

ANALISIS KINERJA CNN DALAM KLASIFIKASI PENGUNAAN MASKER WAJAH

Danang Saputra, Afu Ichsan Pradana, Dwi Hartanti

Teknik Informatika, Universitas Duta Bangsa Surakarta

Jl. Bhayangkara No 55-57 Tipes, Serengan, Kota Surakarta, Jawa Tengah

danang44saputra@gmail.com

ABSTRAK

Penggunaan masker wajah merupakan upaya pencegahan yang krusial dalam menekan penyebaran penyakit melalui udara, termasuk penyakit *zoonosis* seperti Hantavirus. Namun, pemantauan kepatuhan secara manual masih menghadapi keterbatasan dari segi efektivitas dan efisiensi, sehingga diperlukan sistem pemantauan otomatis berbasis computer vision. Penelitian ini mengkaji kemampuan metode *Convolutional Neural Network* (CNN) dalam mengklasifikasikan pemakaian masker wajah ke dalam tiga kategori, yaitu *incorrect_mask*, *with_mask*, dan *without_mask*. Dataset yang digunakan adalah *Face Mask Detection* Dataset yang memuat 14.536 citra, dengan tahapan penelitian meliputi *pre-processing*, perancangan arsitektur CNN, pelatihan model, serta evaluasi menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix*. Hasil pengujian menunjukkan bahwa model CNN mencapai akurasi sebesar 80,08%. Kelas *incorrect_mask* memperoleh performa terbaik dengan *precision* 94%, *recall* 99%, dan *F1-score* 96%, sedangkan kelas *with_mask* dan *without_mask* masih mengalami beberapa kesalahan klasifikasi akibat kemiripan karakteristik visualnya. Secara keseluruhan, metode CNN terbukti memiliki kemampuan yang memadai dalam klasifikasi penggunaan masker wajah dan berpotensi diterapkan sebagai sistem pemantauan kepatuhan masker secara otomatis di lingkungan publik.

Kata kunci : *Convolutional Neural Network*, CNN, Klasifikasi Citra, Deteksi Masker Wajah, *Computer Vision*, *Deep Learning*.

1. PENDAHULUAN

Meningkatnya ancaman penyakit *zoonosis* di ruang publik menjadi perhatian serius dalam upaya pengendalian kesehatan masyarakat global, salah satunya adalah infeksi Hantavirus yang penyebarannya kian mendapat sorotan para lembaga kesehatan [1].

Berbeda dengan penyakit menular pada umumnya, Hantavirus tidak ditularkan melalui kontak langsung antarmanusia, melainkan melalui inhalasi aerosol yang berasal dari urin, kotoran, atau air liur tikus yang terinfeksi. Kondisi ini menjadikan lingkungan dengan tingkat sanitasi yang rentan, seperti pasar tradisional, sebagai zona risiko tinggi penularan. Pasar tradisional tidak hanya berfungsi sebagai pusat transaksi ekonomi dan interaksi sosial yang padat, tetapi juga secara tidak langsung menyediakan habitat yang kondusif bagi hewan pengerat akibat ketersediaan sisa makanan yang melimpah [2].

Sebagai langkah pencegahan, penggunaan masker wajah secara benar merupakan salah satu benteng pertahanan utama bagi pedagang maupun pengunjung pasar dalam menyaring partikel aerosol terkontaminasi agar tidak masuk ke saluran pernapasan. Namun demikian, pengawasan kepatuhan penggunaan masker di area pasar hingga saat ini masih mengandalkan metode manual yang bergantung sepenuhnya pada pengamatan petugas lapangan. Pendekatan konvensional ini memiliki keterbatasan yang tidak dapat diabaikan, mengingat petugas tidak mampu melakukan pemantauan secara terus-menerus sepanjang waktu operasional pasar yang dinamis dan ramai [3].

Oleh karena itu, kebutuhan akan sistem pengawasan otomatis yang mampu bekerja secara mandiri dan kontinu menjadi semakin mendesak.

Perkembangan teknologi computer vision dan pemrosesan citra digital membuka peluang besar untuk menjawab tantangan tersebut dalam konteks pengawasan kesehatan masyarakat modern [4].

Beberapa metode deteksi penggunaan masker wajah telah dikembangkan sebelumnya, di antaranya *You Only Look Once* (YOLO), Viola-Jones atau *Haar Cascade*, *Hybrid Deep Transfer Learning*, serta *Convolutional Neural Network* (CNN) [5],[6].

Di antara berbagai pendekatan tersebut, CNN diakui secara luas sebagai salah satu metode paling andal untuk tugas deteksi dan klasifikasi objek visual. Secara arsitektural, CNN bekerja dengan memproses citra masukan melalui serangkaian lapisan, mulai dari lapisan konvolusi, lapisan *pooling*, hingga lapisan *fully connected*, dan menghasilkan nilai probabilitas klasifikasi melalui fungsi *Softmax* di tahap akhir. Keunggulan utama CNN terletak pada kemampuannya mengekstrak fitur spesifik dari sebagian area gambar secara hierarkis tanpa perlu memproses seluruh piksel secara mentah, sehingga menghasilkan akurasi deteksi yang jauh lebih tinggi, bahkan pada beberapa eksperimen sebelumnya mencapai angka 99% [4], [7].

Meskipun demikian, terdapat permasalahan yang masih belum banyak dieksplorasi oleh penelitian terdahulu. Sebagian besar sistem deteksi masker yang telah dikembangkan hanya mampu mengklasifikasikan kondisi biner, yaitu apakah seseorang mengenakan masker atau tidak, tanpa mempertimbangkan ketepatan cara penggunaannya.

Padahal, dalam praktik di lapangan masih kerap ditemukan pelanggaran seperti masker yang diturunkan di bawah hidung, posisi dagu yang tidak tertutup, atau masker yang dilepas saat berbicara [3], [8].

Dalam konteks pencegahan Hantavirus, kondisi tersebut berpotensi meningkatkan risiko paparan partikel aerosol yang terkontaminasi karena hidung atau mulut tidak terlindungi secara optimal.

Untuk mengatasi permasalahan tersebut, penelitian ini menerapkan metode Convolutional Neural Network (CNN) untuk mengklasifikasikan penggunaan masker wajah ke dalam tiga kategori, yaitu *incorrect_mask*, *with_mask*, dan *without_mask*. Model CNN dibangun menggunakan Face Mask Detection Dataset dan dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, serta *confusion matrix* untuk mengukur kinerja klasifikasi yang dihasilkan. Dengan pendekatan tersebut, penelitian ini bertujuan untuk menganalisis kinerja CNN dalam mengidentifikasi ketepatan penggunaan masker wajah berdasarkan citra digital sehingga dapat menjadi dasar pengembangan sistem pemantauan penggunaan masker secara otomatis pada area publik yang rentan terhadap penyebaran penyakit.

2. TINJAUAN PUSTAKA

2.1. Computer Vision

Computer Vision merupakan salah satu bidang dalam kecerdasan buatan yang berfokus pada bagaimana komputer dapat memperoleh, mengolah, dan memahami informasi dari citra digital atau video [9].

Tujuan utama dari *Computer Vision* adalah meniru kemampuan penglihatan manusia dalam mengenali objek, pola, dan informasi visual lainnya [10].

Dalam penerapannya, *Computer Vision* digunakan dalam berbagai bidang seperti pengenalan wajah, deteksi objek, pengolahan citra medis, serta sistem keamanan [11].

Pada penelitian ini, *Computer Vision* digunakan untuk mendeteksi penggunaan masker wajah berdasarkan citra digital [6].

2.2. Citra Digital

Citra digital merupakan representasi visual dari suatu objek yang disimpan dalam bentuk digital, terdiri dari kumpulan piksel (*pixel*). Setiap piksel memiliki nilai tertentu yang merepresentasikan warna atau intensitas cahaya [12].

Citra digital menjadi input utama dalam proses pengolahan citra menggunakan metode *machine learning* maupun *deep learning* [10].

Dalam penelitian ini, citra digital yang digunakan berupa gambar wajah manusia yang kemudian diklasifikasikan ke dalam dua kategori, yaitu menggunakan masker dan tidak menggunakan masker.

2.3. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu metode dalam *Deep Learning* yang dirancang khusus untuk mengolah data berbentuk citra [12].

CNN memiliki kemampuan untuk mengekstraksi fitur secara otomatis dari gambar tanpa memerlukan proses ekstraksi fitur secara manual [9]. CNN terdiri dari beberapa layer utama, yaitu:

- Convolutional Layer*, Layer ini berfungsi untuk mengekstraksi fitur dari citra dengan menggunakan filter atau kernel. Hasil dari proses ini adalah *feature map* yang merepresentasikan pola tertentu dari gambar [10].
- Pooling Layer*, *Pooling layer* digunakan untuk mengurangi dimensi data sekaligus mempertahankan informasi penting. Teknik yang umum digunakan adalah *max pooling* [12].
- Fully Connected Layer*, Layer ini berfungsi untuk melakukan proses klasifikasi berdasarkan fitur yang telah diekstraksi sebelumnya [9].

Keunggulan CNN dibandingkan metode lain adalah kemampuannya dalam mengenali pola visual dengan tingkat akurasi yang tinggi serta efisien dalam pengolahan data citra.

2.4. Klasifikasi Citra

Klasifikasi citra merupakan proses pengelompokan gambar ke dalam kategori tertentu berdasarkan karakteristik atau fitur yang dimiliki. Dalam konteks *machine learning*, klasifikasi dilakukan dengan melatih model menggunakan data latih (*training data*) sehingga model dapat mengenali pola tertentu [10].

Pada penelitian ini, klasifikasi citra dilakukan untuk membedakan antara wajah yang menggunakan masker dan wajah yang tidak menggunakan masker. Model CNN dilatih menggunakan dataset citra wajah sehingga mampu melakukan prediksi terhadap data baru [6].

2.5. Evaluasi Model

Evaluasi model merupakan tahap krusial untuk mengukur sejauh mana model *deep learning* mampu menggeneralisasi data yang belum pernah dilihat sebelumnya [9].

Dalam penelitian berbasis klasifikasi citra, kinerja model diukur menggunakan beberapa parameter utama sebagai berikut:

- Akurasi (Accuracy)*
Akurasi mendefinisikan tingkat keberhasilan model dalam memprediksi kelas secara tepat dibandingkan dengan keseluruhan jumlah data uji [11].
Semakin tinggi persentase akurasi, maka semakin valid model tersebut dalam mengenali objek, dalam hal ini adalah penggunaan masker wajah [6].
- Loss*
Loss atau fungsi kerugian merepresentasikan selisih antara nilai prediksi model dengan nilai

aktual pada dataset. Penurunan nilai *loss* selama proses pelatihan menjadi indikator bahwa model sedang belajar untuk meminimalkan kesalahan prediksi secara efektif [9].

Nilai *loss* yang rendah pada data validasi menunjukkan stabilitas performa model.


Selain metrik di atas, evaluasi sering kali melibatkan *precision* (ketepatan prediksi positif) dan *recall* (kemampuan model menemukan kembali seluruh data positif) untuk memastikan model tidak condong pada satu kelas saja, terutama jika jumlah dataset tidak seimbang [11].

Berbagai penelitian telah membuktikan efektivitas *Convolutional Neural Network* (CNN) dalam deteksi masker wajah. Payana dkk. [12] memperoleh akurasi sebesar 92,28% menggunakan metode CNN untuk klasifikasi penggunaan masker wajah. Naufal dan Kusuma [10] membandingkan beberapa arsitektur CNN berbasis *transfer learning* dan memperoleh akurasi terbaik sebesar 98,8% menggunakan arsitektur Xception.

Pradana dkk. [6] mengombinasikan CNN dan *Haar Cascade* untuk mendeteksi penggunaan masker yang benar, tidak tepat, dan tanpa masker dengan akurasi sebesar 97%.

Sementara itu, Sopian dkk. [9] mengembangkan sistem deteksi masker berbasis MobileNet dan memperoleh akurasi sebesar 99%. Hasil penelitian tersebut menunjukkan bahwa CNN memiliki performa yang baik dalam klasifikasi masker wajah sehingga dipilih sebagai metode utama dalam penelitian ini. Meskipun demikian, sebagian besar penelitian terdahulu berfokus pada deteksi penggunaan masker secara umum, sehingga masih diperlukan analisis lebih lanjut terhadap kemampuan CNN dalam mengklasifikasikan penggunaan masker ke dalam tiga kategori, yaitu *with_mask*, *without_mask*, dan *incorrect_mask*.

3. METODE PENELITIAN



Gambar 1. Alur Penelitian

Untuk mempermudah pelaksanaan penelitian, disusun kerangka tahapan penelitian agar proses yang dilakukan dapat berjalan secara sistematis, terstruktur, dan efisien. Alur penelitian ini terdiri dari beberapa tahapan utama yang dapat dilihat pada Gambar 1.

4.1. Pengumpulan Dataset

Penelitian ini memanfaatkan dataset *Face Mask Detection* (FMD) yang diunduh dari platform Kaggle. Dataset mencakup tiga kategori, yakni *incorrect_mask*, *with_mask*, dan *without_mask*. Total citra yang digunakan berjumlah 14.536, dengan rincian 5.000 citra *incorrect_mask*, 4.789 citra *with_mask*, dan 4.747 citra *without_mask*. Seluruh data tersebut kemudian dibagi menjadi dua bagian, yaitu data pelatihan dan data validasi, yang masing-masing berperan dalam proses pengembangan model *Convolutional Neural Network* (CNN).


4.2. Pre-Processing

Sebelum data digunakan untuk melatih model, terlebih dahulu dilakukan tahap *pre-processing* guna memastikan kualitas dan konsistensi data. Adapun langkah-langkah yang ditempuh adalah sebagai berikut:

- Loading Dataset*, seluruh citra dari tiap kelas dibaca dan dimuat ke dalam sistem.
- Resizing Image*, ukuran setiap citra diseragamkan agar sesuai dengan kebutuhan *input* model CNN.
- Normalisasi Data, nilai piksel pada setiap citra dikonversi ke rentang 0–1, yang bertujuan mempercepat konvergensi selama pelatihan.
- Data Augmentation, citra mengalami berbagai transformasi seperti rotasi, *zoom*, dan pergeseran posisi untuk memperkaya variasi data pelatihan.
- Pembagian Dataset, data dibagi menjadi subset *training* dan *validation* sesuai proporsi yang ditentukan.

4.3. Arsitektur CNN

Model klasifikasi dibangun di atas kerangka *Convolutional Neural Network* (CNN). Secara umum, arsitektur ini tersusun dari beberapa lapisan utama: *Convolution Layer*, *Max Pooling Layer*, *Flatten Layer*, *Dense Layer*, dan *Output Layer*. *Convolution Layer* bertugas menggali dan mengekstraksi fitur-fitur penting yang terkandung dalam citra, sementara *Max Pooling Layer* mereduksi dimensi representasi fitur agar komputasi lebih efisien. Hasil ekstraksi tersebut kemudian diratakan menjadi vektor satu dimensi melalui *Flatten Layer*, lalu diteruskan ke *Dense Layer* untuk proses pengambilan keputusan klasifikasi. Pada lapisan akhir, fungsi aktivasi Softmax digunakan untuk memetakan output ke salah satu dari tiga kelas: *incorrect_mask*, *with_mask*, atau *without_mask*. Diagram arsitektur CNN pada Gambar 2 menunjukkan alur pemrosesan data mulai dari citra masukan hingga menghasilkan prediksi kelas penggunaan masker wajah.



Gambar 2. Diagram arsitektur CNN

4.4. Pelatihan Model

Model dilatih menggunakan data training yang telah melewati seluruh tahap *pre-processing*. Proses pelatihan berlangsung selama 10 epoch dengan memanfaatkan *optimizer* Adam dan fungsi loss *categorical_crossentropy*. Pada setiap epoch, model menjalani siklus *forward propagation* dan *backpropagation* secara bergantian guna memperbarui bobot jaringan secara bertahap, sehingga model semakin mampu mengenali pola penggunaan masker dari data yang tersedia.

9. Training Model

```

from tensorflow.keras.callbacks import EarlyStopping

early_stop = EarlyStopping(
    monitor='val_loss',
    patience=5,
    restore_best_weights=True
)

history = model.fit(
    train_generator,
    epochs=10,
    validation_data=val_generator,
    callbacks=[early_stop]
)
  
```

Gambar 3. Pelatihan Model

4.5. Evaluasi Model

Untuk mengukur sejauh mana model bekerja dengan baik, dilakukan evaluasi menggunakan sejumlah metrik, yaitu *Accuracy*, *Loss*, *Precision*, *Recall*, dan *F1-Score*. Di samping itu, *Confusion Matrix* turut digunakan untuk melihat secara rinci sebaran prediksi yang benar maupun yang keliru pada masing-masing kelas. Nilai *accuracy* memberikan gambaran umum tentang ketepatan klasifikasi secara keseluruhan, sedangkan *precision*, *recall*, dan *F1-score* lebih berfokus pada performa model di tingkat kelas secara individual.

4.6. Analisis Hasil

Tahap akhir dari metodologi ini adalah menginterpretasikan seluruh hasil evaluasi, meliputi nilai *accuracy*, *loss*, *confusion matrix*, serta *classification report*. Analisis diarahkan pada kemampuan model dalam membedakan ketiga kelas penggunaan masker. Hasil tersebut kemudian dikontraskan dengan temuan dari penelitian-penelitian sebelumnya guna menilai efektivitas CNN dalam konteks klasifikasi masker wajah. Selain itu, kelas dengan tingkat kesalahan klasifikasi tertinggi diidentifikasi secara khusus sebagai bahan refleksi dan titik tolak perbaikan pada penelitian berikutnya.

4. HASIL DAN PEMBAHASAN

4.1. Deskripsi Dataset

Penelitian ini menggunakan Face Mask Detection Dataset yang mencakup tiga kategori, yakni *incorrect_mask*, *with_mask*, dan *without_mask*. Dataset ini bersumber dari platform Kaggle dan difungsikan sebagai bahan pelatihan sekaligus pengujian model CNN. Keseluruhan data yang digunakan berjumlah 14.536 citra, terdiri dari 5.000 citra *incorrect_mask*, 4.789 citra *with_mask*, dan 4.747 citra *without_mask*. Proporsi data antar kelas terbilang cukup berimbang, kondisi ini secara langsung membantu menekan potensi bias yang bisa muncul selama proses pelatihan.

Tabel 1. Deskripsi Dataset

Kelas	Jumlah Data
Incorrect Mask	5.000
With Mask	4.789
Without Mask	4.747
Total	14.536

Merujuk pada Tabel 1, selisih jumlah data antar kelas sangat kecil dan tidak signifikan. Kondisi distribusi yang hampir merata ini memungkinkan model mendapatkan pemahaman yang proporsional terhadap setiap kelas dalam proses pembelajaran.

4.2. Hasil Preprocessing

Pre-processing dijalankan sebagai langkah persiapan sebelum data masuk ke tahap pelatihan model CNN. Proses ini mencakup penyeragaman ukuran citra (*resizing*), normalisasi nilai piksel, penerapan augmentasi data, serta pembagian dataset menjadi subset pelatihan dan validasi. Penyeragaman ukuran dilakukan agar seluruh citra dapat diproses secara konsisten oleh model.

Di samping itu, augmentasi data diterapkan untuk memperluas variasi citra pelatihan, sehingga model lebih tangguh dalam menghadapi perbedaan sudut pandang, orientasi objek, maupun kondisi pencahayaan. Langkah ini secara keseluruhan bertujuan menekan risiko *overfitting* sekaligus memperkuat kemampuan generalisasi model terhadap data baru.

4.3. Arsitektur CNN

Model yang dibangun dalam penelitian ini berbasis *Convolutional Neural Network* (CNN), yang tersusun atas lima lapisan utama: *Convolution Layer*, *Pooling Layer*, *Flatten Layer*, *Dense Layer*, dan *Output Layer*. Lapisan konvolusi berperan dalam mengekstraksi fitur-fitur visual yang relevan dari citra masker, sementara lapisan *pooling* mereduksi dimensi representasi fitur untuk meningkatkan efisiensi komputasi.

Fitur yang telah diekstraksi kemudian diratakan menjadi vektor satu dimensi melalui *Flatten Layer*, sebelum akhirnya dialirkan ke *Dense Layer* untuk proses penentuan kelas. Pada lapisan keluaran, fungsi

aktivasi *Softmax* digunakan untuk mengkonversi nilai tersebut menjadi probabilitas di antara tiga kelas target: *incorrect_mask*, *with_mask*, dan *without_mask*.


4.4. Hasil Pelatihan Model

Pelatihan model dijalankan selama 10 epoch dengan menggunakan *optimizer* Adam dan fungsi *loss categorical_crossentropy*. Dari proses tersebut, model berhasil mencapai akurasi pelatihan sebesar 97,62% dengan nilai *loss* 0,0698.


Tabel 2. Hasil Pelatihan Model

Parameter	Nilai
Epoch	10
Training Accuracy	97,62%
Training Loss	0,0698
Validation Accuracy Terbaik	81,00%
Validation Loss Terbaik	0,5824

Angka-angka tersebut mencerminkan bahwa model cukup berhasil menyerap pola penggunaan masker dari data pelatihan. Meski demikian, kesenjangan yang cukup lebar antara akurasi pelatihan dan akurasi validasi menjadi sinyal awal adanya kecenderungan *overfitting* pada model. Jika di visualisasikan dalam bentuk grafik maka akan tampak seperti pada gambar 1 dan gambar 2 berikut.



Gambar 1. Grafik Akurasi



Gambar 2. Grafik Loss


4.5. Evaluasi Model Menggunakan Confusion Matrix

Guna melihat sebaran prediksi secara lebih terperinci, evaluasi dilakukan menggunakan confusion matrix. Hasilnya terangkum dalam Tabel 3 berikut.

Tabel 3. Hasil Confusion Matrix

Actual Class	Incorrect Mask	With Mask	Without Mask
Incorrect Mask	990	1	9
With Mask	35	620	302
Without Mask	29	203	717

Dari Tabel 3 tampak bahwa model bekerja sangat baik pada kelas *incorrect_mask*, dengan 990 dari 1.000 citra berhasil diprediksi secara tepat. Namun, tingkat kesalahan yang cukup mencolok terjadi pada dua kelas lainnya, yakni antara *with_mask* dan *without_mask*. Hal ini mengindikasikan bahwa kedua kelas tersebut memiliki kemiripan karakteristik visual yang membuat model kesulitan membedakannya. Dapat dilihat pada gambar 3 dibawah ini visualisasi dari *confusion matrix*.



Gambar 3. Confusion Matrix

4.6. Hasil Precision, Recall, dan F1-Score

Evaluasi dilengkapi dengan perhitungan *precision*, *recall*, dan *F1-score* untuk setiap kelas, sebagaimana ditunjukkan pada Tabel 4.

Tabel 4. Hasil Classification Report

Kelas	Precision	Recall	F1-Score
Incorrect Mask	0,94	0,99	0,96
With Mask	0,75	0,65	0,7
Without Mask	0,7	0,76	0,73

Kelas *incorrect_mask* mencatatkan performa tertinggi dengan *precision* 94%, *recall* 99%, dan *F1-score* 96%, menandakan model sangat andal dalam mendeteksi pemakaian masker yang tidak benar. Sementara itu, kelas *with_mask* dan *without_mask* masing-masing memperoleh *F1-score* sebesar 70% dan 73%, yang mengindikasikan masih adanya ruang perbaikan dalam membedakan kedua kategori tersebut.

4.7. Analisis dan Pembahasan Hasil

Berdasarkan pengujian yang telah dilakukan, model CNN yang dibangun pada penelitian ini berhasil mencapai akurasi keseluruhan sebesar 80,08%. Angka tersebut mencerminkan kemampuan model dalam

mengklasifikasikan sekitar delapan dari sepuluh citra secara tepat, dan menjadi bukti bahwa CNN memiliki potensi yang layak untuk diterapkan dalam sistem klasifikasi penggunaan masker berbasis citra digital. Merujuk pada hasil *classification report*, kelas *incorrect_mask* menunjukkan performa paling unggul di antara ketiga kelas, dengan nilai *precision* 94%, *recall* 99%, dan *F1-score* 96%. Capaian ini mengindikasikan bahwa model sangat handal dalam mendeteksi kondisi pemakaian masker yang tidak sesuai aturan. Temuan ini memiliki nilai praktis yang signifikan, mengingat masih banyak ditemukan pelanggaran cara penggunaan masker di ruang publik, seperti pemakaian di bawah hidung atau posisi masker yang tidak menutup hidung dan mulut secara sempurna kondisi yang tetap berpotensi mempercepat penyebaran penyakit menular [6].

Di sisi lain, kelas *with_mask* dan *without_mask* memperlihatkan nilai yang lebih rendah. Kelas *with_mask* memperoleh *precision* 75%, *recall* 65%, dan *F1-score* 70%, sementara kelas *without_mask* mendapatkan *precision* 70%, *recall* 76%, dan *F1-score* 73%. Nilai ini jauh di bawah kelas *incorrect_mask* dan menunjukkan bahwa model masih menghadapi tantangan dalam membedakan kedua kelas tersebut. Fenomena serupa juga dijumpai pada penelitian Pradana [6], di mana kelas penggunaan masker yang tidak tepat cenderung memiliki kemiripan visual yang cukup tinggi dengan kelas pemakaian masker yang benar, sehingga lebih sulit dibedakan oleh model.

Kondisi tersebut diperkuat oleh hasil *confusion matrix* yang memperlihatkan 302 citra *with_mask* salah diprediksi sebagai *without_mask*, dan sebaliknya 203 citra *without_mask* salah diklasifikasikan sebagai *with_mask*. Faktor-faktor seperti variasi sudut pengambilan gambar, kondisi pencahayaan, posisi wajah, serta keragaman bentuk dan warna masker turut berkontribusi pada tingginya angka misklasifikasi tersebut [6].

Dari sisi pelatihan, diperoleh *training accuracy* sebesar 97,62% dengan *validation accuracy* terbaik sebesar 81,00%. Selisih yang cukup besar antara keduanya menjadi indikator adanya *overfitting*, yaitu kondisi di mana model terlalu menyesuaikan diri dengan pola data pelatihan sehingga kemampuan generalisasinya pada data baru menjadi terbatas. Fenomena ini merupakan tantangan umum dalam pengembangan model CNN, terutama ketika arsitektur yang digunakan belum dilengkapi mekanisme regulasi yang memadai seperti *dropout* atau *early stopping* [6].

Apabila dibandingkan dengan penelitian-penelitian sebelumnya, akurasi yang diperoleh dalam penelitian ini memang masih berada di bawah capaian beberapa studi terdahulu. Payana et al [12] melaporkan akurasi sebesar 92,28% dengan menggunakan 7.500 citra dan 20 epoch pelatihan, di mana model berhasil mendeteksi penggunaan masker dari berbagai sudut pengambilan gambar dengan tingkat false negative yang sangat rendah.

Pradana et al. [6] mencapai akurasi lebih tinggi yakni 97% dengan rata-rata *F1-score* 0,97 menggunakan kombinasi algoritma CNN dan Haar Cascade pada dataset tiga kelas. Sementara itu, Sopian et al. [9] memperoleh akurasi tertinggi sebesar 99% menggunakan arsitektur *MobileNet* dengan teknik *transfer learning*, yang terbukti sangat efisien karena mampu menghasilkan performa tinggi sekaligus menjaga latensi deteksi tetap rendah saat diimplementasikan secara *real-time*.

Perbedaan hasil tersebut dapat dipahami dari beberapa sudut pandang. Payana et al. [12] hanya menggunakan dua kelas klasifikasi, sehingga kompleksitas permasalahannya relatif lebih sederhana dibandingkan penelitian ini yang menggunakan tiga kelas.

Pradana et al. [6] memperkuat arsitektur CNN-nya dengan algoritma Haar Cascade untuk deteksi wajah serta menerapkan *preprocessing grayscale* yang dapat menyederhanakan ruang fitur, sehingga model lebih fokus pada pola struktural wajah. Sedangkan Sopian et al. [9] menggunakan *MobileNet* yang merupakan arsitektur jauh lebih dalam dan telah dioptimalkan melalui *transfer learning* dari model yang sudah dilatih pada dataset besar, sehingga kemampuan ekstraksi fiturnya jauh lebih kaya dibandingkan CNN yang dibangun dari awal (*from scratch*).

Meski demikian, penelitian ini memiliki keunggulan tersendiri yang perlu digarisbawahi. Dengan menghadirkan tiga kelas klasifikasi sekaligus *incorrect_mask*, *with_mask*, dan *without_mask* sistem yang dihasilkan tidak sekadar mendeteksi ada tidaknya masker, tetapi juga mampu mengidentifikasi kondisi pemakaian yang tidak sesuai. Kemampuan ini menjadikan model lebih relevan dan aplikatif untuk sistem pemantauan kepatuhan penggunaan masker di lingkungan publik [6], [9].

Secara keseluruhan, penelitian ini membuktikan bahwa metode CNN mampu digunakan untuk klasifikasi penggunaan masker wajah dengan performa yang cukup memadai. Temuan paling menonjol adalah tingginya akurasi model pada kelas *incorrect_mask* dengan *F1-score* 96%, sementara tantangan utama yang tersisa adalah membedakan kelas *with_mask* dan *without_mask* yang secara visual memiliki kemiripan cukup tinggi.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian yang telah berjalan, dapat disimpulkan bahwa metode *Convolutional Neural Network* (CNN) berhasil diterapkan untuk mengelompokkan penggunaan masker wajah ke dalam tiga kategori, yaitu *incorrect_mask*, *with_mask*, dan *without_mask*. Model yang dirancang ini mampu mencapai tingkat akurasi keseluruhan sebesar 80,08%. Angka tersebut menunjukkan bahwa CNN memiliki performa yang cukup baik dalam mengenali karakteristik visual pada foto penggunaan masker.

Dari hasil evaluasi, kategori *incorrect_mask* memberikan hasil yang paling optimal dengan nilai *precision* sebesar 94%, *recall* 99%, dan *F1-score* 96%. Temuan ini membuktikan bahwa sistem sangat efektif dalam mendeteksi posisi masker yang keliru. Di sisi lain, akurasi untuk kategori *with_mask* dan *without_mask* masih relatif rendah. Hal ini dipicu oleh adanya kemiripan visual yang cukup tinggi di antara kedua kategori tersebut, sehingga sistem beberapa kali salah dalam melakukan klasifikasi.

Secara keseluruhan, penelitian ini membuktikan bahwa metode CNN layak digunakan untuk mengklasifikasikan penggunaan masker dan punya potensi besar untuk dikembangkan menjadi sistem pemantauan otomatis berbasis computer vision.

Berdasarkan hasil penelitian yang diperoleh, terdapat beberapa saran yang dapat dijadikan acuan bagi penelitian selanjutnya. Pertama, penambahan jumlah dan variasi dataset perlu dilakukan agar model dapat mempelajari lebih banyak karakteristik penggunaan masker sehingga mampu meningkatkan akurasi klasifikasi. Kedua, penerapan teknik augmentasi data yang lebih beragam diperlukan guna meningkatkan kemampuan generalisasi model terhadap berbagai kondisi pencahayaan, sudut pengambilan gambar, maupun posisi wajah.

Selain itu, penggunaan arsitektur *deep learning* yang lebih modern, seperti *MobileNet*, *ResNet*, *EfficientNet*, atau *YOLO* dapat dipertimbangkan sebagai pembanding terhadap kinerja metode CNN yang digunakan pada penelitian ini. Pengembangan sistem deteksi secara real-time menggunakan kamera juga direkomendasikan agar sistem dapat diterapkan secara langsung pada lingkungan publik yang membutuhkan pemantauan kepatuhan penggunaan masker. Lebih lanjut, optimasi parameter pelatihan seperti jumlah *epoch*, *learning rate*, ukuran *batch*, serta jumlah *layer* CNN perlu dilakukan untuk memperoleh performa model yang lebih optimal.

Dengan berbagai pengembangan tersebut, diharapkan sistem klasifikasi penggunaan masker wajah dapat menghasilkan tingkat akurasi yang lebih tinggi serta memiliki kemampuan yang lebih baik dalam membedakan kelas *with_mask* dan *without_mask*.

DAFTAR PUSTAKA

- [1] F. Tortosa *et al.*, "Seroprevalence of hantavirus infection in non - epidemic settings over four decades : a systematic review and meta - analysis," *BMC Public Health*, 2024, doi: 10.1186/s12889-024-20014-w.
- [2] Marissa Farikha Siti Fatimatuazzahra, "UNAIR veterinary technology expert warns of rising hantavirus risks amid climate change," UNAIR News. [Online]. Available: <https://unair.ac.id/en/unair-veterinary-technology-expert-warns-of-rising-hantavirus-risks-amid-climate-change/>
- [3] R. Alturki, M. Alharbi, and F. Alanzi, "Deep learning techniques for detecting and recognizing face masks : A survey," *J. Front. Public Heal.*, vol. 10, no. September 2022, p. 3389, 2022.
- [4] S. Rasheed, "Lightweight Deep Learning Models for Face Mask Detection in Real-Time Edge Environments : A Review and Future Research Directions," *Mach. Learn. Knowl. Extr.*, vol. 8, no. 4, 2026.
- [5] P. Dubey, P. Dubey, and D. D. Rao, "Enhanced IoT-Based Face Mask Detection Framework Using Optimized Deep Learning Models : A Hybrid Approach With Adaptive Algorithms," *IEEE Access*, vol. 13, no. January, pp. 17325–17339, 2025, doi: 10.1109/ACCESS.2025.3532764.
- [6] H. Afu Ichsan Pradana, Robi Wariyanto Abdullah, "Deteksi Ketepatan Penggunaan Masker Wajah Dengan Algoritma CNN Dan," *J. Tek. Inform. dan Sist. Inf.*, vol. 9, no. 3, pp. 2305-2316 ISSN, 2022.
- [7] I. Candradewi, B. A. A. S, A. Harjoko, and A. Dharmawan, "Comparative Analysis of Face Mask Detection using Lightweight CNN and Bag of Visual Word-based Classifier for Real-Time Surveillance," *J. Tek. Inform.*, vol. 7, no. 1, pp. 210–225, 2026.
- [8] G. Valenzuela *et al.*, "Beyond ECMO Survival : Long-Term Symptom Burden and Quality-of-Life Impairment in Hantavirus Cardiopulmonary Syndrome Survivors," *Viruses*, vol. 17, no. 9, pp. 1–15, 2025.
- [9] A. Sopian, D. Setiadi, A. Suryatno, and R. Agustino, "Computer Vision : Deteksi Masker Wajah Prediksi Usia Jenis Kelamin dengan Teknik Deep Learning Menggunakan Algoritma Convolutional Neural Network (CNN) atau tidak . Teknologi computer vision muncul sebagai solusi potensial untuk mempermudah atau bahkan," *J. Teknologi Inform. dan Komput. MH. Thamrin*, vol. 10, no. 2, pp. 720–733, 2024.
- [10] M. F. Naufal, S. F. Kusuma, U. Surabaya, P. Korespondensi, and T. Learning, "Pendeteksi Citra Masker Wajah Menggunakan Cnn Dan Transfer," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 6, pp. 1293–1300, 2021, doi: 10.25126/jtiik.202185201.
- [11] A. M. W. Muh. Firizki, Brian Brilliant, "Sistem Deteksi Masker Wajah Menggunakan CNN untuk Akses Pintu Otomatis," *MDP STUDENT Conf.*, vol. 5, no. 2, pp. 851–858, 2025.
- [12] M. D. Payana, D. Ria, Y. Tb, Z. Musliyana, and M. B. Wibawa, "Deteksi Masker Wajah Menggunakan Metode Convolutional Neural Network (Cnn) Meningkatkan Nilai Akurasi Melalui Arsitektur Layer Konvolusi Face Mask Detection Using Convolutional Neural Network (Cnn) Method To Increase Accuracy Value Through Convolution," *J. Informatics Comput. Sci.*, vol. 8, no. 1, pp. 30–35, 2022.