

Andhika Fajri Raihan Supadi

713 ~ 725 - ID 895 (1)

 Karya Ilmiah Mahasiswa UMBY

Document Details

Submission ID

trn:oid::3618:146580355

Submission Date

Jul 27, 2026, 1:22 PM GMT+7

Download Date

Jul 27, 2026, 1:24 PM GMT+7

File Name

713 ~ 725 - ID 895 (1).docx

File Size

217.2 KB

13 Pages

4,055 Words

27,323 Characters

18% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report

- Bibliography

Top Sources

- 12%  Internet sources
 - 9%  Publications
 - 14%  Submitted works (Student Papers)
-

Top Sources

- 12% Internet sources
- 9% Publications
- 14% Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	Internet	fahruddin.org	2%
2	Student papers	Universitas Islam Riau on 2026-05-13	<1%
3	Student papers	Universitas 17 Agustus 1945 Semarang on 2025-11-12	<1%
4	Student papers	Universitas Islam Riau on 2026-07-06	<1%
5	Student papers	Universitas Sangga Buana YPKP on 2026-07-24	<1%
6	Internet	ejournal.utmj.ac.id	<1%
7	Internet	jer.or.id	<1%
8	Student papers	Universitas Putera Batam on 2026-07-25	<1%
9	Internet	e-journals.unmul.ac.id	<1%
10	Student papers	Universitas Islam Riau on 2026-07-15	<1%
11	Student papers	Fakultas Teknik on 2026-07-10	<1%

12	Publication	Khaidil Aswadi, Supatman Supatman. "SISTEM PENUNJANG KEPUTUSAN PEMILIH...	<1%
13	Student papers	Politeknik Negeri Bandung on 2019-02-18	<1%
14	Student papers	Universitas Budi Luhur on 2026-07-10	<1%
15	Student papers	Universitas Gadjah Mada on 2026-06-02	<1%
16	Publication	Kimberley J. Lewis, Nicole C. Silvester, Steven Barberini-Jammaers, Sammy A. Mas...	<1%
17	Publication	Yiming Zhang, Yunpeng Zhang, Hongzhi Liu, Jiakai Hu, Zhenggang An, Qizheng D...	<1%
18	Internet	ojs.unm.ac.id	<1%
19	Publication	Rizky Arya Kurniawan, Andi Sunyoto, Asro Nasiri. "PENGARUH ARSITEKTUR CONV...	<1%
20	Student papers	Universitas Budi Luhur on 2026-07-24	<1%
21	Student papers	University of East London on 2026-05-07	<1%
22	Internet	cids-sim-doc.readthedocs.io	<1%
23	Internet	text-id.123dok.com	<1%
24	Student papers	UNIVERSITAS BUDI LUHUR on 2026-02-21	<1%
25	Student papers	Universitas Islam Indonesia on 2026-06-15	<1%

26	Student papers	Universitas Maritim Raja Ali Haji on 2025-04-21	<1%
27	Student papers	Universitas Muslim Indonesia on 2025-02-05	<1%
28	Student papers	Universitas Putera Batam on 2026-01-29	<1%
29	Student papers	Universitas Trunojoyo on 2026-07-23	<1%
30	Internet	es.scribd.com	<1%
31	Internet	mmt.its.ac.id	<1%
32	Internet	repository.trisakti.ac.id	<1%
33	Student papers	UPN Veteran Yogyakarta on 2026-05-04	<1%
34	Student papers	Universitas Maritim Raja Ali Haji on 2024-12-20	<1%
35	Student papers	Universitas Negeri Manado on 2025-03-05	<1%
36	Student papers	Universitas Putera Batam on 2026-02-02	<1%
37	Student papers	Universitas Putera Batam on 2026-07-24	<1%
38	Student papers	University of Sydney on 2024-04-12	<1%
39	Internet	core.ac.uk	<1%

40	Internet	doctorpenguin.com	<1%
41	Internet	ejournal.atmajaya.ac.id	<1%
42	Internet	embesmarketing.blogspot.com	<1%
43	Internet	jurnal.polibatam.ac.id	<1%
44	Internet	pcc-global.org	<1%
45	Internet	skripsipedia.wordpress.com	<1%
46	Internet	uisi-repository.sgp1.cdn.digitaloceanspaces.com	<1%
47	Internet	www.ejournal.unma.ac.id	<1%
48	Student papers	Universitas Budi Luhur on 2025-07-15	<1%
49	Publication	Sriani Sriani, Ayu Nabila. "IMPLEMENTASI DEEP LEARNING UNTUK MENGIDENTIFI...	<1%
50	Student papers	Universitas Sangga Buana YPKP on 2026-07-20	<1%
51	Student papers	Universitas Trunojoyo on 2026-07-24	<1%

OPTIMIZATION OF FACIAL IMAGE RESOLUTION ON CONVOLUTIONAL NEURAL NETWORK FOR PRESENCE BIOMETRIC SYSTEMS

Andhika Fajri Raihan Supadi^{1*}, Supatman²

Program Studi Informatika, Universitas Mercu Buana Yogyakarta, Indonesia

andikfjr15@gmail.com^{1*}, supatman@mercubuana-yogya.ac.id²

*Corresponding author

Received June 30, 2026; Revised July 11, 2026; Accepted July 13, 2026; Published July 31, 2026

ABSTRACT

Facial recognition-based biometric systems are widely used in attendance and security applications because they do not require physical contact and are easy to implement on various devices. However, image resolution can affect the accuracy and computation time of facial recognition systems. This study developed a system with varying architectures and input resolutions, namely 512×512 , 256×256 , 128×128 , 64×64 , and 32×32 pixels. The dataset consisted of 480 images, including 240 face images and 240 non-face images. Evaluation was conducted using accuracy and training and testing computation times. The results showed that the 512×512 pixel resolution yielded the highest training accuracy of 55.00%, and the 512×512 -pixel resolution required the longest training time of 504.23 seconds. In testing using new data, the 256×256 pixel resolution demonstrated optimal performance with an accuracy of 72.50% and a computation time of approximately 0.1602 seconds. Based on these results, the 256×256 pixel resolution can be recommended as the preferred choice for implementing a CNN based facial recognition system with limited computational resources.

Keywords: Convolutional Neural Network, face recognition, biometrics, image resolution, computer vision.

ABSTRAK

Sistem biometrik berbasis pengenalan wajah banyak digunakan pada aplikasi presensi dan keamanan karena tidak memerlukan kontak fisik serta mudah diterapkan pada berbagai perangkat. Namun, resolusi citra dapat memengaruhi tingkat akurasi dan waktu komputasi sistem pengenalan wajah. Penelitian membangun sebuah sistem yang memiliki arsitektur dan input resolusi yang bervariasi, yaitu 512×512 , 256×256 , 128×128 , 64×64 dan 32×32 piksel. Dataset yang digunakan terdiri atas 480 citra yang meliputi 240 citra wajah dan 240 citra non-wajah. Evaluasi dilakukan menggunakan akurasi dan waktu komputasi pelatihan dan pengujian. Hasil penelitian menunjukkan bahwa resolusi 512×512 piksel menghasilkan akurasi pelatihan tertinggi sebesar 55,00% dan resolusi 512×512 piksel memerlukan waktu pelatihan terlama yaitu 504,23 detik. Pada pengujian menggunakan data baru, resolusi 256×256 piksel menunjukkan performa yang sesuai dengan akurasi 72,50% dan waktu komputasi sekitar 0,1602 detik. Berdasarkan hasil tersebut, resolusi 256×256 piksel dapat direkomendasikan sebagai pilihan untuk implementasi sistem pengenalan wajah berbasis CNN dengan keterbatasan sumber daya komputasi.

Kata kunci: Convolutional Neural Network, pengenalan wajah, biometrik, resolusi citra, computer vision.

PENDAHULUAN

Saat ini sistem keamanan sudah sangat berkembang, salah satunya adalah sistem biometrik. Sistem biometrik sendiri adalah sistem verifikasi yang mengandalkan identitas

biologis seseorang (Zahra et al., 2024). Sistem biometrik tidak hanya berlaku untuk keamanan saja. Dari banyaknya sistem biometrik yang beredar, sistem yang memiliki fleksibilitas tinggi adalah sistem pengenalan wajah, karena jika dibandingkan dengan metode lain seperti sidik jari dan iris mata tidak perlu melakukan kontak fisik dan bisa digunakan di berbagai kondisi (Setiawan & Tjahyanti, 2024). Banyak aplikasi sudah mengandalkan sistem biometrik berbasis wajah sebagai fitur tambahan untuk memudahkan penggunaannya. Wajah merupakan bagian tubuh manusia yang berguna untuk menunjukkan ekspresi, pengenalan dan juga berkomunikasi (Sigit Guntoro et al., 2022). Sistem biometrik ini sudah banyak diterapkan di keamanan perangkat, absensi, *boarding pass*, dan masih banyak lagi. Oleh sebab itu, saat ini sistem pengenalan wajah lebih banyak dipilih sebagai sistem keamanan atau absensi.

Penggunaan sistem pengenalan wajah terus meningkat pada berbagai bidang seperti sistem presensi, autentikasi perangkat, hingga keamanan layanan digital karena mampu memberikan proses identifikasi tanpa kontak fisik dan lebih praktis dibandingkan metode biometrik lainnya. Penelitian oleh Aisah Lestari et al. (2026) menghasilkan bahwa implementasi sistem presensi mahasiswa berbasis pengenalan wajah menggunakan model FaceNet dengan Convolutional Neural Network (CNN) sebagai backbone mampu menghasilkan tingkat akurasi yang tinggi dalam proses identifikasi pengguna. Hasil tersebut menunjukkan bahwa teknologi pengenalan wajah telah memiliki tingkat keandalan yang baik untuk digunakan pada sistem presensi dengan basis biometrik. Namun demikian, tingginya akurasi sistem juga perlu diimbangi dengan kecepatan komputasi agar dapat diterapkan secara optimal pada perangkat dengan sumber daya yang terbatas. karenanya, diperlukan penelitian lebih lanjut tentang faktor-faktor yang memengaruhi keseimbangan antara akurasi dan kecepatan waktu komputasi, salah satunya adalah pemilihan resolusi citra masukan.

Berdasarkan permasalahan tersebut, penelitian ini menawarkan solusi berupa analisis pengaruh variasi resolusi citra terhadap performa Convolutional Neural Network (CNN) pada sistem pengenalan wajah. Seluruh model dibangun menggunakan arsitektur CNN, parameter pelatihan, proses preprocessing, serta dataset yang sama, sehingga satu-satunya variabel yang dibedakan adalah ukuran resolusi citra masukan. Pendekatan ini memungkinkan pengukuran secara objektif mengenai hubungan antara resolusi citra dengan tingkat akurasi serta waktu komputasi, sehingga dapat diperoleh resolusi yang memberikan keseimbangan terbaik antara ketepatan identifikasi dan efisiensi komputasi.

Pengolahan citra adalah kumpulan cara yang digunakan untuk memperbaiki kualitas gambar sebelum menganalisisnya lebih lanjut (Setiawan & Tjahyanti, 2024). Berdasarkan penelitian ini, pengolahan citra yang dipakai adalah pendekatan *Deep Learning*. *Deep Learning* merupakan cabang dari *machine learning* yang menggunakan *Artificial Neural Network* dengan banyak *hidden layer* untuk mengenali pola dan karakteristik data secara otomatis (Raup et al., 2022). Tidak seperti cara tradisional yang perlu mengambil fitur secara manual, *Deep Learning* bisa belajar fitur secara bertahap langsung dari data yang masuk. Ini membuatnya bisa mengenali pola yang rumit dengan akurasi yang lebih tinggi.

Kemampuan tersebut membuat *Deep Learning* dapat diterapkan pada berbagai bidang pengolahan citra, contohnya klasifikasi citra, deteksi objek, segmentasi, serta sistem pengenalan wajah. Salah satu arsitektur yang sering kali digunakan adalah *Convolutional Neural Network* (CNN).


Penelitian sebelumnya oleh Aisah Lestari et al. (2026) berfokus pada implementasi model FaceNet dengan *Convolutional Neural Network* (CNN) sebagai backbone dan metode KNN untuk sistem presensi mahasiswa berbasis pengenalan wajah, dengan mengevaluasi kemampuan sistem dalam melakukan identifikasi pengguna secara akurat. Namun, penelitian tersebut belum membahas pengaruh variasi resolusi citra masukan terhadap kinerja model, baik dari aspek akurasi maupun efisiensi komputasi. Sementara itu, penelitian Atmawijaya & Radiyah (2024) memanfaatkan FaceNet sebagai komponen autentikasi multi-faktor yang menitikberatkan pada aspek keamanan dan privasi sistem, bukan pada optimasi resolusi citra maupun efisiensi komputasi model. Berbeda dengan penelitian-penelitian tersebut, penelitian ini secara khusus mengevaluasi lima variasi resolusi citra, yaitu 512×512 , 256×256 , 128×128 , 64×64 , dan 32×32 piksel menggunakan arsitektur CNN yang sama untuk menentukan resolusi yang memberikan keseimbangan terbaik antara akurasi dan waktu komputasi pada sistem pengenalan wajah.

Tujuan penelitian ini adalah menganalisis pengaruh variasi resolusi citra terhadap performa *Convolutional Neural Network* (CNN) pada sistem pengenalan wajah berdasarkan dua variabel utama, yaitu tingkat akurasi dan waktu komputasi. Melalui pengujian pada lima variasi resolusi citra (512×512 , 256×256 , 128×128 , 64×64 , dan 32×32 piksel), penelitian ini bertujuan menentukan resolusi citra yang menghasilkan keseimbangan terbaik antara akurasi pengenalan wajah dan efisiensi komputasi sehingga dapat dijadikan acuan dalam pengembangan sistem biometrik berbasis CNN.

METODE PENELITIAN

Penelitian ini menerapkan metode eksperimen dengan pendekatan kuantitatif. Metode eksperimen dipilih karena tujuan penelitian adalah untuk memahami dampak perubahan resolusi gambar terhadap kinerja model *Convolutional Neural Network* (CNN) dalam sistem pengenalan wajah melalui uji yang terstandarisasi. Pendekatan kuantitatif diterapkan karena hasil penelitian diukur dengan data numerik dalam bentuk akurasi dan waktu komputasi yang selanjutnya dianalisis secara objektif.

Penelitian ini menggunakan desain eksperimen satu faktor, yang berarti hanya ada satu variabel bebas dalam eksperimentasi. Dalam studi ini, variabel bebas tersebut adalah resolusi gambar input yang meliputi 512×512 , 256×256 , 128×128 , 64×64 , dan 32×32 piksel, sementara variabel terikatnya adalah kinerja model CNN yang dievaluasi berdasarkan akurasi serta waktu komputasi. Semua variabel lainnya, seperti struktur CNN, parameter pelatihan, tahap preprocessing, jumlah dataset, optimizer, ukuran batch, dan jumlah epoch, tetap konstan agar perbedaan hasil yang didapatkan hanya disebabkan oleh variasi resolusi gambar. Dengan alur penelitian seperti pada gambar 1.



Gambar 1. Diagram Alur Sistem

Eksperimen dilakukan dengan membandingkan hasil kerja model jaringan saraf tiruan konvolusi (CNN) pada berbagai jenis resolusi gambar wajah. *Convolutional Neural Network* (CNN) merupakan pengembangan dari *multilayer perceptron* (MLP) yang merupakan jenis jaringan saraf yang bukan bergerak secara berulang melainkan bergerak maju karena termasuk kedalam *neural network* bertipe *feed forward* (Sriani & Nabila, 2024). CNN dapat memahami rincian citra dengan lebih baik karena mempunyai struktur yang mirip dengan cara otak manusia mengolah informasi visual. Setiap resolusi digunakan sebagai masukan ke model yang sama, sehingga perbedaan hasil kinerjanya dapat dilihat dan dianalisis berdasarkan perubahan ukuran gambar.

Perangkat yang Digunakan

Perangkat lunak yang digunakan dalam mengembangkan sistem adalah google colab dengan spesifikasi seperti pada tabel 1.

Tabel 1. Spesifikasi Perangkat Lunak

Spesifikasi	Keterangan
System Ram	12,7GB
GPU Ram	15.0GB
System Ram	112,6GB

Pengumpulan Dataset

Penelitian ini melakukan proses pengumpulan dataset yang terdiri atas dua kategori citra, yaitu citra wajah dan citra non-wajah. Pengolahan citra sendiri termasuk kedalam

computer vision. *Computer Vision* merupakan kemampuan sebuah mesin untuk melihat atau mengenali gambar, dengan kemampuan yang sama atau bahkan lebih baik daripada penglihatan manusia (Mulya et al., 2023). Dalam sistem keamanan, teknologi ini digunakan untuk pengenalan wajah guna akses kontrol, deteksi objek dan gerakan untuk pemantauan area tertentu, serta analisis perilaku mencurigakan untuk pencegahan kejahatan (Irfansyah et al., 2025). Penggunaan kedua kategori tersebut bertujuan agar model Convolutional Neural Network (CNN) tidak hanya mampu mengenali karakteristik wajah secara mendalam, tetapi juga mampu membedakannya dari objek lain yang bukan termasuk wajah. Pendekatan ini dinilai lebih cocok karena proses pembelajaran model tidak hanya berfokus pada pola visual wajah, melainkan juga mencakup pola visual non-wajah, sehingga model dapat menghasilkan kemampuan klasifikasi yang lebih baik dan lebih general.

Dataset yang digunakan dalam penelitian ini berjumlah 480 citra, yang terdiri atas 240 citra wajah dan 240 citra non-wajah. Data dikumpulkan dari foto orang terdekat peneliti, dengan beberapa kriteria pengambilan gambar, seperti foto dari berbagai angle guna memaksimalkan pelatihan data yang akan digunakan. Mulai dari menghadap kamera, 45° ke kanan dan kiri, 45° ke atas dan ke bawah. Apabila terdapat foto yang tidak sesuai kriteria peneliti akan menggantu foto tersebut dengan foto baru yang lebih sesuai dengan ketentuan. Seluruh data tersebut kemudian dibagi menjadi dua bagian, yaitu data latih (*training data*) dan data uji (*testing data*). Data latih digunakan sebagai dasar dalam membangun dan melatih model CNN, sedangkan data uji digunakan untuk mengukur kemampuan penyamarataan model dalam mengenali data yang belum pernah dipelajari sebelumnya.

Perancangan CNN

Pada penelitian ini, sistem pengenalan wajah dibangun menggunakan metode Convolutional Neural Network (CNN) yang dipilih karena kemampuannya dalam melakukan ekstraksi fitur secara otomatis dari citra masukan tanpa memerlukan proses ekstraksi fitur secara manual. Arsitektur CNN yang digunakan terdiri atas empat lapisan utama, yaitu lapisan konvolusi (Convolutional Layer), lapisan aktivasi (Activation Layer), lapisan penggabungan (Pooling Layer), dan lapisan terhubung penuh (Fully Connected Layer) (Azmi et al., 2023).

Evaluasi Model

Pada tahap ini, penelitian membangun lima skenario CNN dengan arsitektur dan parameter pelatihan yang sama, namun menggunakan variasi resolusi citra yaitu 512×512, 256×256, 128×128, 64×64 dan 32×32 piksel. Setiap model diuji menggunakan data testing untuk memperoleh nilai akurasi dan waktu komputasi. Performa model dievaluasi dengan rumus akurasi, precision, recall, dan F1-Score.

1. Menghitung Akurasi

$$\text{accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\%$$

Keterangan :

TP (True Positive) = wajah dikenali sebagai wajah.

TN (True Negative) = non-wajah dikenali sebagai non-wajah.

FP (False Positive) = non-wajah dikenali sebagai wajah.

FN (False Negative) = wajah dikenali sebagai non-wajah.

2. Menghitung Precision

$$Precision = \frac{TP}{TP + FP}$$

Keterangan :

TP (True Positive) = wajah dikenali sebagai wajah.

FP (False Positive) = non-wajah dikenali sebagai wajah.

3. Menghitung Recall

$$Precision = \frac{TP}{TP + FN}$$

Keterangan :

TP (True Positive) = wajah dikenali sebagai wajah.

FN (False Negative) = wajah dikenali sebagai non-wajah.

4. Menghitung F1-Score

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Keterangan :

Precision = tingkat ketepatan model dalam mengklasifikasikan citra sebagai wajah.

Recall = kemampuan model dalam menemukan seluruh citra wajah yang sebenarnya.

5. Menghitung Waktu Komputasi

$$Traning\ time = T_{End} - T_{start}$$

Keterangan:

T_{start} = waktu mulai pelatihan.

T_{end} = waktu selesai pelatihan.

Skenario Pengujian

Pengujian dilakukan dengan mengevaluasi delapan skenario yang menggunakan resolusi citra berbeda. Seluruh skenario menggunakan arsitektur, parameter pelatihan, jumlah data, dan proses *preprocessing* yang sama. Variabel yang dibedakan pada penelitian ini hanyalah ukuran resolusi citra masukan. Seluruh model menggunakan parameter dan konfigurasi pelatihan secara sama yang memberikan hasil evaluasi dapat dibandingkan secara adil. Kinerja setiap model kemudian dievaluasi berdasarkan akurasi, waktu pelatihan, dan waktu pengujian. Melalui evaluasi ini, akan diketahui resolusi citra

yang memberikan keseimbangan optimal antara akurasi dan kecepatan komputasi dalam deteksi wajah menggunakan CNN (Nugroho & Yulia, 2021; Rumapea, 2025).

Tabel 2. Tabel Skenario Pengujian

Skenario	Model	Resolusi Citra
Skenario-1	CNN	512×512
Skenario-2	CNN	256×256
Skenario-3	CNN	128×128
Skenario-4	CNN	64×64
Skenario-5	CNN	32×32

Pada tabel 2 dijelaskan bahwa perbedaan dalam resolusi gambar berpengaruh pada jumlah informasi visual yang dapat diproses oleh model CNN. Gambar yang memiliki resolusi lebih tinggi biasanya menyimpan lebih banyak detail yang dapat membantu model dalam mengambil fitur-fitur penting, seperti tekstur, bentuk, dan pola wajah. Namun, semakin besar ukuran gambarnya, semakin tinggi juga permintaan komputasi, konsumsi memori, dan waktu yang dibutuhkan selama pelatihan serta pengujian. Di sisi lain, menggunakan resolusi lebih rendah dapat mempercepat proses komputasi, namun dapat mengakibatkan hilangnya informasi visual yang diperlukan oleh model, sehingga dapat mempengaruhi tingkat akurasi klasifikasinya (Setia Budi et al., 2024).

HASIL DAN PEMBAHASAN

Pelatihan CNN

Pelatihan model Convolutional Neural Network (CNN) dilakukan menggunakan delapan variasi resolusi citra, yaitu 512×512 , 256×256 , 128×128 , 64×64 dan 32×32 piksel. Setiap model dilatih menggunakan parameter yang sama, yaitu optimizer Adam, batch size 16, dan jumlah epoch sebanyak 200. Tujuan pengujian ini adalah untuk mengetahui perbedaan resolusi citra terhadap kemampuan model dalam proses pengenalan wajah. Total data yang digunakan untuk melatih model terdapat 480 gambar yang dibagi menjadi 2 kelas yaitu kelas face (240 gambar) dan non_face (240 gambar).

Tabel 3. Tabel hasil pelatihan CNN

Resolusi	Akurasi (%)	Training Time (detik)
512×512	55.00%	504.23 detik
256×256	51.11%	339.12 detik
128×128	48.89%	55.49 detik
64×64	52.22%	35.39 detik
32×32	50.00%	22.49 detik


Berdasarkan tabel 3, dari sisi waktu pelatihan, resolusi 512×512 piksel membutuhkan waktu training paling lama yaitu 504,23 detik. Sebaliknya, resolusi 32×32 piksel memiliki waktu pelatihan tercepat yaitu 22,49 detik. Penurunan waktu pelatihan

terjadi karena semakin kecil ukuran citra maka jumlah piksel yang diproses oleh layer konvolusi juga semakin sedikit sehingga beban komputasi menjadi lebih ringan.

Secara umum, hasil pelatihan menunjukkan adanya hubungan antara resolusi citra dan waktu komputasi. Semakin kecil ukuran resolusi citra yang digunakan, semakin singkat waktu pelatihan model CNN. Pada penelitian ini, model dengan resolusi 512×512 piksel memerlukan waktu pelatihan paling lama, sedangkan model dengan resolusi 32×32 piksel menunjukkan waktu pelatihan paling singkat. Hal ini terjadi karena peningkatan ukuran resolusi menyebabkan jumlah piksel yang diproses oleh setiap lapisan konvolusi semakin besar, sehingga beban komputasi dan jumlah operasi yang dilakukan selama proses ekstraksi fitur juga meningkat.

Hasil tersebut searah dengan penelitian Simatupang (2025) yang menjelaskan bahwa meskipun algoritma Convolutional Neural Network (CNN) mampu meningkatkan akurasi sistem pengenalan wajah secara signifikan, kebutuhan komputasi yang tinggi masih menjadi salah satu tantangan utama dalam implementasinya. Penelitian tersebut menyatakan bahwa model deep learning memerlukan sumber daya komputasi yang besar sehingga optimalisasi efisiensi komputasi masih menjadi fokus penelitian lanjutan. Dengan demikian, penggunaan resolusi citra yang sesuai dapat menjadi salah satu alternatif untuk menekan beban komputasi tanpa harus mengubah arsitektur model CNN.

Analisis Akurasi Model



Gambar 2. Grafik Akurasi Training & Testing Model

Berdasarkan hasil pelatihan, nilai akurasi tertinggi diperoleh pada resolusi 512×512 piksel dengan nilai sebesar 55,00%, sedangkan akurasi terendah diperoleh pada resolusi 128×128 piksel sebesar 48,89%. Hasil ini menunjukkan bahwa resolusi citra memberikan perubahan terhadap kemampuan CNN dalam melakukan ekstraksi fitur wajah. Resolusi 512×512 mampu menjaga informasi penting seperti mata, hidung, mulut, dan kontur wajah sehingga fitur yang dipelajari oleh CNN masih cukup bisa untuk membedakan citra wajah dan non-wajah. Selain itu, jumlah piksel yang tidak terlalu besar membuat proses pembelajaran menjadi lebih cepat sehingga model dapat melakukan penyamarataan dengan lebih baik. Sebaliknya, pada resolusi yang sangat rendah seperti 32×32 piksel, sebagian besar detail wajah mengalami kehilangan informasi (information

loss). Akibatnya, fitur-fitur penting yang dibutuhkan CNN tidak dapat diekstraksi secara optimal sehingga akurasi mengalami penurunan.

Variasi resolusi citra terhadap performa Convolutional Neural Network (CNN) pada sistem pengenalan wajah. Penelitian terdahulu yang dilakukan oleh Marvelino Wijaya & Eric Samodra (2023) berhasil mengembangkan sistem presensi berbasis face recognition menggunakan CNN dengan akurasi sebesar 92,5% dan waktu deteksi 60–66 milidetik, serta menyimpulkan bahwa CNN mampu memberikan performa yang baik untuk pengenalan wajah secara real-time. Namun, penelitian tersebut berfokus pada implementasi sistem dan peningkatan kualitas dataset melalui variasi pose wajah serta kondisi pencahayaan, tanpa mengevaluasi pengaruh ukuran resolusi citra yang digunakan sebagai masukan model.

Oleh sebab itu, studi ini mengatasi celah yang ada dengan melakukan analisis sistematis terhadap berbagai variasi resolusi gambar menggunakan arsitektur CNN, parameter pelatihan, prosedur preprocessing, dan dataset yang serupa. Dengan cara ini, satu-satunya faktor yang berbeda adalah ukuran resolusi gambar sehingga dampaknya terhadap akurasi dan waktu komputasi bisa dievaluasi secara objektif. Metode ini memberikan kontribusi baru dengan mengidentifikasi ukuran resolusi gambar yang dapat menciptakan keseimbangan terbaik antara akurasi dalam pengenalan wajah dan efisiensi dalam komputasi. Hasil dari penelitian ini diharapkan dapat menjadi panduan dalam menentukan resolusi gambar yang paling baik untuk pengembangan sistem pengenalan wajah berbasis CNN, yang mana hal tersebut belum dibahas dengan detail dalam penelitian sebelumnya.

Penelitian ini secara khusus mengevaluasi pengaruh variasi resolusi citra terhadap performa Convolutional Neural Network (CNN) dengan menjaga seluruh variabel eksperimen tetap sama, meliputi arsitektur model, parameter pelatihan, proses preprocessing, dan dataset. Dengan demikian, perubahan performa yang diamati benar-benar disebabkan oleh perbedaan resolusi citra sehingga hubungan antara resolusi, akurasi, dan waktu komputasi dapat dianalisis secara lebih objektif. Berbeda dengan penelitian terdahulu yang lebih berfokus pada pengembangan sistem pengenalan wajah, peningkatan akurasi, atau penerapan CNN pada berbagai aplikasi, penelitian ini mengidentifikasi resolusi citra yang memberikan keseimbangan terbaik antara kualitas pengenalan wajah dan efisiensi komputasi. Temuan ini memperluas kajian mengenai optimasi masukan (*input optimization*) pada sistem pengenalan wajah berbasis CNN yang masih relatif jarang dibahas dalam penelitian-penelitian sebelumnya (Setiawan & Tjahyanti, 2024; Rumapea, 2025).

Penelitian ini memberikan kontribusi sederhana bagi pengembangan sistem biometrik berbasis pengenalan wajah, khususnya dalam menentukan resolusi citra yang sesuai sebelum proses pelatihan maupun implementasi model CNN. Berdasarkan pengujian, resolusi 256×256 piksel dapat menghasilkan keseimbangan terbaik antara akurasi dan waktu komputasi sehingga berpotensi diterapkan pada sistem presensi, autentikasi pengguna, pengendalian akses, maupun perangkat *embedded* yang memiliki keterbatasan sumber daya komputasi. Selain meningkatkan efisiensi penggunaan memori

dan waktu pemrosesan, pemilihan resolusi yang optimal juga dapat mendukung pengembangan sistem pengenalan wajah yang lebih responsif tanpa memerlukan perubahan arsitektur CNN. Oleh karena itu, temuan penelitian ini dapat acuan dalam perancangan sistem biometrik berbasis *deep learning* yang lebih efektif dan efisien (Simatupang, 2025; Atmawijaya & Radiyah, 2024; Rumapea, 2025).

Analisis Waktu Komputasi




Gambar 3. Grafik Waktu Komputasi Training Model


Berdasarkan hasil pengujian, waktu pelatihan meningkat seiring bertambahnya ukuran resolusi citra. Resolusi 512×512 membutuhkan waktu pelatihan paling lama yaitu 504.23 detik, sedangkan resolusi 32×32 membutuhkan waktu pelatihan tercepat yaitu 22,49 detik. Hal ini terjadi karena semakin besar resolusi citra maka jumlah piksel yang harus diproses oleh layer konvolusi juga semakin banyak. Akibatnya, jumlah operasi matematis yang dilakukan CNN meningkat sehingga waktu pelatihan menjadi lebih lama. Sebaliknya, citra dengan resolusi rendah memiliki jumlah piksel yang lebih sedikit sehingga proses ekstraksi fitur dan pembelajaran model dapat dilakukan dengan lebih cepat.

Hasil Pengujian Data

Setelah proses pelatihan selesai, setiap model diuji menggunakan citra baru yang tidak termasuk dalam data pelatihan. Pengujian dilakukan untuk mengetahui kemampuan model dalam melakukan klasifikasi wajah dan non-wajah pada kondisi nyata.



Gambar 4. Grafik Akurasi Training & Testing Model



Gambar 5. Grafik Waktu Komputasi Testing Model

Berdasarkan hasil uji coba, resolusi 256×256 piksel menunjukkan kinerja terbaik dibandingkan dengan resolusi lainnya karena dapat menciptakan keseimbangan antara kualitas visual dan efisiensi dalam pengolahan. Saat menggunakan resolusi yang lebih tinggi, seperti 512×512 piksel, jumlah piksel yang diolah menjadi jauh lebih banyak, yang berakibat pada peningkatan beban komputasi dan waktu pelatihan yang dibutuhkan. Meskipun informasi visual yang diperoleh menjadi lebih kaya, tambahan tersebut tidak selalu secara signifikan meningkatkan kemampuan model dalam mengenali pola wajah. Sebaliknya, pada resolusi yang lebih rendah, seperti 128×128 , 64×64 , dan 32×32 piksel, kecepatan proses komputasi meningkat, tetapi beberapa rincian wajah mulai hilang karena proses downsampling. Hal ini menyebabkan informasi krusial, seperti tekstur halus, kontur wajah, dan ciri lokal, tidak lagi terwakili dengan baik, sehingga kemampuan CNN dalam mengekstraksi fitur menjadi berkurang.

Resolusi 256×256 piksel memberikan informasi yang cukup lengkap untuk melakukan ekstraksi fitur sambil tetap menjaga performa komputasi. Dalam ukuran ini, lapisan konvolusi dapat mengenali pola-pola penting dari wajah tanpa perlu menangani informasi visual yang berlebihan seperti pada resolusi 512×512 piksel. Oleh karena itu, model dapat membuat representasi fitur yang lebih konsisten, mencapai tingkat akurasi yang lebih tinggi, serta mengurangi waktu pelatihan dibandingkan dengan resolusi yang lebih besar atau lebih kecil. Temuan ini menyoroti bahwa peningkatan dalam resolusi citra tidak selalu berhubungan langsung dengan peningkatan kinerja model, melainkan terdapat resolusi optimal yang memberikan keseimbangan terbaik antara kualitas ekstraksi fitur dan kecepatan komputasi.

KESIMPULAN

Penelitian ini berfokus menguji resolusi citra dan waktu komputasi CNN pada sistem identifikasi wajah. Sebanyak 480 gambar (360 wajah, 120 bukan wajah) dilatih melalui delapan tingkat resolusi, mulai dari 512×512 hingga 32×32 piksel. Ketika diuji dengan data baru, resolusi 256×256 piksel menunjukkan keseimbangan optimal antara akurasi (72,50%) dan kecepatan identifikasi (sekitar 0,1602 detik). Oleh karena itu, resolusi ini disarankan sebagai pilihan terbaik untuk digunakan dalam sistem pengenalan wajah yang menggunakan CNN, terutama pada perangkat dengan kemampuan komputasi terbatas yang membutuhkan pengenalan wajah berjalan cepat. Penelitian ini juga berkontribusi dalam pengembangan sistem biometrik karena menunjukkan bahwa

memilih resolusi gambar yang tepat bisa meningkatkan efisiensi penghitungan tanpa mengurangi performa model secara signifikan. Temuan ini bisa digunakan sebagai dasar dalam membuat berbagai aplikasi biometrik, seperti sistem absensi, pengendalian akses, keamanan, serta pengenalan pengguna pada perangkat mobile atau sistem yang terpasang (*embedded systems*) yang memiliki keterbatasan pada sumber daya yang dimiliki. Untuk penelitian berikutnya, sebaiknya diperluas jumlah dan variasi data yang digunakan, serta diuji dalam kondisi nyata seperti perubahan cahaya, sudut kamera, penghalang, dan ekspresi wajah. Selain itu, bisa juga digunakan arsitektur CNN yang lebih canggih atau model berbasis transfer learning untuk meningkatkan akurasi, kemampuan menerapkan di berbagai situasi, serta keandalan sistem pengenalan wajah.

REFERENSI

- Atmawijaya, R., & Radiyah, U. (2024). Perancangan Autentikasi Multi Faktor dengan Pengenalan Wajah dan Fido (Fast Identity Online). *INTI Nusa Mandiri*, 19(1), 46–53. <https://doi.org/10.33480/inti.v19i1.5263>
- Azmi, K., Defit, S., & Putra Indonesia YPTK Padang Jl Raya Lubuk Begalung-Padang-Sumatera Barat, U. (2023). Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat. *Jurnal Unitek*, 16(1), 28–40. <https://doi.org/10.52072/unitek.v16i1.504>
- Irfansyah, D., Ruseno, N., & Yani, A. (2025). Penerapan Computer Vision dalam Sistem Keamanan Berbasis Artificial Intelligence (AI), Robotik, dan Otomatisasi. *Jurnal Pasti*, 1(1), 40–47. <https://doi.org/10.9001/jurnalpasti.v1i1.920>
- Maliki, Aisah Lestari, L., Rizal, K., Hidayat, R., & Susliansyah. (2026). Implementasi Sistem Presensi Mahasiswa Berbasis Pengenalan Wajah Menggunakan Model Facenet (CNN Backbone) dan Metode KNN. *Jurnal Sistem Informasi Dan Sistem Komputer*, 11(1). <https://doi.org/10.51717/simkom.v11i1.1217>
- Marvelino Wijaya, A., & Eric Samodra, J. (2023). Sistem Presensi Pegawai dengan Face Recognition Menggunakan Deep Learning CNN. *Jurnal Informatika Atma Jogja*, 4(2), 163–168. <https://doi.org/10.24002/jiaj.v4i2.7660>
- Mulya, M. A., Zaenul Arif, & Syefudin. (2023). Tinjauan Pustaka Sistematis: Penerapan Metode Gabor Wavelet Pada Computer Vision. *Journal Of Computer Science and Technology (JOCSTEC)*, 1(2), 83–88. <https://doi.org/10.59435/jocstec.v1i2.78>
- Nugroho, B., & Yulia, E. (2021). Kinerja Metode CNN untuk Klasifikasi Pneumonia dengan Variasi Ukuran Citra Input. 8(3), 533–538. <https://doi.org/10.25126/jtiik.202184515>
- Raup, A., Ridwan, W., Khoeriyah, Y., & Yuliati Zaqiah, Q. (2022). Deep Learning dan Penerapannya dalam Pembelajaran. *Jurnal Ilmiah Ilmu Pendidikan*, 5(9), 3258–3267. <https://doi.org/10.54371/jiip.v5i9.805>
- Rumapea, H. (2025). Evaluasi Kinerja CNN dan Vision Transformer pada Klasifikasi Citra Resolusi Tinggi Berbasis Deep Learning. *METHOMIKA Jurnal Manajemen Informatika dan Komputerisasi Akuntansi*, 9(2), 372–379. <https://doi.org/10.46880/jmika.Vol9No2.pp372-379>

- Setia Budi, E., Nofriyaldi Chan, A., Priscillia Alda, P., & Arif Fauzi Idris, M. (2024). Optimasi Model Machine Learning untuk Klasifikasi dan Prediksi Citra Menggunakan Algoritma Convolutional Neural Network. *Media Online*, 4(5), 502–509. <https://doi.org/10.30865/resolusi.v4i5.1892>
- Setiawan, N. Y., & Tjahyanti, L. P. S. (2024). Optimasi Sistem Pengenalan Wajah Dengan Teknik Pengolahan Citra untuk Meningkatkan Akurasi dan Efisiensi. *Jurnal Komputer Dan Teknologi Sains (KOMTEKS)*, 3(1), 18–22. <https://doi.org/10.37637/komteks.v3i1.2294>
- Sigit Guntoro, A. L., Julianto, E., & Budiyanto, D. (2022). Pengenalan Ekspresi Wajah Menggunakan Convolutional Neural Network. *Jurnal Informatika Atma Jogja*, Vol. 3(2), 155–160. <https://doi.org/10.24002/jiaj.v3i2.6790>
- Simatupang, A. P. (2025). Penerapan Algoritma Deep LeaRNINg dalam Pengenalan Wajah Untuk Sistem Keamanan. *JITIFNA: Jurnal Ilmu Teknologi Informasi Indonesia*, Vol. 1(1), 7–12. <https://doi.org/https://doi.org/10.70134/jitifna.v1i1.741>
- Sriani, S., & Nabila, A. (2024). Implementasi Deep Learning untuk Mengidentifikasi Umur Manusia Menggunakan Convolutional Neural Network (CNN). *Jurnal Informatika dan Teknik Elektro Terapan*, 12(3), 1836–1843. <https://doi.org/10.23960/jitet.v12i3.4457>
- Zahra, N., Hapsari, R. A., & Safitri, M. (2024). Perlindungan Hukum Teknologi Identitas Digital Melalui Sistem Verifikasi Identitas Berbasis Biometrik. *Jurnal Pemikiran Dan Penelitian Ilmu-Ilmu Sosial, Hukum, & Pengajarannya*, Vol. 19(1), 86–98. <https://doi.org/10.26858/supremasi.v19i1.51062>