

IMPLEMENTASI METODE HAARCASCADE CLASSIFIER DALAM MENGIDENTIFIKASI OBJEK WAJAH MANUSIA

Haikal Farhan Ramadhan, Kana Saputra S, Said Iskandar Al Idrus, Zulfahmi Indra, Insan Taufik

Ilmu Komputer, Universitas Negeri Medan

Jalan Willem Iskandar, Pasar V Medan Estate, Percut Sei Tuan, Deli Serdang, Sumatera Utara, Indonesia

haikalf512@gmail.com

ABSTRAK

Keamanan menjadi aspek esensial dalam berbagai sektor, terutama pada era teknologi modern yang menuntut sistem pengamanan canggih. Salah satu inovasi dalam identifikasi dan autentikasi adalah pengenalan wajah, metode yang andal, tidak invasif, dan sesuai berbagai konteks. Dalam penelitian ini, algoritma Haar Cascade Classifier dan arsitektur jaringan saraf Inception V3 digunakan untuk meningkatkan efisiensi serta akurasi pengenalan wajah. Penelitian ini merespons tiga permasalahan utama, yaitu kebutuhan sistem keamanan modern, kendala akurasi, dan keandalan teknologi pengenalan wajah saat ini. Penelitian bertujuan menganalisis kemampuan dan kinerja Haar Cascade Classifier dalam mendeteksi wajah dengan variasi pose, serta mengoptimalkan implementasinya untuk memenuhi kebutuhan aplikasi dunia nyata. Metodologi meliputi pengumpulan data berupa citra wajah, pra-pemrosesan data (normalisasi piksel, augmentasi data, segmentasi wajah), serta pemisahan dataset untuk pelatihan (80%) dan pengujian (20%). Proses implementasi melibatkan Haar Cascade Classifier untuk deteksi wajah dan arsitektur Inception V3 untuk pengenalan wajah. Hasil evaluasi menunjukkan bahwa dengan learning rate $10e-4$, model mencapai akurasi 100%, jauh lebih tinggi dibandingkan learning rate $10e-6$ yang hanya mencapai akurasi 56%.

Kata kunci : Pengolahan Citra, Pengenalan Wajah, Deteksi Wajah

1. PENDAHULUAN

Keamanan memiliki peran fundamental dalam berbagai aspek kehidupan, baik dalam lingkup individu maupun institusi. Dengan berkembangnya teknologi, kebutuhan akan sistem pengamanan yang lebih canggih semakin meningkat, terutama dalam hal identifikasi dan autentikasi yang akurat, yang menjadi komponen utama dalam strategi perlindungan modern. Dalam konteks ini, teknologi pengenalan wajah menawarkan solusi non-invasif yang inovatif dan memiliki potensi luas untuk diterapkan dalam berbagai lingkungan dan keperluan [1].

Sebagai salah satu metode *biometrik* yang didasarkan pada karakteristik fisiologis, wajah memiliki sifat unik seperti bentuk, pola mata, dan tekstur kulit, yang memungkinkan identifikasi individu secara akurat. Perkembangan pesat dalam bidang ini didorong oleh kemajuan teknologi pengolahan citra serta kecerdasan buatan [2]. Dalam pengenalan wajah, proses pengolahan citra berperan penting dengan menganalisis fitur-fitur utama melalui teknik seperti penghalusan dan deteksi tepi, yang bertujuan untuk meningkatkan tingkat akurasi dalam identifikasi [3].

Haarcascade Classifier merupakan salah satu algoritma deteksi wajah yang banyak digunakan karena berbasis fitur *Haar*, yang memungkinkan identifikasi pola visual melalui analisis distribusi intensitas cahaya pada gambar. Efektivitasnya telah diuji dalam berbagai penelitian, termasuk penelitian yang dilakukan oleh Prathivi dan Kurniawati, yang mendapatkan hasil bahwa sistem presensi berbasis pengenalan wajah yang menggunakan algoritma ini mencapai akurasi sebesar 75%. [4]. Penelitian yang

dilakukan oleh Mulyana mendapatkan akurasi 80% untuk absensi di Yayasan Pusat Pengembangan Anak [5], sementara Ramadini dan Haryatmi dalam penelitian nya mencapai akurasi 88,42% pada pengenalan wajah secara real-time menggunakan kombinasi *Haar Cascade* dan *LBPH* [6].

Penelitian ini bertujuan untuk mengeksplorasi penerapan *Haarcascade Classifier* dan *Convolutional Neural Network* (CNN), terutama dengan arsitektur *Inception V3*, dalam sistem pengenalan wajah. Studi ini diharapkan dapat memberikan pemahaman yang lebih komprehensif mengenai kelebihan serta keterbatasan *Haarcascade Classifier*, sekaligus meningkatkan efisiensi dan akurasi dalam proses identifikasi wajah

2. TINJAUAN PUSTAKA

2.1. Wajah Manusia

Wajah merupakan salah satu karakteristik identitas yang digunakan untuk mengenali individu, sebagaimana metode *biometrik* lainnya seperti suara, sidik jari, retina, dan tanda tangan [7]. Sebagai bagian dari tubuh manusia, wajah memiliki peran sentral dalam interaksi sosial, memungkinkan ekspresi identitas dan emosi. Dengan fitur unik seperti mata, hidung, dan mulut, wajah tidak hanya memfasilitasi komunikasi verbal dan non-verbal yang kompleks, tetapi juga berkontribusi secara signifikan dalam proses identifikasi individu [8].

2.2. Pengenalan Wajah

Metode pengenalan wajah yang paling umum didasarkan pada analisis karakteristik fisik serta posisi relatif dari berbagai atribut wajah, seperti mata, alis,

hidung, bibir, dan dagu. Selain itu, pendekatan ini juga mencakup evaluasi wajah secara keseluruhan, di mana wajah dianggap sebagai kombinasi dari beberapa pola wajah standar untuk meningkatkan akurasi identifikasi [9].

Konsep utama dalam sistem pengenalan wajah adalah melakukan perbandingan antara citra wajah yang diinput dengan *database* wajah yang telah tersedia, lalu mencocokkan data untuk memperoleh hasil identifikasi yang paling akurat. Namun, terdapat beberapa faktor yang dapat mempengaruhi kinerja sistem, seperti pencahayaan yang tidak merata, variasi ekspresi wajah, serta perubahan atribut fisik seperti pertumbuhan janggut, kumis, atau penggunaan kacamata, yang dapat mengubah struktur visual wajah dan mengurangi tingkat akurasi [10].

2.3. Haarcascade Classifier

Metode Viola-Jones, yang lebih dikenal sebagai *Haarcascade*, memiliki reputasi sebagai teknik deteksi citra yang akurat, cepat, dan efisien, terutama dalam pengenalan wajah. Pendekatan ini bekerja dengan mengklasifikasikan citra berdasarkan pola yang telah ada dalam *dataset*, memungkinkan identifikasi wajah secara efektif melalui analisis fitur visual yang telah ditentukan sebelumnya [11]. Salah satu kelebihan utama dari metode ini adalah efisiensi komputasi yang tinggi, karena prosesnya hanya bergantung pada jumlah piksel dalam suatu area persegi, tanpa perlu menganalisis setiap nilai piksel individu dalam gambar. Hal ini memungkinkan deteksi yang lebih cepat dan optimal dalam penerapan pengenalan wajah. [12].

a. Haar Feature

Fitur *Haar* merupakan teknik perhitungan yang diterapkan dalam area berbentuk persegi panjang yang saling berdekatan dalam jendela deteksi. Metode ini bekerja dengan menjumlahkan intensitas piksel di setiap wilayah dan menganalisis perbedaan nilai intensitasnya, sehingga mampu mengidentifikasi pola visual dengan tingkat efisiensi yang tinggi.

b. Integral Image

Integral Image meningkatkan efisiensi perhitungan fitur *Haar* dengan membentuk sub-persegi panjang dan menetapkan referensi array untuk masing-masing wilayah tersebut. Pendekatan ini menggantikan proses perhitungan langsung pada setiap piksel, sehingga mempercepat analisis dan ekstraksi fitur *Haar* dalam deteksi citra secara signifikan.

c. Adaboost

Adaboost berfungsi untuk mengidentifikasi fitur-fitur yang paling relevan dan melatih klasifier agar dapat memanfaatkannya secara optimal. Metode ini bekerja dengan menggabungkan sejumlah klasifier lemah, yang secara individu memiliki performa terbatas, untuk membentuk klasifier kuat yang mampu meningkatkan akurasi deteksi objek secara signifikan.

2.4. Deep Learning

Deep Learning merupakan metode pembelajaran yang menggunakan jaringan saraf tiruan berlapis-lapis (*multi-layer neural networks*) untuk memproses data secara kompleks. Teknik ini, yang juga dikenal sebagai *deep structured learning*, *hierarchical learning*, atau *deep neural learning*, bekerja dengan menerapkan transformasi non-linear melalui serangkaian lapisan tersembunyi guna mengekstrak pola dari data. Dalam konteks kecerdasan buatan, *Deep learning* dapat dianggap sebagai perpaduan antara *machine learning* dan *artificial intelligence*, karena mampu melakukan pemrosesan data secara adaptif dan menghasilkan representasi fitur dengan tingkat abstraksi yang lebih tinggi [13].

2.5. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan arsitektur jaringan saraf yang sangat efektif dalam memproses serta memahami citra secara mendalam. Proses pembelajarannya mengikuti *training loop*, yang terdiri dari beberapa tahap utama, yaitu *feed forward*, perhitungan error, *backpropagation*, serta pembaruan bobot menggunakan *optimizer*. Setiap kali seluruh dataset diproses dalam satu siklus *training loop*, hal tersebut disebut sebagai *epoch*. Jika akurasi hasil pelatihan sudah memuaskan, proses *fine-tuning* mungkin tidak diperlukan, meskipun eksperimen tambahan tetap bisa dilakukan guna meningkatkan akurasi lebih lanjut [14].

2.6. Arsitektur Inception V3

Inception V3 merupakan arsitektur jaringan saraf konvolusi (CNN) yang dikembangkan oleh tim peneliti Google pada tahun 2015 sebagai evolusi dari *Inception V1* dan *Inception V2*. Model ini dirancang untuk meningkatkan efisiensi komputasi sekaligus mengoptimalkan kinerja dalam pengenalan gambar. Efektivitasnya telah dibuktikan dalam berbagai tugas seperti klasifikasi gambar, deteksi objek, serta segmentasi gambar [14]. Selain itu, arsitektur ini mendukung komputasi berkinerja tinggi dengan memanfaatkan matriks padat, sehingga memungkinkan pemrosesan yang lebih optimal terhadap beragam fitur spasial. [15].


3. METODE PENELITIAN

Proses penelitian dalam melakukan identifikasi objek wajah manusia dengan menggunakan metode *haarcascade classifier* dan CNN adalah sebagai berikut.

3.1. Pengumpulan Data

Pada tahap ini, dilakukan pengumpulan *dataset* wajah manusia yang diperlukan untuk proses pelatihan dan pengujian model. Keberadaan *dataset* yang komprehensif sangat penting untuk memastikan bahwa model mampu mengenali wajah dengan akurasi tinggi dalam berbagai kondisi. *Dataset* yang

digunakan terdiri dari wajah 20 individu mahasiswa Ilmu Komputer stambuk 20, yang diambil melalui posisi *selfie* dengan jarak minimal 40 cm dan maksimal 60 cm dari kamera, guna menjaga konsistensi dalam pencitraan.



Gambar 1. Tahapan Penelitian

3.2. Preprocessing Data

Tahap ini mencakup serangkaian teknik yang bertujuan untuk mempersiapkan data sebelum digunakan dalam pelatihan model. Proses pra-pemrosesan meliputi normalisasi intensitas piksel guna mengurangi variabilitas pencahayaan, resizing gambar agar memiliki dimensi yang seragam, augmentasi data untuk meningkatkan variasi dataset, serta segmentasi wajah agar model dapat fokus pada fitur yang paling relevan. Setelah augmentasi data selesai dilakukan, proses berikutnya adalah deteksi wajah dengan menerapkan *Haarcascade Classifier*, yang berfungsi untuk mengidentifikasi wajah pada setiap gambar yang telah dikumpulkan, sehingga memastikan bahwa model bekerja dengan data yang telah disaring dan dioptimalkan.

3.3. Data Splitting

Dataset yang telah melalui proses pra-pemrosesan kemudian dipisahkan menjadi dua *subset*, yaitu data pelatihan (*training set*) dan data pengujian (*testing set*) atau validasi. Dalam penelitian ini, pembagian data dilakukan dengan rasio 80:20, di mana 80% *dataset* digunakan untuk melatih model, sedangkan 20% sisanya digunakan untuk menguji dan mengevaluasi kinerja model guna memastikan tingkat akurasi dan generalisasi yang optimal.

3.4. Implementasi Haarcascade Classifier dan CNN

Tahap ini mencakup penerapan *Haarcascade Classifier* untuk deteksi wajah dalam citra serta penggunaan *Inception V3* sebagai arsitektur jaringan saraf untuk pengenalan individu berdasarkan wajah. Implementasi *Haarcascade Classifier* terdiri dari beberapa langkah, yaitu inisialisasi klasifier, pelatihan dengan dataset pelatihan, serta pengujian menggunakan dataset pengujian guna memastikan keakuratan sistem deteksi wajah. Sementara itu, *Inception V3* diterapkan dengan membangun arsitektur jaringan saraf yang sesuai, melatih model menggunakan *dataset* pelatihan, dan mengujinya dengan dataset pengujian, sehingga sistem mampu mengenali individu berdasarkan karakteristik wajah dengan tingkat presisi yang optimal[16].

3.5. Evaluasi Model

Tahap evaluasi dilakukan dengan menerapkan fungsi kerugian (*loss function*) yang telah ditentukan sebelumnya untuk menilai kinerja model. Langkah berikutnya adalah pengujian model, yang bertujuan untuk mengidentifikasi aspek-aspek yang masih memerlukan perbaikan. Melalui proses ini, area yang perlu ditingkatkan dapat diketahui, sehingga memungkinkan optimasi lebih lanjut guna meningkatkan akurasi hasil pelatihan pada tahap berikutnya..

4. HASIL DAN PEMBAHASAN

4.1. Pengumpulan data

Dalam penelitian ini, dataset terdiri dari 100 citra wajah yang diperoleh melalui proses pemotretan terhadap 20 mahasiswa Ilmu Komputer. Setiap individu difoto dalam lima pose wajah yang berbeda, sehingga menciptakan variasi data yang kaya dan representatif. Proses pengambilan data ini dilakukan dengan menggunakan perangkat yang dimiliki oleh peneliti. Berikut adalah contoh data wajah yang peneliti kumpulkan:

Tabel 1. Contoh Pengambilan Gambar

	
Tegak lurus	Menghadap ke atas
	
Menghadap ke Bawah	Rotasi ke kanan 30 °
	
Rotasi ke kiri 30°	

4.2. Pra-pemrosesan data

Proses ini penting untuk memastikan bahwa data yang digunakan dalam model telah melalui tahap persiapan yang memadai, sehingga dapat menghasilkan hasil pelatihan yang optimal saat diterapkan dalam pemodelan. Tahap pra-pemrosesan data mencakup serangkaian langkah berikut.

a. Pelabelan data

Gambar yang telah dikumpulkan dikelompokkan dalam folder masing-masing, di mana setiap folder diberi label sesuai dengan identitas individu yang bersangkutan.



Gambar 2. Pelabelan Data

b. Penghapusan latar

Penghapusan latar dilakukan untuk memastikan bahwa analisis hanya berfokus pada objek yang relevan, tanpa adanya gangguan dari elemen latar belakang yang tidak penting.



Gambar 3. Penghapusan Latar

4.3. Augmentasi Data

Augmentasi data merupakan teknik yang bertujuan untuk memperbesar dan memperkaya keragaman dataset dengan menciptakan variasi baru dari data yang telah ada. Metode ini membantu model pembelajaran mesin dalam menggeneralisasi lebih baik dengan mempelajari pola dari berbagai bentuk data yang beragam.

a. Rotation

Teknik ini menerapkan rotasi gambar pada sudut tertentu. Dalam penelitian ini, gambar diputar 45° untuk membantu model pembelajaran mesin dalam mengenali objek yang sama dari berbagai orientasi atau sudut pandang.



Citra

Hasil Citra Rotasi 45°

Gambar 4. Contoh Augmentasi Rotasi Citra

b. Random Noise

Teknik ini menambahkan noise acak ke gambar, berupa titik-titik putih atau hitam yang tersebar secara acak di seluruh area gambar. Noise ini bertujuan untuk meningkatkan ketahanan model, sehingga mampu mengenali objek dengan lebih.



Citra Awal

Hasil Citra Noise

Gambar 5. Contoh Augmentasi Citra Noise

c. Zoom

Teknik zoom memungkinkan gambar diperbesar atau diperkecil, sehingga membantu model dalam mengenali detail kecil yang mungkin tidak terlihat pada skala normal.




Citra Awal

Hasil Zoom Citra

Gambar 6. Hasil Augmentasi Zoom Citra

d. Brightness

Teknik ini menyesuaikan tingkat kecerahan gambar guna mensimulasikan berbagai kondisi pencahayaan. Dengan meningkatkan atau menurunkan kecerahan, model dapat beradaptasi lebih baik terhadap gambar yang diambil dalam lingkungan terang maupun gelap.



Citra Awal

Hasil Brightness

Gambar 7. Hasil Augmentasi Brightness Citra

4.4. Pembagian Data

Dataset dibagi menjadi dua bagian utama: data pelatihan dan data pengujian. Dalam penelitian ini, pembagian dilakukan dengan rasio 80% untuk data latih dan 20% untuk data uji, sehingga terdapat 2.560 gambar untuk pelatihan dan 640 gambar untuk pengujian.

4.5. Pembangunan Model CNN

Setelah data dibagi, model dikembangkan menggunakan arsitektur *Inception V3*, dengan input citra berukuran (299×299) . Optimasi dilakukan dengan optimizer Adam, menggunakan variasi learning rate sebesar 10^{-4} , 10^{-5} , dan 10^{-6} . Untuk

mencegah overfitting, diterapkan regularisasi pada lapisan tersembunyi (hidden layers) serta dropout sebesar 40%, yang membantu meningkatkan generalisasi model dengan menonaktifkan sebagian neuron saat pelatihan.

Lapisan terakhir atau dense layer menyesuaikan jumlah kelas, yaitu 20 kelas, dengan fungsi aktivasi *SoftMax*. Fungsi ini sangat efektif dalam klasifikasi multi-kelas, karena mengubah *output* menjadi distribusi probabilitas yang mudah diinterpretasikan. Dengan pendekatan ini, model diharapkan mampu memberikan prediksi yang lebih akurat terhadap data baru

4.6. Pelatihan Model

Setelah model berhasil dibangun, langkah berikutnya adalah melibatkan penyusunan layer serta pelatihan model menggunakan CNN. Dalam proses ini, kinerja model diukur berdasarkan nilai accuracy, validation accuracy, loss, validation loss. Tabel 2 merupakan hyperparameter yang digunakan pada penelitian ini.

Tabel 2. Hyperparameter

Hyperparameter	Nilai
Epochs(epoch)	50
Image Size	(299,299)
Batch Size	32
Learning Rate	10^{-4} , 10^{-5} , 10^{-6}
Optimizer	Adam
Dropout Rate	0.4

Tabel 2 merangkum hyperparameter yang digunakan untuk mengoptimalkan pelatihan model dalam penelitian ini. Parameter yang disertakan mencakup jumlah epoch (50) sebagai siklus pelatihan, ukuran gambar 299×299 piksel, dan batch size sebesar 32, yang menentukan jumlah data yang diproses sebelum pembaruan bobot.

Laju pembelajaran (learning rate) yang diterapkan terdiri 10^{-4} , 10^{-5} , dan 10^{-6} . Optimizer yang digunakan adalah Adam, yang secara adaptif memperbarui bobot selama pelatihan. Untuk mengatasi overfitting, model menerapkan regularisasi pada lapisan tersembunyi, serta dropout sebesar 40%, yang menonaktifkan sebagian neuron secara acak selama pelatihan. Kombinasi hyperparameter ini dirancang untuk memastikan kinerja optimal dengan mengacu pada metrik seperti akurasi, validasi akurasi, loss, dan validasi loss guna meningkatkan generalisasi model terhadap data baru.


Tabel 3. Hasil Tiap Learning Rate

LR	Accuracy	Val Accuracy	Loss	Val Loss
10^{-4}	0.9980	0.9984	0.0181	0.0129
10^{-5}	0.9523	0.9640	0.3628	0.2554
10^{-6}	0.3871	0.4953	2.7548	2.7187


Analisis pada tabel menunjukkan bahwa learning rate 10^{-5} memberikan kinerja cukup baik dengan accuracy 95.23% dan val_accuracy 96.40%, meskipun nilai loss 0.3628 dan val_loss 0.2554 menunjukkan bahwa model masih dapat ditingkatkan. Selisih kecil antara accuracy dan val_accuracy mengindikasikan bahwa model tidak mengalami overfitting, tetapi belum mencapai performa optimal.

Sebaliknya, learning rate 10^{-4} menghasilkan kinerja terbaik, dengan accuracy 99.80% dan val_accuracy 99.84%. Nilai loss 0.0181 dan val_loss 0.0129 menunjukkan minimnya kesalahan prediksi, serta kemampuan generalisasi yang sangat baik. Selisih yang sangat kecil antara accuracy dan val_accuracy menandakan bahwa model tetap stabil tanpa mengalami overfitting.


Dari analisis ini, dapat disimpulkan bahwa konfigurasi learning rate 10^{-4} , epoch 50, dan rasio data 80:20 merupakan pilihan terbaik untuk pengujian lebih lanjut.



Gambar 2. Grafik Hasil Learning Rate 10^{-4}



Gambar 3. Grafik Hasil Learning Rate 10^{-5}




Gambar 4. Grafik Hasil Learning Rate 10^{-6}

Grafik pada Gambar 8-10 menunjukkan pola peningkatan accuracy dan penurunan loss selama proses pelatihan, mengonfirmasi hasil evaluasi model.

4.7. Evaluasi Model

Evaluasi model bertujuan untuk mengukur kinerja algoritma dalam memahami dan

mengklasifikasikan data dengan akurasi tinggi, Evaluasi model pada dilakukan pada 640 data uji.



Gambar 5. Confusion Matrix

Berdasarkan visualisasi diatas dapat ditemukan hasil dari keseluruhan nilai precision, recall dan f1-score pada setiap kelas dari pengujian model dapat dilihat pada tabel 4.

Tabel 4. Precision, Recall, F1-Score, Accuracy

Kelas	Precision	Recall	F-1Score
Ade Setiawan	100%	100%	100%
Adinda Wibowo	100%	100%	100%
Boy Hendrawan	100%	100%	100%
Desti Syafrida	100%	100%	100%
Fahruraji	100%	100%	100%
Haikal Farhan	100%	100%	100%
Immanuel Batituta	100%	100%	100%
Iyan Abdillah	100%	100%	100%
Jeremia S.P.	100%	100%	100%
Mochammad Gani	100%	100%	100%
M. Lazuardi	100%	100%	100%
Rahayu Andriani	100%	100%	100%
Rahman Wahabi	100%	100%	100%
Ridho Ardhana	100%	100%	100%
Rinay Eka	100%	100%	100%
Rizky gunawan	100%	100%	100%
Sadion Tumpal	100%	100%	100%
Todo Josafat	100%	100%	100%
Wulan Adira	100%	100%	100%
Yolanda Feby	100%	100%	100%
Rata-Rata	100%	100%	100%
Accuracy	100%		

Dari Tabel 5 dapat dilihat bahwa model dari Learning rate 10^{-4} klasifikasi menunjukkan performa yang sangat baik dengan rata-rata precision, recall, dan F1-score masing-masing sebesar 100% terhadap data uji.

Tabel 5. Hasil Evaluasi Tiap Learning Rate

Learning Rate	Precision	Recall	F-1 Score	Accuracy
10e-4	100%	100%	100%	100%
10e-5	98%	98%	98%	98%
10e-6	69%	56%	53%	56%

Evaluasi model dilakukan dengan learning rate $10e-4$, $10e-5$, dan $10e-6$. Learning rate $10e-4$ memberikan hasil terbaik dengan akurasi 100%, sementara $10e-5$ tetap stabil dengan 98%. Sebaliknya, $10e-6$ menunjukkan performa jauh lebih rendah dengan akurasi 56%, menghambat pembelajaran pola secara efektif. Learning rate yang lebih tinggi cenderung lebih baik, tetapi perlu memperhatikan risiko overfitting dan stabilitas model

4.8. Tes Model

Dari ketiga model yang diuji, learning rate 10^{-4} menunjukkan hasil akurasi yang lebih tinggi, sehingga dianggap paling efektif untuk digunakan dalam pengujian model ini.



Gambar 6. Output Model

Model mampu mengidentifikasi wajah "Immanuel Batituta Tarigan" dengan akurasi tinggi, mencapai confidence 100%, dalam waktu 0.079 m/s, menunjukkan efisiensi tinggi dalam pemrosesan dan ketepatan dalam prediksi.

5. KESIMPULAN DAN SARAN

Kesimpulan dari penelitian ini menunjukkan bahwa sistem pengenalan wajah berbasis *Haarcascade Classifier* yang dikombinasikan dengan *Convolutional Neural Network* (CNN) menggunakan arsitektur *Inception V3* telah berhasil dikembangkan. Dengan optimalisasi hyperparameter dengan learning rate 10^{-4} dan epoch sebanyak 50, model ini mencapai akurasi 100% serta nilai Precision, Recall, dan F-1 Score yang sangat tinggi, menandakan kemampuan identifikasi yang akurat. Keberhasilan ini menunjukkan bahwa model dapat melakukan generalisasi dengan baik terhadap data baru, memastikan prediksi yang presisi dan andal. Tahapan penting dalam pengembangannya meliputi pemrosesan data, perancangan arsitektur CNN, pelatihan model, dan evaluasi kinerja menggunakan metrik yang relevan. Hasil penelitian ini membuka peluang pengembangan lebih lanjut untuk berbagai aplikasi, seperti sistem keamanan dan identifikasi wajah dalam berbagai sektor.

DAFTAR PUSTAKA

- [1] L. Qinjun, C. Tianwei, Z. Yan, and W. Yuying, "Facial Recognition Technology: A Comprehensive Overview," *Acad. J. Comput. Inf. Sci.*, vol. 6, no. 7, pp. 15–26, 2023, doi: 10.25236/ajcis.2023.060703.
- [2] A. Alwendi and M. Masriadi, "Aplikasi Pengenalan Wajah Manusia Pada Citra Menggunakan Metode Fisherface," *J. Digit.*, vol. 11, no. 1, p. 01, 2021, doi: 10.51920/jd.v11i1.174.
- [3] L. Putu, A. Sri, T. Informasi, U. P. Sakti, and P. Korespondensi, "OPTIMIZATION OF FACE RECOGNITION SYSTEMS WITH IMAGE PROCESSING," vol. 3, no. 1, pp. 18–22, 2024.
- [4] R. Prathivi and Y. Kurniawati, "Sistem Presensi Kelas Menggunakan Pengenalan Wajah Dengan Metode Haar Cascade Classifier," *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 11, no. 1, pp. 135–142, 2020, doi: 10.24176/simet.v11i1.3754.
- [5] D. I. Mulyana *et al.*, "Penerapan Face Recognition Dengan Algoritma Haar Cascade Untuk Sistem Absensi Pada Yayasan Pusat Pengembangan Anak Jakarta," *J. Cahaya Mandalika ISSN 2721-4796*, pp. 215–226, 2023, [Online]. Available: <https://ojs.cahayamandalika.com/index.php/jcm/article/view/1284>
- [6] F. L. Ramadini and E. Haryatmi, "Penggunaan Metode Haar Cascade Classifier dan LBPH Untuk Pengenalan Wajah Secara Realtime," *InfoTekJar J. Nas. Inform. dan Teknol. Jar.*, vol. 6, no. 2, pp. 1–8, 2022, [Online]. Available: <https://jurnal.uisu.ac.id/index.php/infotekjar/article/view/4714/pdf>
- [7] P. Rosyani and R. Retnawati, "Ekstraksi Fitur Wajah Menggunakan Metode Viola Jones dengan Tools Cascade Detector," *JURIKOM (Jurnal Ris. Komputer)*, vol. 10, no. 2, p. 633, 2023, doi: 10.30865/jurikom.v10i2.6062.
- [8] L. N. Haikal Engga Nawawi, Reni Rahmadewi, "Pendeteksian Wajah Hasil Dari Manipulasi Ai Pada Citra Digital," *J. Ilm. Wahana Pendidik.*, vol. 10, no. 2, pp. 402–409, 2024.
- [9] S. Kusmaryanto, "Jaringan Saraf Tiruan Backpropagation untuk Pengenalan Wajah Metode Ekstraksi Fitur Berbasis Histogram," *J. EECCIS (Electrics, Electron. Commun. Control. Informatics, Syst.)*, vol. 8, no. 2, pp. 193–195, 2021, [Online]. Available: <https://jurnaleeccis.ub.ac.id/index.php/eeccis/article/view/283/246>
- [10] M. Khatama Insani and D. Budi Santoso, "Perbandingan Kinerja Model Pre-Trained CNN (VGG16, RESNET, dan INCEPTIONV3) untuk Aplikasi Pengenalan Wajah pada Sistem Absensi Karyawan," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 3, pp. 2612–2622, 2024, [Online]. Available: <https://journal.stmiki.ac.id>
- [11] S. Teguh Arifianto, "Penerapan Algoritma Viola-Jones Untuk Deteksi Masker Covid-19 Di Politeknik Perkeretaapian Indonesia Madiun," *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 4, pp. 2030–2040, 2021.
- [12] P. Viola and M. Jones, "Haar-like," *Cvpr*, vol. 1, pp. I-511–I-518, 2001, [Online]. Available: <http://ieeexplore.ieee.org/document/990517/>
- [13] N. Dewi and F. Ismawan, "Implementasi Deep Learning Menggunakan Cnn Untuk Sistem Pengenalan Wajah," *Fakt. Exacta*, vol. 14, no. 1, p. 34, 2021, doi: 10.30998/faktorexacta.v14i1.8989.
- [14] M. Raihan, R. Allaam, and A. T. Wibowo, "Klasifikasi Genus Tanaman Anggrek Menggunakan Metode Convolutional Neural Network (CNN)," *e-Proceeding Eng.*, vol. 8, no. 2, p. 1153, 2021.
- [15] X. Wang *et al.*, "A Recognition Method of Ancient Architectures Based on the Improved Inception V3 Model," *Symmetry (Basel)*, vol. 14, no. 12, 2022, doi: 10.3390/sym14122679.
- [16] M. S. Satrio, "Pengenalan Wajah Menggunakan Principal Component Analysis (Pca) Dan Eigen Face," *J. Inform. dan Ris.*, vol. 1, no. 2, pp. 14–18, 2023, doi: 10.36308/iris.v1i2.521.