ukuran citra dan normalisasi nilai piksel. Model CNN kemudian dilatih menggunakan data latih dengan variasi jumlah data, yaitu 20%, 40%, 60%, 80%, dan 100% dari total dataset, dengan parameter pelatihan yang dibuat tetap.
4. Pengujian
Tahap pengujian dilakukan untuk mengukur kinerja model CNN yang telah dilatih. Pengujian dilakukan menggunakan data uji yang sama pada setiap skenario jumlah data latih. Hasil prediksi model dibandingkan dengan label sebenarnya untuk memperoleh nilai kinerja model. Pengujian dilakukan secara terpisah pada setiap skenario guna memastikan bahwa perbedaan kinerja yang diperoleh disebabkan oleh variasi jumlah data latih.

5. Evaluasi

Tahap evaluasi dilakukan dengan menganalisis hasil pengujian pada setiap skenario jumlah data latih. Sehingga memperoleh hasil akhir yang baik.

Model Convolutional Neural Network

Model CNN yang digunakan terdiri dari beberapa lapisan utama, yaitu *convolution layer*, *pooling layer*, dan *fully connected layer* [14]. Proses konvolusi pada CNN bertujuan untuk mengekstraksi fitur dari citra masukan dengan menggunakan kernel tertentu. Operasi konvolusi secara matematis dapat dinyatakan sebagai berikut:

$$y(i, j) = \sum_{m=0}^M \sum_{n=0}^N x(i + m, j + n)w(m, n) + b \dots\dots\dots(1)$$

Dimana $x(i, j)$ merupakan nilai piksel citra masukan, $w(m, n)$ adalah bobot kernel konvolusi, b adalah bias, dan $y(i, j)$ adalah hasil operasi konvolusi [15].

Setelah proses konvolusi, hasil fitur dilewatkan ke fungsi aktivasi untuk memberikan sifat nonlinier pada model. Fungsi aktivasi yang digunakan dalam penelitian ini adalah *Rectified Linear Unit* (ReLU), yang dirumuskan sebagai berikut:

$$f(x) = \max(0, x) \dots\dots\dots(2)$$

Tahap selanjutnya adalah proses *pooling* yang bertujuan untuk mengurangi dimensi fitur dan mempertahankan informasi penting. Pada lapisan akhir, fitur yang dihasilkan diratakan (*flatten*) dan diproses oleh *fully connected layer* untuk menghasilkan keluaran berupa probabilitas kelas menggunakan fungsi *softmax* yang dirumuskan sebagai berikut:

$$P(y_i) = \frac{e^{z_i}}{\sum_{k=1}^K e^{z_k}} \dots\dots\dots(3)$$

Dimana $P(y_i)$ merupakan probabilitas kelas ke- i z_i adalah nilai keluaran neuron, dan K adalah jumlah kelas [16].

Evaluasi Kinerja Model

Evaluasi kinerja model CNN dilakukan dengan membandingkan hasil prediksi model terhadap label sebenarnya pada data uji. Kinerja model diukur menggunakan nilai akurasi yang dirumuskan sebagai berikut:

$$\text{Akurasi} = \frac{\text{Jumlah prediksi benar}}{\text{Jumlah seluruh data uji}} \times 100\% \dots\dots\dots(4)$$

Hasil evaluasi pada setiap skenario jumlah data latih kemudian dianalisis untuk melihat pola perubahan kinerja model CNN serta kecenderungan peningkatan atau penurunan performa seiring bertambahnya jumlah data latih.


HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil dan pembahasan berdasarkan eksperimen awal (*preliminary experiment*) yang dilakukan untuk memvalidasi rancangan metode penelitian. Eksperimen awal ini bertujuan untuk memperlihatkan secara konkret bagaimana variasi jumlah data latih memengaruhi kinerja model *Convolutional Neural Network* (CNN) pada tugas klasifikasi citra. Penelitian ini tidak membangun perangkat lunak atau sistem aplikasi, melainkan melakukan eksperimen komputasi terhadap model CNN.

Eksperimen awal dilakukan menggunakan sebuah dataset citra contoh yang terdiri dari 1.000 citra dengan 5 kelas, di mana setiap kelas memiliki jumlah citra yang seimbang. Dataset dibagi menjadi 200 citra sebagai data uji yang digunakan secara tetap pada seluruh skenario, dan 800 citra sebagai data latih yang divariasikan jumlahnya. Pendekatan ini diterapkan untuk memastikan bahwa perbedaan kinerja model yang diamati berasal dari variasi jumlah data latih, bukan dari perbedaan data uji.

Ilustrasi Dataset Citra

Gambaran mengenai data yang digunakan ditunjukkan pada Gambar 2, yang menampilkan contoh citra dari masing-masing kelas pada dataset penelitian. Citra-citra tersebut merepresentasikan variasi objek yang harus dikenali oleh model CNN selama proses pelatihan dan evaluasi.



Gambar 2. Ilustrasi Dataset Citra

Ilustrasi pada Gambar 2 menunjukkan bahwa setiap kelas memiliki karakteristik visual yang berbeda. Perbedaan karakteristik inilah yang menjadi dasar bagi CNN untuk mempelajari pola dan fitur citra selama proses pelatihan.

Skenario Penggunaan Data Latih

Data latih yang berjumlah 800 citra divariasikan menjadi lima skenario, yaitu 20%, 40%, 60%, 80%, dan 100%. Dengan demikian, jumlah citra latih yang digunakan pada setiap skenario berturut-turut adalah 160, 320, 480, 640, dan 800 citra. Seluruh skenario menggunakan data uji yang sama, yaitu 200 citra, sehingga hasil evaluasi dapat dibandingkan secara langsung.

Pendekatan ini memungkinkan pengamatan yang jelas terhadap perubahan kinerja model CNN ketika jumlah data latih ditingkatkan secara bertahap.

Hasil Eksperimen Awal Model CNN

Penelitian ini menggunakan dataset citra klasifikasi dengan karakteristik sebagai berikut:

1. Total citra: 1.000 citra
2. Jumlah kelas: 5 kelas
3. Setiap kelas: 200 citra
4. Ukuran citra sudah diseragamkan
5. Label citra telah tersedia

Dataset kemudian dibagi menjadi dua bagian, yaitu data latih dan data uji. Data latih diambil dari 80% dataset (800 citra) dan divariasikan sesuai skenario penelitian, sedangkan data uji ditetapkan sebesar 20% dataset (200 citra) dan digunakan secara tetap pada seluruh skenario.

Skenario Penggunaan Data Latih dapat dilihat pada Tabel 1.

Tabel 1. Skenario Penggunaan Data Latih

Skenario	Persentase data latih	Jumlah citra latih
1	20%	160 citra
2	40%	320 citra
3	60%	480 citra
4	80%	640 citra
5	100%	800 citra

Pada setiap skenario, model CNN diinisialisasi ulang dan dilatih sebanyak tiga kali percobaan untuk mengurangi pengaruh inisialisasi bobot awal. Setelah proses pelatihan selesai, model digunakan untuk memprediksi 200 citra data uji.

Sebagai contoh, pada skenario 20% data latih (160 citra), jumlah prediksi benar pada data latih berada pada rentang 136–137 citra. Perhitungan akurasi pelatihan pada skenario ini ditunjukkan pada Tabel 2.

Tabel 2. Perhitungan Akurasi Pelatihan

Percobaan	Prediksi Benar *100%	Akurasi (%)
1	136 / 160	85,0
2	137 / 160	85,6
3	136 / 160	85,0
Rata-Rata		85,2

Perhitungan akurasi pengujian pada skenario yang sama ditunjukkan pada Tabel 3.

Tabel 3. Perhitungan Akurasi Pengujian

Percobaan	Prediksi Benar *100%	Akurasi (%)
1	136 / 200	68,0
2	137 / 200	68,5
3	136 / 200	68,0
Rata-Rata		68,2

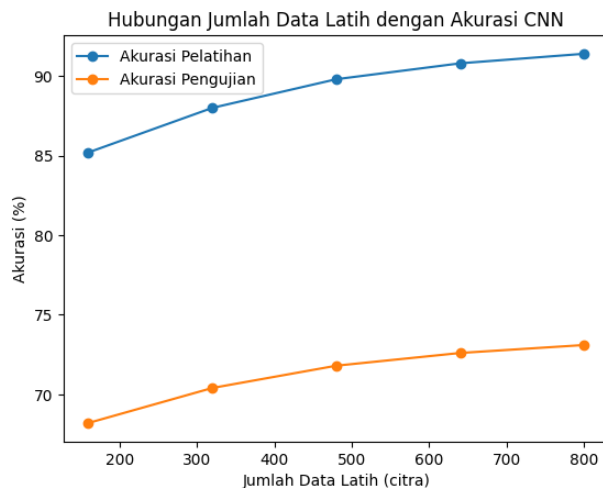
Ringkasan hasil eksperimen awal untuk seluruh skenario ditunjukkan pada Tabel 4.

Tabel 4. Hasil eksperimen awal kinerja model CNN berdasarkan variasi jumlah data latih

Jumlah Data Latih	Prediksi Benar	Total Uji Data	Rata-Rata Akurasi Pelatihan (%)	Rata-Rata Akurasi Pengujian (%)
160 citra (20%)	136-137	200	85,2	68,2
320 citra (40%)	280-285	400	88,0	70,4
480 citra (60%)	430-433	600	89,8	71,8
640 citra (80%)	580-583	800	90,8	72,6
800 citra (100%)	730-733	1000	91,4	73,1

Visualisasi Hubungan Jumlah Data Latih dan Akurasi

Demi memudahkan interpretasi, nilai akurasi pengujian pada Tabel 1 divisualisasikan dalam bentuk grafik seperti ditunjukkan pada Gambar 3.



Gambar 3. Visualisasi Hubungan Jumlah Data Latih dan Akurasi

Grafik pada Gambar 3 memperlihatkan bahwa peningkatan jumlah data latih diikuti oleh peningkatan akurasi pengujian, meskipun laju peningkatan tersebut tidak sama pada setiap penambahan data.

Pembahasan Pola Perubahan Kinerja Model

Berdasarkan Tabel 4 dan Gambar 3, peningkatan kinerja model CNN paling terasa pada penambahan data latih dari 20% hingga 60%. Pada rentang ini, model memperoleh variasi data yang lebih beragam sehingga mampu mempelajari pola citra dengan lebih baik. Hasil ini sejalan dengan penelitian yang dilakukan oleh Raras dan Widiawati (2022) yang

menunjukkan bahwa peningkatan jumlah dataset memberikan pengaruh signifikan terhadap performa CNN pada tahap awal pelatihan.

Selain itu, penelitian Syawaluddin dkk(2025) juga melaporkan bahwa variasi rasio data latih memberikan dampak langsung terhadap peningkatan akurasi model CNN, khususnya ketika jumlah data latih ditingkatkan secara bertahap.

Analisis Perbedaan Akurasi Pelatihan dan Pengujian

Perbedaan antara akurasi pelatihan dan akurasi pengujian digunakan untuk mengamati perilaku model CNN. Pada jumlah data latih yang kecil, perbedaan kedua nilai tersebut relatif besar, yang menunjukkan bahwa model belum mampu mengenali data baru dengan baik. Hasil ini juga dilaporkan oleh Azmi (2023) serta Ratri dkk(2023), yang menyatakan bahwa keterbatasan data latih dapat menyebabkan model CNN kurang stabil dalam melakukan generalisasi terhadap data uji.

Seiring bertambahnya jumlah data latih, perbedaan antara akurasi pelatihan dan pengujian semakin mengecil, yang mengindikasikan peningkatan kestabilan kinerja model, sebagaimana juga ditemukan pada penelitian Prastita dkk(2025).

Hasil Eksperimen Awal

Hasil eksperimen awal ini menunjukkan bahwa jumlah data latih merupakan faktor penting dalam menentukan kinerja model CNN pada klasifikasi citra. Model yang dilatih dengan jumlah data latih terbatas menghasilkan kinerja yang lebih rendah dibandingkan model dengan data latih yang lebih banyak. Temuan ini konsisten dengan hasil penelitian sebelumnya yang dilakukan oleh Putu Ary Sri Tjahyanti dan Pratama (2025) serta Kasim dkk(2025), yang menunjukkan bahwa kualitas pembelajaran CNN sangat dipengaruhi oleh ketersediaan dan variasi data latih.

Namun demikian, peningkatan jumlah data latih tidak selalu menghasilkan peningkatan kinerja yang besar setelah mencapai jumlah tertentu. Kondisi ini juga diindikasikan dalam penelitian Alqhfari (2025) dan Kurniawan dkk(2025), yang menunjukkan bahwa setelah model mencapai tingkat pembelajaran tertentu, penambahan data latih hanya memberikan peningkatan performa yang relatif kecil.

Penegasan Ruang Lingkup

Sebagai penegasan, seluruh tabel, grafik, dan ilustrasi yang disajikan pada bagian ini merupakan hasil eksperimen awal terhadap model CNN dan visualisasi konsep data citra, bukan hasil pengujian perangkat lunak atau aplikasi. Fokus penelitian ini adalah pada analisis perilaku model CNN terhadap variasi jumlah data latih.

KESIMPULAN DAN SARAN

Kesimpulan

Berdasarkan hasil dan pembahasan yang telah diuraikan, dapat disimpulkan bahwa variasi jumlah data latih memberikan pengaruh terhadap kinerja model *Convolutional Neural Network* (CNN) pada tugas klasifikasi citra. Melalui eksperimen awal yang dilakukan, terlihat bahwa peningkatan jumlah data latih cenderung diikuti oleh peningkatan akurasi pelatihan dan akurasi pengujian model CNN.

Hasil eksperimen awal menunjukkan bahwa pada jumlah data latih yang kecil, model CNN belum mampu mengenali pola citra secara menyeluruh, yang ditandai dengan perbedaan yang cukup besar antara akurasi pelatihan dan akurasi pengujian. Seiring dengan bertambahnya jumlah data latih, perbedaan tersebut semakin mengecil, menunjukkan bahwa model memperoleh variasi data yang lebih beragam sehingga kinerjanya menjadi lebih stabil.

Selain itu, hasil eksperimen awal juga menunjukkan bahwa peningkatan kinerja model tidak terjadi secara terus-menerus dengan penambahan data latih. Setelah mencapai jumlah data latih tertentu, peningkatan akurasi cenderung melambat. Temuan ini menunjukkan bahwa penentuan jumlah data latih yang tepat merupakan faktor penting dalam pelatihan model CNN, terutama untuk menyeimbangkan antara kinerja model dan efisiensi proses pelatihan.

Eksperimen awal yang dilakukan dalam penelitian ini berfungsi sebagai validasi rancangan metode penelitian dan memberikan gambaran awal mengenai hubungan antara jumlah data latih dan kinerja model CNN pada klasifikasi citra.

Saran

Berdasarkan hasil dan kesimpulan penelitian ini, beberapa saran yang dapat diberikan adalah sebagai berikut:

1. Penelitian selanjutnya disarankan untuk melakukan eksperimen lanjutan dengan dataset yang lebih besar dan lebih beragam guna memperoleh hasil kinerja model CNN yang lebih komprehensif dan representatif.
2. Variasi parameter pelatihan, seperti jumlah *epoch*, *batch size*, dan *learning rate*, dapat dikaji lebih lanjut untuk mengetahui pengaruhnya terhadap kinerja model CNN pada berbagai jumlah data latih.
3. Penelitian berikutnya dapat mengembangkan analisis dengan menggunakan arsitektur CNN yang berbeda untuk membandingkan perilaku model terhadap variasi jumlah data latih.
4. Eksperimen lanjutan juga dapat dilakukan pada jenis data citra yang berbeda untuk menguji konsistensi pengaruh jumlah data latih terhadap kinerja model CNN.

DAFTAR PUSTAKA

- [1] L. Putu Ary Sri Tjahyanti dan Putu Aditya Pratama. “Deteksi Objek Menggunakan Convolutional Neural Network (CNN) pada Pengolahan Citra Digital”. *Jurnal KOMTEKS*, vol. 4, no. 2, pp. 35–40, 2025.
- [2] N. Kasim, M. B. Fadilah, W. Al Hidayat, dan R. A. Saputra. “Klasifikasi Jenis Tanaman Herbal Berdasarkan Citra Menggunakan Metode Convolutional Neural Network (CNN)”. *Jurnal Teknologi dan Informatika*, vol. 19, no. 1, pp. 64–78, 2025.
- [3] D. A. Prastita, A. Setiawan, dan I. F. Ashari. “Analisis Perbandingan Metode Convolutional Neural Network (CNN) untuk Deteksi Warna pada Objek”. *Bulletin of Computer Science Research*, vol. 5, no. 4, pp. 821–830, 2025, <https://doi.org/10.47065/bulletincsr.v5i4.617>.
- [4] A. Penelitian. “Analisis Deep Learning Metode Convolutional Neural Network dalam Klasifikasi Varietas Gandum”. *Jurnal Komputasi dan Sains*, vol. 6, no. 12, pp. 2081–2092, 2023, <https://doi.org/10.56338/jks.v6i12.4938>.
- [5] C. Raras dan A. Widiawati. “Pengaruh Dataset terhadap Performa Convolutional Neural Network pada Klasifikasi X-Ray Pasien Covid-19”. *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 9, no. 6, pp. 1109–1118, 2022, <https://doi.org/10.25126/jtiik.2022965645>.
- [6] A. Alqhfari. “Klasifikasi Citra Mebel Menggunakan CNN”. *Jurnal Teknik dan Teknologi*, vol. 13, no. 2, pp. 50–60, 2025.
- [7] I. R. Kurniawan, I. U. Fakhri, F. A. Cahyadewi, dan F. D. Saputra. “Pengaruh Penambahan Arsitektur Model dalam Klasifikasi Citra Bencana Alam Menggunakan Ensemble Learning”. *Jurnal Sistem Cerdas*, vol. 15, no. 2, pp. 280–289, 2025.
- [8] D. Simanjuntak dan A. Matondang. “Penerapan Transfer Learning untuk Klasifikasi Citra Bunga Berbasis Convolutional Neural Network”. *Jurnal Informatika*, vol. 14, pp. 1062–1067, 2025.
- [9] R. P. Ray. “Analisis Pengaruh Fungsi Aktivasi CNN terhadap Performa Klasifikasi Hewan”. *Incoding: Journal of Informatic and Computer Science Engineering*, vol. 3, pp. 1–10, 2025.
- [10] M. N. Azmi. “Analisis Pengaruh Dimensi Gambar pada Klasifikasi Motif Batik Menggunakan Convolutional Neural Network”. *Jurnal Informatika Batik*, vol. 6, no. 2, pp. 190–198, 2023.
- [11] M. Syawaluddin, S. Susandri, dan A. Zamsuri. “Optimalisasi Model CNN untuk Klasifikasi Citra CIFAR-10 dengan Variasi Rasio Data Latih dan Uji”. *Jurnal Teknologi Komputer*, vol. 8, no. 1, pp. 303–311, 2025.
- [12] N. P. Sari. “Analisis Performa Algoritma CNN dalam Klasifikasi Citra Medis Berbasis Deep Learning”. *Jurnal Deep Learning Indonesia*, vol. 2, no. 2, pp. 87–92, 2025.
- [13] R. Ihza, Y. Vianda, P. Anjarwati, H. A. Pratama, R. M. Akbar, dan R. D. Irawan. “Klasifikasi Citra Bunga Multikelas Menggunakan Convolutional Neural Network (CNN)”. *Jurnal Vision Computing*, vol. 10, pp. 367–376, 2025.
- [14] K. E. N. Ratri, R. Wardani, dan L. Leonardi. “Klasifikasi Penyakit pada Daun Anggur menggunakan Metode Convolutional Neural Network”. *Jurnal Pertanian Digital*, vol. 17, no. 2, pp. 112–126, 2023.
- [15] S. Sahibu dan I. Taufik. “Implementation of the Convolutional Neural Network Algorithm for Classifying Types of Organic and Non-Organic Waste”. *Jurnal Machine Learning dan Sistem Cerdas*, vol. 4, no. 7, pp. 840–852, 2024.
- [16] V. No, J. Hal, A. Nurfitri, R. Munandar, dan A. Fauzan. “Analisis Arsitektur Convolutional Neural Network untuk Klasifikasi Citra Bunga”. *Jurnal Data Citra*, vol. 6, no. 3, pp. 522–531, 2024.

NOMENKLATUR

Σ sigma (perulangan)

BIODATA PENULIS



Niko Surya Atmaja

Penulis merupakan seorang peneliti dan seorang dosen di Politeknik Ganesha di Medan. Memperoleh Gelar Magister Komputer dari Universitas Putra Indonesia YPTK Padang pada tahun 2019.