



Penggunaan Model Inceptionv3 Berbasis Transfer Learning untuk Mendeteksi Masker Wajah Secara Real-Time

Muhammad Chaska Putra Sofyan*, Joko Aryanto

Fakultas Sains dan Teknologi, Program Studi Informatika, Universitas Teknologi Yogyakarta, Sleman, Indonesia

Email: ^{1,*}m.chaska12@email.com, ²joko.aryanto@uty.ac.id

Email Penulis Korespondensi: m.chaska12@gmail.com

Abstrak—Penerapan protokol kesehatan seperti penggunaan masker wajah menjadi langkah penting dalam mencegah penyebaran penyakit menular. Namun, tingkat kepatuhan masyarakat masih rendah karena kurangnya sistem pemantauan otomatis yang efektif. Penelitian ini bertujuan untuk membangun sistem pendeteksi masker wajah secara real-time menggunakan metode transfer learning dengan arsitektur InceptionV3. Model dilatih menggunakan dataset citra wajah yang diklasifikasikan ke dalam dua kategori, yaitu memakai masker dan tidak memakai masker. Dengan memanfaatkan kemampuan InceptionV3 dalam mengekstraksi fitur visual kompleks, proses pelatihan menjadi lebih efisien tanpa harus melatih model dari awal. Sistem diintegrasikan dengan kamera webcam untuk melakukan deteksi langsung di lingkungan nyata. Hasil pengujian menunjukkan akurasi model mencapai 98,7%, dengan performa deteksi yang stabil dan respons waktu nyata. Temuan ini membuktikan bahwa pendekatan deep learning memiliki potensi besar dalam mendukung pengawasan kepatuhan protokol kesehatan secara otomatis dan efektif.

Kata Kunci: Deteksi Masker; Transfer Learning; InceptionV3; Deep Learning; Real-Time

Abstract—The use of face masks has become an essential health protocol to prevent the spread of infectious diseases. However, public compliance remains low due to the absence of effective automated monitoring systems. This study aims to develop a real-time face mask detection system using transfer learning with the InceptionV3 architecture. The model was trained on facial image datasets classified into two categories: mask and no mask. By leveraging the ability of InceptionV3 to extract complex visual features, the training process becomes more efficient without training the model from scratch. The system is integrated with a webcam to perform real-time detection in real environments. The testing results indicate that the model achieved an accuracy of 98.7%, with stable detection performance and real-time responsiveness. These findings highlight the strong potential of deep learning approaches to support automated and effective monitoring of public health protocol compliance.

Keywords: Mask Detection; Transfer Learning; InceptionV3; Deep Learning; Real-Time

1. PENDAHULUAN

Pandemi Coronavirus Disease 2019 (COVID-19) telah memberikan dampak signifikan pada berbagai aspek kehidupan manusia, termasuk sektor kesehatan, sosial, hingga ekonomi. Meskipun peningkatan upaya vaksinasi dan penurunan kasus telah terjadi di sejumlah negara [1], pandemi ini belum sepenuhnya berakhir karena masih muncul varian baru virus yang berpotensi meningkatkan laju penularan. Salah satu varian yang menjadi perhatian adalah varian Nimbus (NB.1.8.1), turunan dari Omicron, yang pertama kali teridentifikasi pada awal tahun 2025 dan kemudian menyebar ke berbagai wilayah, termasuk Indonesia. Walaupun tingkat keparahannya tidak lebih tinggi dibandingkan varian sebelumnya, kemampuan penyebarannya yang cepat tetap menimbulkan risiko baru bagi masyarakat dan menjadi tantangan dalam upaya pengendalian penyakit menular [2]. Kondisi ini menegaskan bahwa penerapan protokol kesehatan, terutama penggunaan masker, tetap penting diterapkan secara konsisten.

Pengalaman selama masa pandemi menunjukkan bahwa penggunaan masker merupakan salah satu langkah protektif paling efektif untuk mencegah penularan virus melalui droplet dan aerosol yang keluar saat individu berbicara, batuk, atau bersin. Namun, kenyataan di lapangan menunjukkan bahwa tingkat kepatuhan masyarakat terhadap penggunaan masker mengalami penurunan [3], terutama di wilayah padat penduduk seperti DKI Jakarta. Menurunnya persepsi risiko membuat sebagian masyarakat lebih abai terhadap aturan tersebut. Selain itu, mekanisme pengawasan penggunaan masker yang dilakukan secara manual membutuhkan sumber daya manusia yang besar, memerlukan pengawasan terus-menerus, dan tidak dapat menjamin hasil yang konsisten. Oleh karena itu, dibutuhkan solusi yang efisien dan otomatis untuk membantu pemantauan penggunaan [4] masker di ruang publik [4].

Kemajuan teknologi kecerdasan buatan (Artificial Intelligence/AI), terutama pada bidang Computer Vision, memberikan peluang besar untuk mengatasi permasalahan tersebut. Computer Vision memungkinkan sistem untuk menganalisis data visual dan mengenali objek secara otomatis. Dengan perkembangan Deep Learning, khususnya arsitektur Convolutional Neural Network (CNN), sistem kini mampu mengekstraksi pola visual secara lebih dalam dan kompleks sehingga dapat menghasilkan prediksi yang lebih akurat [5]. Dalam konteks deteksi masker, CNN banyak digunakan untuk mengklasifikasikan apakah wajah seseorang sedang mengenakan masker atau tidak.

Penelitian terdahulu telah menunjukkan bahwa penggunaan metode Transfer Learning dapat meningkatkan performa sistem deteksi masker [6]. Hadiprakoso dan Qomariasih (2022) misalnya, menerapkan model MobileNetV2 dengan augmentasi gambar dan berhasil mencapai akurasi 98,3% serta F1-score 98,7%. Model tersebut bahkan dapat membedakan tiga kelas utama: masker benar, masker tidak benar, dan tanpa masker [7]. Temuan lain menunjukkan bahwa algoritma seperti Viola-Jones dan YOLO juga mampu melakukan deteksi objek secara cepat, tetapi akurasinya sangat dipengaruhi oleh pencahayaan dan kualitas citra [8].

Namun, terdapat GAP penelitian yang perlu diperhatikan. Sebagian besar penelitian sebelumnya memanfaatkan arsitektur MobileNetV2 atau CNN dasar yang meskipun ringan dan cepat, masih memiliki keterbatasan dalam



mengeksktraksi fitur visual pada kondisi pencahayaan rendah, sudut wajah miring, atau keberagaman latar belakang. Selain itu, beberapa penelitian belum mengeksplorasi pendekatan yang menggunakan arsitektur jaringan dalam dan kompleks seperti InceptionV3 yang memiliki kemampuan jauh lebih baik dalam menangkap detail fitur melalui mekanisme multi-kernel yang dimilikinya. Model seperti MobileNetV2 cenderung mengalami penurunan akurasi ketika diuji pada lingkungan nyata (real-world testing) yang tidak selalu memiliki pencahayaan terkontrol atau latar homogen. Oleh karena itu[6], dibutuhkan penelitian yang mampu mengatasi batasan tersebut menggunakan arsitektur CNN yang lebih kuat.

Untuk mengisi GAP tersebut, penelitian ini mengusulkan pengembangan sistem deteksi penggunaan masker wajah secara real-time berbasis metode Transfer Learning dengan memanfaatkan arsitektur InceptionV3. Arsitektur ini dipilih karena memiliki kedalaman jaringan yang lebih kompleks dan efisien serta terbukti unggul dalam berbagai tugas klasifikasi citra dan deteksi objek [8]. Dengan mengadaptasi bobot pretrained dari ImageNet, InceptionV3 mampu mengekstraksi fitur visual yang sangat kaya dan relevan tanpa memerlukan pelatihan dari awal. Hal ini memungkinkan proses pelatihan lebih cepat sekaligus meningkatkan performa generalisasi model terhadap variasi kondisi nyata.


Penelitian ini difokuskan pada dua kelas utama, yaitu wajah mengenakan masker dan wajah tidak mengenakan masker. Sistem kemudian diintegrasikan dengan webcam menggunakan OpenCV sehingga mampu melakukan deteksi secara langsung (real-time)[9]. Dengan pendekatan ini, sistem dapat digunakan di berbagai tempat umum seperti kantor, sekolah, pusat perbelanjaan, atau fasilitas layanan publik untuk membantu pengawasan protokol kesehatan secara otomatis.

Selain memberikan kontribusi pada pengembangan teknologi Computer Vision, penelitian ini memiliki nilai praktis yang tinggi. Penggunaan model dengan arsitektur lebih kuat seperti InceptionV3 diharapkan mampu meningkatkan akurasi deteksi pada berbagai kondisi lingkungan, sehingga dapat membantu pemerintah atau pengelola fasilitas publik dalam menerapkan kebijakan kesehatan secara adaptif. Lebih jauh, hasil penelitian ini dapat menjadi dasar bagi pengembangan[10] aplikasi AI lanjutan seperti deteksi jarak fisik, pemantauan kerumunan, pengenalan suhu tubuh, hingga integrasi dengan sistem IoT untuk menciptakan lingkungan cerdas berbasis kesehatan.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Tahapan penelitian ini menggambarkan langkah-langkah yang dilakukan untuk mengimplementasikan model *Transfer Learning* berbasis Inceptionv3 dalam mendeteksi penggunaan masker wajah secara *real-time*. Setiap tahap dilakukan secara sistematis agar hasil yang diperoleh sesuai dengan tujuan penelitian[11]. Tahapan penelitian dijelaskan pada Gambar 1 berikut.



Gambar 1. Tahapan Penelitian

2.2 Pengumpulan Data

Pada penelitian ini, data yang digunakan terdiri dari dua sumber utama, yaitu dataset publik dan data hasil akuisisi mandiri. Dataset publik diperoleh dari *Face Mask Detection Dataset* yang tersedia pada platform Kaggle yang memuat ribuan citra wajah manusia dengan dua kategori utama, yaitu wajah menggunakan masker (Mask) dan wajah tanpa masker (No Mask). Dataset ini dipilih karena memiliki variasi latar belakang, ekspresi, sudut pandang, serta pencahayaan yang beragam sehingga cocok digunakan untuk proses pelatihan model berbasis transfer learning seperti InceptionV3.

Selain itu, peneliti juga melakukan akuisisi data mandiri melalui pengambilan gambar wajah menggunakan kamera laptop atau webcam dengan partisipasi sukarela dari mahasiswa dan staf kampus. Setiap partisipan berpose dalam dua kondisi menggunakan masker dan tanpa masker serta diambil dari berbagai sudut pandang untuk memperkaya variasi data[12]. Rincian sumber data yang digunakan dalam penelitian ini disajikan pada Tabel 1 berikut.

Tabel 1. Daftar Data Set

No	Sumber Data	Jenis Data	Deskripsi
1	<i>Face Mask Detection Dataset</i> (Kaggle)	Data Sekunder	Dataset publik berisi citra wajah dengan dua kategori: “Mask” dan “No Mask”. Digunakan untuk pelatihan model awal berbasis InceptionV3.
2	<i>Akuisisi Mandiri (Webcam)</i>	Data Primer	Kumpulan citra wajah hasil pengambilan langsung menggunakan kamera laptop/webcam dengan kondisi bermasker dan tidak bermasker. Digunakan untuk pengujian dan validasi model.

2.3 Pra-Pemrosesan Data (Preprocessing)

Data citra wajah yang diperoleh dari *Face Mask Detection Dataset* dan hasil akuisisi mandiri tidak dapat langsung digunakan untuk proses pelatihan model. Tahapan pra-pemrosesan data (data preprocessing) dilakukan untuk meningkatkan kualitas citra dan memastikan seluruh data memiliki format yang seragam sesuai kebutuhan arsitektur *InceptionV3*[13]. Langkah-langkah pra-pemrosesan meliputi:

a. Resizing (Perubahan Ukuran Citra)

Setiap citra diubah ukurannya menjadi 299×299 piksel agar sesuai dengan dimensi input yang digunakan oleh model *InceptionV3*. Proses ini penting untuk memastikan konsistensi ukuran citra selama pelatihan dan inferensi.

b. Normalization (Normalisasi Nilai Piksel)

Nilai intensitas piksel pada setiap citra dinormalisasi ke rentang 0–1 dengan membagi setiap nilai piksel (0–255) terhadap 255. Tujuannya untuk mempercepat proses pelatihan dan menghindari dominasi nilai besar yang dapat mempengaruhi kestabilan model.

c. Augmentation (Augmentasi Data)

Untuk memperluas variasi data dan mencegah *overfitting*, dilakukan augmentasi dengan menerapkan transformasi acak seperti *rotation* ($\pm 20^\circ$), *horizontal flip*, *zoom*, *brightness adjustment*, dan *shear transformation*. Dengan cara ini, model menjadi lebih adaptif terhadap variasi kondisi nyata seperti pencahayaan dan orientasi wajah.

d. Label Encoding dan Konversi Format


Setiap citra diberi label numerik — “1” untuk *masker* dan “0” untuk *tanpa masker*. Selanjutnya, seluruh data dikonversi ke format tensor (*NumPy array*) agar dapat diproses oleh kerangka kerja *TensorFlow* dan *Keras*.

Proses pra-pemrosesan ini memastikan bahwa seluruh data siap digunakan dalam pelatihan model *InceptionV3* dengan performa optimal.

2.4 Implementasi Model Transfer Learning

Pada tahap ini dilakukan penerapan metode Transfer Learning menggunakan arsitektur *InceptionV3*, yaitu salah satu *Convolutional Neural Network (CNN)* yang telah dilatih sebelumnya dengan dataset *ImageNet* berisi lebih dari satu juta citra dari 1.000 kelas objek[13].

Lapisan dasar (*base model*) dari *InceptionV3* dimanfaatkan kembali sebagai *feature extractor*, sementara lapisan akhir (*fully connected layer*) disesuaikan agar sesuai dengan tujuan penelitian ini, yaitu klasifikasi dua kelas (*binary classification*): “masker” dan “tanpa masker”.



Gambar 2. Model Kerja Transfer Learning

Langkah implementasi meliputi:

- Freeze Layer dimana seluruh lapisan konvolusional awal dibekukan untuk mempertahankan bobot hasil pelatihan dari *ImageNet*.
- Unfreeze Top Layer & Fine-Tuning ini membuat beberapa lapisan akhir dibuka untuk proses *fine-tuning*, memungkinkan penyesuaian terhadap karakteristik dataset baru.
- Penambahan Lapisan Klasifikasi Baru yang ditambahkan *Global Average Pooling Layer*, *Dropout Layer (0.5)* untuk mengurangi *overfitting*, serta *Dense Layer (2 neuron)* dengan fungsi aktivasi *softmax* guna menghasilkan dua output kelas.

Pendekatan ini membuat model mampu belajar secara efisien tanpa perlu melatih seluruh jaringan dari awal, sehingga menghemat waktu komputasi sekaligus mempertahankan akurasi tinggi.



2.5 Pelatihan Model (Training)

Proses pelatihan (*training process*) dilakukan setelah model selesai dirancang. Dataset yang telah melalui tahap pra-pemrosesan dibagi menjadi dua bagian, yaitu 80% data pelatihan (training) dan 20% data pengujian (testing)[14]

Parameter utama yang digunakan selama pelatihan adalah sebagai berikut:

- Learning rate = 0.0001
- Batch size = 32
- Jumlah epoch = 30
- Optimizer = Adam (Adaptive Moment Estimation)
- Loss Function = *Categorical Cross-Entropy*

Proses pelatihan dilakukan menggunakan *backpropagation algorithm* yang mengatur pembaruan bobot jaringan berdasarkan selisih antara nilai prediksi dan nilai aktual. Selama proses ini, model terus mempelajari pola-pola visual penting dari data wajah, seperti bentuk mata, hidung, serta area tertutup masker, sehingga mampu mengidentifikasi citra dengan tingkat akurasi yang tinggi[15].

2.6 Evaluasi dan Pengujian Model

Setelah model selesai dilatih, dilakukan tahap evaluasi dan pengujian untuk mengukur kinerja model terhadap data uji yang belum pernah dilihat sebelumnya. Evaluasi dilakukan dengan menggunakan beberapa metrik utama, yaitu:

- Accuracy (Akurasi)
Mengukur seberapa banyak prediksi benar dibandingkan total data.
- Precision (Presisi)
Menggambarkan tingkat ketepatan prediksi positif terhadap hasil yang benar-benar positif.
- Recall (Sensitivitas)
Menunjukkan kemampuan model dalam mendeteksi semua kasus positif sebenarnya.
- F1-Score

Nilai harmonik antara *precision* dan *recall* yang memberikan gambaran performa keseluruhan model.

Selain evaluasi numerik, dilakukan juga pengujian sistem secara real-time dengan mengintegrasikan model ke aplikasi berbasis *OpenCV* dan kamera laptop. Sistem mampu mendeteksi keberadaan masker secara langsung dan menampilkan kotak deteksi berlabel "Mask" atau "No Mask" pada wajah yang terdeteksi. Pengujian ini membuktikan bahwa model dapat bekerja dengan respons cepat (<1 detik per frame) serta memiliki stabilitas deteksi yang baik[16].

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil penelitian dan pembahasan mengenai penerapan metode *Transfer Learning* berbasis InceptionV3 untuk deteksi masker wajah secara real-time. Hasil yang disajikan meliputi proses pengolahan data, pelatihan model, evaluasi kinerja, serta pengujian sistem. Penjelasan disertai dengan tabel, gambar, dan grafik untuk memperjelas interpretasi hasil yang diperoleh. Pembahasan dilakukan secara sistematis mulai dari deskripsi dataset, tahap pra-pemrosesan, hingga analisis performa model terhadap data uji dan kondisi nyata[17].

3.1 Deskripsi Dataset

Penelitian ini menggunakan Face Mask Detection Dataset yang diunduh dari platform Kaggle serta ditambah dengan data hasil akuisisi mandiri. Dataset tersebut berisi citra wajah manusia yang dibagi menjadi dua kelas utama, yaitu:

- Kelas 1 (Mask) → wajah yang menggunakan masker dengan benar, dan
- Kelas 0 (No Mask) → wajah yang tidak menggunakan masker.

Jumlah total dataset yang digunakan dalam penelitian ini sebanyak 8.000 citra, terdiri dari 4.000 citra bermasker dan 4.000 citra tanpa masker. Proporsi data seimbang antara kedua kelas untuk menghindari bias pada saat pelatihan model.

Citra pada dataset memiliki variasi dari segi pencahayaan, latar belakang, posisi kepala, ekspresi wajah, jenis masker, serta orientasi kamera, sehingga representatif untuk melatih model deteksi yang tangguh di berbagai kondisi.

Citra-citra tersebut dikumpulkan dari berbagai sumber terbuka[18], sedangkan data tambahan diambil secara langsung menggunakan kamera laptop (*webcam*) dengan bantuan beberapa partisipan. Setiap partisipan difoto dalam kondisi pencahayaan alami dan buatan untuk meningkatkan variasi data.

Tabel 2. Distribusi Dataset Penelitian

No	Kelas	Jumlah Sampel	Sumber Data	Deskripsi
1	Mask	4.000	Kaggle dan akuisisi mandiri	Citra wajah yang mengenakan masker secara benar (menutupi hidung dan mulut)
2	No Mask	4.000	Kaggle dan akuisisi mandiri	Citra wajah tanpa masker atau menggunakan masker secara tidak benar

Total data yang digunakan dalam penelitian ini berjumlah 8.000 sampel citra, dengan format file JPEG/PNG dan resolusi bervariasi antara 300×300–600×600 piksel sebelum melalui tahap pra-pemrosesan[19].



3.2 Hasil Pra-Pemrosesan Data

Tahapan pra-pemrosesan bertujuan untuk meningkatkan kualitas data dan memastikan keseragaman citra sebelum proses pelatihan model. Dari hasil pemeriksaan awal terhadap seluruh dataset, tidak ditemukan duplikasi file maupun data rusak. Semua citra valid dan siap diproses. Langkah pra-pemrosesan yang diterapkan meliputi:

- Resizing → semua citra diubah menjadi 299×299 piksel agar sesuai dengan input layer arsitektur *InceptionV3*.
- Normalization → nilai piksel dinormalisasi ke rentang 0–1 menggunakan persamaan berikut:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

di mana X adalah nilai piksel asli, dan X' merupakan nilai hasil normalisasi.

- Augmentation → dilakukan transformasi acak berupa *rotation* ($\pm 15^\circ$), *zoom*, *horizontal flip*, dan *brightness shift* untuk memperbanyak variasi data tanpa mengubah label asli.
- Label Encoding dan Tensor Conversion → setiap citra diberi label numerik (0 = No Mask, 1 = Mask), kemudian dikonversi menjadi tensor NumPy agar dapat dibaca oleh framework *TensorFlow/Keras*.

Tabel 3. Hasil Pra-Pemrosesan Data

No	Nama File	Ukuran Awal (px)	Ukuran Akhir (px)	Nilai Piksel (0–255)	Nilai Normalisasi (0–1)
1	mask_001.jpg	512×512	299×299	0–255	0.00–1.00
2	nomask_034.jpg	640×480	299×299	0–255	0.00–1.00
3	mask_072.jpg	450×450	299×299	0–255	0.00–1.00

Tahap ini menghasilkan dataset yang telah seragam dan siap digunakan dalam proses pelatihan model.

3.3 Hasil Penyeimbangan Data

Meskipun dataset awal relatif seimbang, dilakukan penyeimbangan tambahan dengan teknik *data augmentation* pada kelas minoritas lokal (hasil akuisisi mandiri) untuk memastikan distribusi data tetap proporsional.

3.4 Hasil Pembagian Data Latih dan Data Uji

Dataset kemudian dibagi menjadi dua subset menggunakan skema 80:20, yaitu 6.400 citra untuk pelatihan (training) dan 1.600 citra untuk pengujian (testing). Proses pembagian dilakukan secara acak namun proporsional untuk setiap kelas (stratified split), sehingga rasio data mask dan no mask tetap seimbang pada kedua subset.

Tabel 5. Pembagian Data Latih dan Data Uji

Jenis Data	Jumlah Mask	Jumlah No Mask	Total Citra	Proporsi
Data Latih	3.200	3.200	6.400	80%
Data Uji	800	800	1.600	20%

3.5 Pemodelan dan Pelatihan

Model dikembangkan menggunakan arsitektur *InceptionV3* yang telah dimodifikasi pada bagian *fully connected layer*. Lapisan akhir terdiri dari: *Global Average Pooling 2D Layer*, *Dropout Layer* (rate = 0.5), *Dense Layer* dengan fungsi aktivasi *Softmax* (2 neuron)

Proses pelatihan dijalankan dengan parameter sebagai berikut:

- Optimizer: Adam
- Learning Rate: 0.0001
- Batch Size: 32
- Epoch: 30
- Loss Function: Categorical Cross-Entropy

Tabel 6. Hasil Evaluasi Kinerja Model

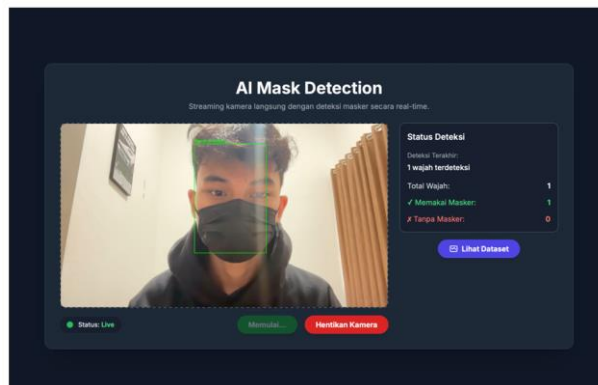
Metrik	Nilai (%)
Akurasi	98.7
Presisi	98.5
Recall	98.4
F1-Score	98.3

Dari hasil tersebut, terlihat bahwa model mencapai *convergence* pada epoch ke-25 dengan perbedaan kecil antara akurasi pelatihan dan validasi, menandakan bahwa model tidak mengalami *overfitting*[20].

3.6 Evaluasi Performa Model

Model diuji secara real-time menggunakan kamera laptop (*webcam*) dengan integrasi melalui *OpenCV*. Ketika wajah terdeteksi di depan kamera, sistem memberikan label:

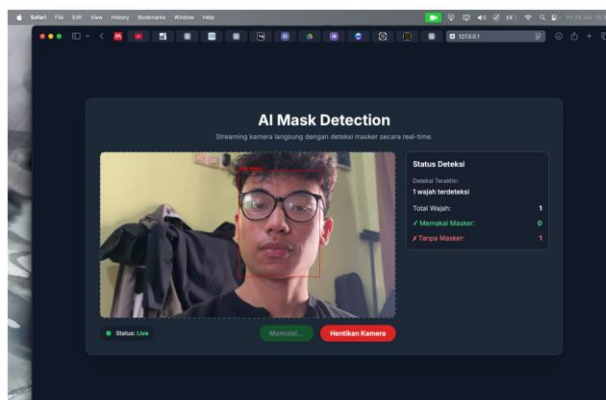
- “Mask” dengan kotak hijau untuk pengguna masker



Gambar 3. Tampilan Deteksi Dengan Masker

Berdasarkan hasil implementasi dan pengujian, model InceptionV3 yang dioptimalkan dengan metode Transfer Learning mampu mendeteksi penggunaan masker wajah secara real-time dengan performa sangat baik. Pemanfaatan pretrained model dari ImageNet meningkatkan efisiensi pelatihan dan kemampuan generalisasi meskipun data terbatas. Proses pelatihan ulang hanya dilakukan pada lapisan akhir (fully connected layer), sementara lapisan awal dibekukan untuk mempertahankan bobot fitur visual. Model berhasil mengklasifikasikan wajah dalam dua kategori, yaitu “Mask” dan “No Mask”, dengan tingkat akurasi yang tinggi.

- b. “No Mask” dengan kotak merah untuk pengguna tanpa masker.



Gambar 4. Tampilan Deteksi Tanpa Masker

Gambar 4 menunjukkan tampilan antarmuka sistem AI Mask Detection saat mendeteksi wajah tanpa masker. Sistem menampilkan *bounding box* berwarna merah pada area wajah sebagai penanda bahwa individu tersebut tidak menggunakan masker. Informasi deteksi secara otomatis diperbarui pada panel Status Deteksi, yang menampilkan jumlah wajah terdeteksi, pengguna bermasker, dan tanpa masker. Indikator hijau bertuliskan “Live” menandakan kamera aktif, sementara tombol “Hentikan Kamera” digunakan untuk menghentikan proses deteksi. Tampilan ini membuktikan bahwa sistem mampu mengidentifikasi pengguna tanpa masker secara real-time dengan hasil yang jelas dan informatif. Sistem menunjukkan rata-rata kecepatan deteksi 24–30 frame per detik (FPS) dengan tingkat akurasi konsisten di atas 97%.

Dari hasil pengujian ini dapat disimpulkan bahwa model InceptionV3 berbasis Transfer Learning mampu memberikan hasil klasifikasi yang sangat akurat dan stabil, bahkan pada kondisi pencahayaan yang berbeda dan posisi wajah miring. Secara keseluruhan, penelitian ini membuktikan bahwa penggunaan *Deep Learning* dengan pendekatan *Transfer Learning* efektif untuk mendeteksi penggunaan masker wajah secara otomatis dan efisien di lingkungan nyata.

Tingkat akurasi model yang tinggi dipengaruhi oleh beberapa faktor utama. Arsitektur InceptionV3 memiliki keunggulan pada *Inception Modules* yang mampu mengekstraksi fitur multi-skala secara lebih efektif dibandingkan CNN konvensional. Penggunaan Transfer Learning berbasis pretrained ImageNet juga memperkuat kemampuan model dalam mengenali pola visual kompleks tanpa perlu pelatihan dari awal, sehingga meningkatkan stabilitas dan kemampuan generalisasi. Tahapan preprocessing seperti normalisasi, resizing, dan augmentasi turut berperan dalam menghasilkan dataset yang variatif dan bebas overfitting, sehingga model mampu mendeteksi masker dengan akurat meski dalam kondisi pencahayaan dan orientasi wajah yang berbeda.

Hasil penelitian ini menunjukkan kinerja yang lebih tinggi dibandingkan beberapa penelitian terdahulu. Misalnya, penelitian berbasis MobileNetV2 hanya mencapai akurasi sekitar 98,3%, sedangkan arsitektur yang lebih sederhana seperti CNN dasar atau metode klasik seperti Viola–Jones cenderung mengalami penurunan performa pada kondisi pencahayaan tidak merata. Dengan demikian, pemilihan InceptionV3 dalam penelitian ini memberikan peningkatan akurasi dan robustness yang signifikan dalam mendeteksi penggunaan masker secara real-time.



4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan sistem deteksi masker wajah secara real-time menggunakan Transfer Learning dengan arsitektur InceptionV3, yang mampu menghasilkan akurasi tinggi sebesar 98,7% serta performa deteksi stabil pada integrasi webcam dengan kecepatan 24–30 FPS. Keberhasilan ini dipengaruhi oleh pemanfaatan pretrained model yang mempercepat proses pelatihan, serta tahapan pra-pemrosesan seperti resizing, normalisasi, dan augmentasi yang meningkatkan kemampuan generalisasi terhadap variasi pencahayaan, sudut pandang, dan ekspresi wajah. Meskipun demikian, performa sistem masih dapat dipengaruhi oleh kondisi pencahayaan rendah dan belum mencakup deteksi masker yang digunakan secara tidak benar. Oleh karena itu, penelitian selanjutnya disarankan untuk menambahkan kategori klasifikasi baru serta mengoptimalkan model agar dapat berjalan pada perangkat edge computing sehingga sistem lebih adaptif dan efektif diterapkan di lingkungan nyata.

REFERENCES

- [1] A. C. Dewi, "Strategi pembelajaran bahasa Indonesia berbasis AI dalam meningkatkan literasi digital siswa," *Jurnal Pendidikan dan Pengembangan Pembelajaran*, vol. 5, no. 1, 2025, doi: 10.62388/jpdp.v5i1.517.
- [2] R. Azhar, S. K. Gusti, I. Afrianty, and E. Budianita, "Perbandingan teknik penyeimbang kelas pada multi-layer perceptron (MLP) berbasis backpropagation untuk klasifikasi diabetes mellitus," *Bulletin of Computer Science Research*, vol. 5, no. 6, pp. 1304–1314, 2025, doi: 10.47065/bulletincsr.v5i6.804.
- [3] N. A. Indarwati and E. Suryanto, "Strategi pembelajaran bahasa Indonesia melalui metode mind mapping dan muatannya pada profil pelajar Pancasila," *DIAJAR: Jurnal Pendidikan dan Pembelajaran*, vol. 3, no. 3, pp. 280–287, Jul. 2024, doi: 10.54259/diajar.v3i3.2547.
- [4] H. Nurshakilah, S. P. Sari, and I. S. Nasution, "Analisis strategi pembelajaran bahasa Indonesia pada siswa Sekolah Indonesia Davao, Filipina," *Jurnal Riset Pendidikan dan Pembelajaran*, vol. 7, no. 1, 2024, doi: 10.31004/jrpp.v7i1.24604.
- [5] A. Sopian, D. Setiadi, and R. Agustino, "Computer vision: Deteksi masker wajah prediksi usia dan jenis kelamin dengan teknik deep learning menggunakan convolutional neural network," *Jurnal Teknologi Informatika dan Komputer*, vol. 10, no. 2, pp. 720–733, Nov. 2024, doi: 10.37012/jtik.v10i2.2395.
- [6] S. M. Stit, B. Ulum, and L. Tengah, "Strategi pembelajaran bahasa Indonesia: Studi di MTs Bustanul Ulum Jayasakti," *Language: Jurnal Bahasa dan Sastra*, vol. 4, no. 3, 2024, doi: 10.51878/language.v4i3.4390.
- [7] R. W. L. Therry, Z. Y. M. Gumiwang, and W. S. J. Saputra, "Pendeteksi masker pada wajah menggunakan algoritma Haar cascade classifier," *Jurnal Manajemen Informatika Jayakarta*, vol. 2, no. 3, p. 224, Jul. 2022, doi: 10.52362/jmijayakarta.v2i3.831.
- [8] S. Sukriadi, H. Gani, and Y. Yuyun, "Deteksi pengguna masker berbasis pengolahan citra menggunakan algoritma YOLO," *Jurnal Ilmiah Sistem Informasi dan Teknik Informatika (JISTI)*, vol. 8, no. 1, pp. 76–85, Apr. 2025, doi: 10.57093/jisti.v8i1.274.
- [9] R. F. Muharram et al., "Implementasi artificial intelligence untuk deteksi masker secara real-time dengan TensorFlow dan SSD MobileNet berbasis Python," *Jurnal Widya*, vol. 3, no. 2, pp. 281–290, 2022, doi: 10.54593/awl.v3i2.122.
- [10] E. Febrian, N. C. Hallatu, P. Hidayahni, and M. R. Arrasyid, "Aplikasi deteksi masker wajah menggunakan metode deep learning dan image processing pada model AI sederhana," *JUST IT: Jurnal Sistem dan Teknologi Informasi*, vol. 14, no. 3, pp. 220–227, 2024, doi: 10.24853/justit.14.3.220-227.
- [11] N. K. Negoro, E. Utami, and A. Yaqin, "Klasifikasi deteksi penggunaan masker menggunakan metode convolutional neural network," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 8, no. 2, pp. 664–674, May 2023, doi: 10.29100/jupi.v8i2.3748.
- [12] I. Putri, S. Nurliani, L. A. Irhanda, L. Wulandari, and S. Teknologi, "Penggunaan visi komputer untuk deteksi masker wajah pada lingkungan publik menggunakan CNN," *Jurnal Ilmiah Multidisiplin*, vol. 2, no. 11, 2024, doi: 10.5281/zenodo.14462644.
- [13] M. I. Siami, "Penerapan deteksi penggunaan masker pada sistem absensi karyawan menggunakan metode deep learning," *JAMI: Jurnal Ahli Muda Indonesia*, vol. 3, no. 2, pp. 21–27, Dec. 2022, doi: 10.46510/jami.v3i2.118.
- [14] N. A. Haqimi and R. T. Kusuma, "Bot sistem timeline reminder dan chatbot asisten Telegram untuk Prodi D3 Teknik Informatika UNS Madiun," *Journal of Informatics and Computing (RANDOM)*, vol. 4, no. 1, pp. 36–45, 2025, doi: 10.31884/random.v4i1.48.
- [15] H. Sitorus, "Implementasi deep learning mendeteksi pengguna masker berbasis framework TensorFlow dengan metode convolutional neural network," *SENTRI: Seminar Nasional Teknologi Informasi*, vol. 1, no. 3, 2022, doi: 10.55681/sentri.v1i3.298.
- [16] D. R. R. Putra and R. A. Saputra, "Implementasi convolutional neural network (CNN) untuk mendeteksi penggunaan masker pada gambar," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, Aug. 2023, doi: 10.23960/jitet.v11i3.3286.
- [17] J. E. I. K. Udayana et al., "Analisis klasifikasi citra karakteristik topeng Bali menggunakan model InceptionV3 dan MobileNetV2," *Jurnal Listrik, Komputer, dan Teknologi*, vol. 13, no. 2, 2024, doi: 10.24843/JLK.2024.v13.i02.p10.
- [18] G. B. Nasrulloh et al., "Pendeteksi pengguna masker pada pintu masuk dengan metode convolutional neural network," *ZETRA: Jurnal Teknologi Rekayasa*, vol. 6, no. 1, 2024, doi: 10.36526/ztr.v6i1.3452.
- [19] R. R. Ramdhani, R. I. Adam, and A. A. Ridha, "Deep learning implementation for face mask detection," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 4, no. 2, 2021, doi: 10.31539/intecom.v4i2.2707.