

3591-9517-1-RV

by jiko unkhair

Submission date: 08-Nov-2021 03:27PM (UTC-0700)

Submission ID: 1693847844

File name: 3591-9517-1-RV.docx (1.29M)

Word count: 3728

Character count: 23275

DETEKSI MASKER WAJAH MENGGUNAKAN DEEP TRANSFER LEARNING DAN AUGMENTASI GAMBAR

Raden B. Hadiprakoso¹, Nurul Qomariasih²

1,2 Politeknik Siber dan Sandi Negara
Email: ¹raden.budiarto@poltekssn.ac.id, ²nurul.qomariasih@ poltekssn.ac.id

25
(Naskah masuk: dd mmm yyyy, diterima untuk diterbitkan: dd mmm yyyy)

Abstrak

Pandemi COVID-19 saat ini merupakan masalah kesehatan global. Menurut WHO, memakai masker wajah di depan umum adalah metode perlindungan yang efektif. Mengenakan masker merupakan salah satu gerakan 3M untuk pencegahan virus corona (selain mencuci tangan dan menjaga jarak). Bagaimana pun pengawasan pemakaian masker di ruang publik yang ramai bukanlah tugas yang mudah. Makalah ini mengusulkan penggunaan deep learning untuk mendeteksi orang yang memakai masker wajah dengan benar, memakai masker namun tidak benar dan yang tidak memakai masker. Kami menerapkan transfer learning dan augmentasi gambar, untuk meningkatkan kinerja model deep learning diusulkan secara keseluruhan. Penelitian ini menggunakan dataset CelebA untuk wajah tidak memakai masker dan dataset maskedface net untuk wajah yang bermasker dengan benar dan yang memakainya tapi tidak benar (seperti hanya menutupi mulutnya). Dengan menggunakan augmentasi gambar dan pembelajaran transfer, model yang dibangun mencapai akurasi 98,3% dan skor F1 98,7% pada dataset validasi. Hasil pengujian menunjukkan bahwa teknik augmentasi gambar dan transfer learning mampu meningkatkan akurasi model secara keseluruhan.

Kata kunci: deteksi masker wajah, deep learning, transfer learning, augmentasi gambar

22 FACE MASK DETECTION USING DEEP TRANSFER LEARNING AND IMAGE AUGMENTATION

32 Abstract

The COVID-19 coronavirus pandemic is producing a global health crisis. According to the World Health Organization (WHO), wearing a face mask in public places is one of the most efficient protection techniques. Wearing a mask is one of the viral actions (together with washing hands and keeping physical distance) used to prevent the spread of the coronavirus. However, supervising the public in a busy public arena is a difficult task. This paper proposes using a deep learning model to recognize people who are not wearing a face mask, wearing a face mask improperly, or wearing a face mask correctly. A deep neural network model was created to increase overall performance by integrating an image augmentation approach with transfer learning techniques. This study employs the CelebA dataset for faces that do not wear masks and the maskedface net dataset for individuals who correctly wear masks and incorrectly wear a face mask (such as only covering their mouths). Using image augmentation and transfer learning, the developed model scored 98.3 % accuracy and 98.7 % F1 score during testing on the validation dataset. According to the test results, image augmentation and transfer procedures have improved the model's overall accuracy.

Keywords: face mask detection, deep learning, transfer learning, image augmentation

1. PENDAHULUAN

Dunia saat ini dihadapkan dengan masalah kesehatan sebagai akibat dari pandemi COVID-19. Virus Covid-19 menyebar dengan cepat ke seluruh dunia dari asalnya di Wuhan, Cina, pada akhir tahun 2019. Organisasi Kesehatan Dunia (WHO) menetapkan Covid-19 sebagai pandemi global pada Maret 2020 [1]. Sementara beberapa negara sudah mulai pulih dari pandemi Covid-19, pandemi ini masih terus memiliki efek jangka panjang di sejumlah negara, terutama negara-negara berkembang seperti India, Brasil, dan Indonesia [2]. Virus *corona* telah berevolusi menjadi beberapa subtype. Menurut WHO, varian delta dari virus *corona* adalah yang paling menular. Sejak ditemukan pada Oktober 2020 di India, varian Delta telah menyebar dengan cepat ke lebih dari 100 negara [3].

WHO dan pemerintah republik Indonesia telah mengeluarkan berbagai upaya untuk perlindungan diri terhadap penyebaran virus *corona*. Salah satunya adalah anjuran untuk mengenakan masker di tempat umum sebagai bentuk perlindungan terhadap COVID-19 [4]. Hal ini terutama pada tempat publik yang ramai, ketika pembatasan sosial sulit dilakukan.. Melalui penggunaan masker diharapkan mengurangi risiko penularan dari orang yang terinfeksi ke orang yang sehat, pada akhirnya penyebaran virus bisa sangat berkurang. Selain itu, WHO menyarankan semua orang yang telah divaksinasi lengkap untuk terus memakai masker dan secara ketat mengikuti peraturan kesehatan [5]. Pasalnya, mereka yang sudah divaksinasi tetap berisiko tertular Covid-19. Untuk mengurangi bahaya penularan Covid-19 dan peningkatan kasus terkait, pemerintah Indonesia telah meminta agar masyarakat menggunakan masker saat keluar rumah melalui satuan tugas Covid-19. Penggunaan masker merupakan salah satu dari gerakan 3M (memakai masker, mencuci tangan, menjaga jarak) yang viral didengungkan untuk mencegah penularan virus *corona*.

Penggunaan masker wajah telah terbukti efektif terhadap varian Covid-19 jenis apapun [6]. Pada banyak negara, penduduk diwajibkan oleh peraturan setempat untuk memakai masker wajah di tempat umum. Berbagai tempat umum, termasuk bandara, rumah sakit, dan stasiun kereta api, terminal bus kini membutuhkan masker untuk individu yang bepergian. Demikian pula untuk memasuki kantor atau sekolah mewajibkan penggunaan masker [7].

Meskipun demikian, pekerjaan mengawasi masyarakat di ruang publik yang ramai menjadi masalah yang tidak mudah. Akibatnya, identifikasi masker wajah telah menjadi pekerjaan penting dalam bidang ilmu *computer vision* untuk membantu mengidentifikasi siapa yang mengenakan masker dan yang tidak serta yang mengenakan masker namun tidak benar seperti hanya menutup mulut. Hal ini

dapat menjadi tantangan karena terdapat macam warna maupun model masker wajah yang digunakan seseorang.

Masalah ini telah menarik perhatian berbagai penelitian untuk mencoba mengembangkan model deteksi untuk menentukan apakah seseorang memakai masker wajah atau tidak. Sebuah metode untuk mengidentifikasi penggunaan masker wajah dikembangkan dalam penelitian [8]. Dalam penelitian ini, penggunaan masker wajah menjadi dua kategori: mereka yang memakainya dengan benar, mereka yang tidak. Peneliti [9] menggunakan model *Convolution Neural Network* (CNN) dan akurasi model yang diusulkan sebesar 97,2 persen.

Makalah [10] menggunakan TensorFlow, Keras, dan OpenCV untuk membuat model deteksi masker wajah. Model dapat diterapkan pada perangkat seluler karena penggunaan memori yang sangat sedikit. Hasil pengujian makalah ini menunjukkan akurasi 0,92 dan nilai F1 0,93. Untuk membedakan pemakaian masker wajah atau tidak, peneliti [11] menggunakan gabungan *deep learning* dan algoritma *machine learning*. Algoritma *machine learning* seperti *Support Vector Machine* (SVM) dan algoritma *ensemble* digunakan untuk mengklasifikasikan fitur yang diambil model Resnet50. Tingkat akurasi 98,49% dalam simulasi data dicapai oleh algoritma SVM.

Pada makalah ini, kami menyajikan model untuk mendeteksi masker wajah menggunakan *deep learning*. Model yang diusulkan dilatih menggunakan model pre-trained MobileNet V2 sehingga memiliki performa yang ringan dan dapat diimplementasikan pada perangkat mobile. Selain itu, kami menggunakan *image augmentation* untuk meningkatkan akurasi model secara terhadap perubahan latar belakang, tingkat kecerahan serta berbagai atribut gambar lainnya.

Secara spesifik, hal yang membedakan kontribusi penelitian ini dengan sebelumnya adalah (1) Kami menggunakan 3 label kelas: memakai masker, tidak memakai masker dan memakai masker yang tidak benar dengan jumlah besar (lebih 200.000 gambar) (2) Kami menerapkan *image augmentation* pada *dataset* gambar sehingga memperkaya data latih terhadap berbagai kondisi inputan sesuai dunia nyata. (3) Kami menggunakan *deep transfer learning* MobileNet sehingga membuat model yang dihasilkan lebih akurat serta tetap ringan digunakan pada perangkat *mobile* atau perangkat IoT (Internet of Things) seperti Raspberry.

2. METODE PENELITIAN

Pada penelitian ini, kami menghadirkan model *deep learning* berbasis arsitektur transfer learning dan attention model untuk mendeteksi penggunaan masker wajah. Alur penelitian yang kami lakukan

antara lain: (1) pengumpulan data; (2) pra-pemrosesan data; (3) membangun model; (4) pelatihan dan evaluasi model. Gambar 1 menggambarkan alur dan temuan studi secara keseluruhan.



Gambar 1. Alur penelitian

2.1 Pengumpulan Data

Data dikumpulkan melalui *dataset* yang tersedia secara publik di internet. Pengumpulan data ini dilakukan selama bulan Juli 2021. *Dataset* yang dikumpulkan merupakan gabungan dari 3 kelas kategori yang berbeda. Pertama gambar seseorang yang mengenakan masker wajah dengan benar, kedua mengenakan masker wajah namun salah dan ketiga tidak menggunakan masker wajah sama sekali.

Untuk *dataset* kategori pertama dan kedua kami menggunakan *dataset* maskedface net [12]. Terdapat total 132616 gambar yang terdiri dari, 67.193 gambar orang yang memakai masker dengan benar dan 69.823 gambar orang yang memakai masker namun tidak benar. Secara umum *dataset* ini memiliki berbagai foto orang dari jenis kelamin, etnik, warna kulit yang bervariasi. Keseluruhan *dataset* ini di-generate secara otomatis menggunakan program komputer. Gambar 2 menunjukkan contoh dari *dataset* untuk yang mengenakan masker tidak benar.



Gambar 2. Contoh *dataset* menggunakan masker namun tidak benar

Untuk *dataset* kategori ketiga, gambar orang tidak mengenakan masker, kami menggunakan *dataset* CelebFaces Attributes (CelebA) *Dataset* [13]. *Dataset* ini merupakan kumpulan gambar wajah yang terdiri dari 202.599 gambar. Pada penelitian ini kami hanya mengambil 68.000 gambar. Hal ini dilakukan agar jumlah *dataset* pada masing-masing kelas seimbang. Tabel 1 menjabarkan *dataset* yang digunakan pada penelitian ini.

Tabel 1. *Dataset* yang digunakan

Kelas	Sumber	Jumlah
Memakai masker dengan benar	maskedface net	67.193
Memakai masker dengan tidak benar	maskedface net	69.823
Tidak pakai masker	CelebA	68.000
Total		205.016

2.2 Pra-Pemrosesan Data

Kami melakukan pra-pemrosesan data setelah mengumpulkan *dataset*. Selama tahap ini, data diproses terlebih dahulu sebelumnya gunakan untuk melatih model. Teknik pra-pemrosesan data dilakukan dengan berbagai cara di antaranya: (1) Menyamakan resolusi gambar. (2) Melakukan augmentasi gambar. (3) Membagi *dataset* menjadi dua bagian.

Untuk memulai, kami mengubah ukuran gambar sehingga semua input memiliki ukuran yang sama. Gambar telah disesuaikan menjadi ukuran 100x100 piksel. Kami mengurangi ukuran gambar ke ukuran yang dapat ditoleransi dengan tetap menjaga informasi yang dikandungnya. Hal ini diperlukan agar model dapat berjalan dengan cepat ketika nantinya dilatih pada model yang akan dibuat.

Berikut proses Augmentasi gambar dilakukan. Augmentasi gambar adalah teknik yang berguna untuk memperluas data pelatihan model tanpa perlu mencari data tambahan. Augmentasi gambar, secara sederhana, merupakan tindakan mereplika gambar yang ada dengan berbagai penyesuaian untuk memperbanyak data latih [14]. Memperbesar ukuran gambar +/-20%, flip horizontal, mengubah kecerahan +/-20%, dan memutar gambar +/-10% adalah semua teknik yang kami gunakan untuk meningkatkan jumlah data latih. Model terlatih akan lebih realistis dari kondisi dunia nyata dan akan mampu beradaptasi dengan berbagai perubahan kondisi yang ada.

Terakhir, *dataset* dibagi menjadi kelompok. Delapan puluh persen data digunakan untuk melatih model, dan dua puluh persen digunakan untuk mengujinya. Kami menggunakan 5-fold validasi silang dalam penelitian ini. Selama tahap pelatihan dan pengujian, validasi silang 5-fold akan membagi *dataset* menjadi 5 kelompok yang berukuran sama atau hampir sama namun tidak saling tumpang tindih di mana 80% atau 4/5 dari seluruh *dataset* akan digunakan untuk melatih model dan sisanya untuk menguji model. Gambar 3 menunjukkan bagaimana

validasi silang 5 kali lipat digunakan untuk memartisi data.



Gambar 3. Penerapan 5-fold validasi silang

2.3 Membuat Model

Model yang digunakan pada penelitian ini menggunakan arsitektur *deep transfer learning*. *Transfer learning* pada bidang *computer vision* didasarkan pada premis bahwa model yang dilatih pada kumpulan data besar dari gambar yang tersedia dapat digunakan sebagai model dasar untuk mengenali fitur atau bentuk objek di dunia nyata. Melalui *transfer learning* memungkinkan untuk menggunakan fitur ini tanpa melatih ulang model dari awal [15].

Pada model *deep transfer learning* akan terdapat beberapa lapisan (*layer*) untuk mengenali sebuah objek. Lapisan pertama dan tengah model bertanggung jawab untuk mengenali bentuk dalam gambar. Misalnya, lapisan pertama dalam model pengenalan wajah manusia dapat mengenali garis, lapisan kedua lingkaran, mata lapisan ketiga, dan wajah lapisan keempat. Sekarang lapisan telah dilatih, mereka dapat digunakan dalam kumpulan data lain, yang pada penelitian ini adalah penggunaan masker wajah. Gambar 4 menunjukkan pseudocode model yang diusulkan.

```
model = models.Sequential([MobileNetV2 (
weights="imagenet",
input_tensor=Input(shape=(100, 100, 3))),
layers.Flatten(),
layers.Dense(512, activation='relu'),
layers.Dense(256, activation='relu'),
layers.Dense(128, activation='relu'),
layers.Dense(3, activation='softmax')
])
```

Gambar 4. Pseudocode model yang diusulkan

Pertama pada model yang diusulkan, kami menerapkan model *sequential*. Model *Sequential* adalah arsitektur model digunakan untuk tumpukan lapisan (*layer*) di mana setiap lapisan memiliki tepat satu tensor input dan satu tensor output. Berikutnya pada model *sequential* ini kami menerapkan *transfer learning*. Arsitektur *transfer learning* yang digunakan adalah *MobileNetV2* [16]. *MobileNetsV2* merupakan pengembangan dari *MobileNetsV1* [17] yang memiliki kinerja lebih efektif dan lebih efisien. *MobileNetsV1* sendiri didasarkan pada arsitektur

ramping yang menggunakan konvolusi yang dapat dipisahkan untuk membangun jaringan saraf dalam yang ringan. Arsitektur ini ditujukan untuk model yang diterapkan pada aplikasi mobile atau tertanam.

Berikutnya arsitektur *MobileNetV2* membutuhkan untuk menerima 2 parameter inputan yang utama yakni *weights* dan *input_tensor*. Parameter *weights* merupakan bobot atau *dataset* gambar yang ingin digunakan untuk melatih model. Untuk parameter *weight* ini, kami mengisinya nilai 'imagenet'. Artinya model yang diusulkan akan menggunakan model berbasis *MobileNetV2* yang telah dilatih pada *dataset* imagenet [18]. *Imagenet* merupakan sebuah basis data gambar yang berisi lebih dari 14 juta gambar lengkap dengan anotasinya. *Imagenet* merupakan basis data sumber terbuka yang dapat digunakan dalam penelitian perangkat lunak pengenalan objek visual.

Parameter kedua adalah *Input_tensor*, sesuai namanya parameter ini merupakan ukuran resolusi dari input gambar. Karena pada tahap pra-pemrosesan data kami sudah mengubah ukuran gambar menjadi 100x100 maka di sini parameter diisi dengan nilai (100, 100, 3). Adapun nilai 3 merupakan mode warna gambar yakni RGB (*Red Green Blue*) yang memiliki 3 kanal warna.

Berikut inputan gambar akan di-*flatten* ke dalam bentuk vektor matriks 1 dimensi. Kami menggunakan 3 lapisan *neural network*, lapisan pertama terdiri dari 512 neuron, kedua 256 neuron dan terakhir 128 neuron. Setiap lapisan neuron menggunakan fungsi aktivasi ReLU (*Rectified Linear Unit*). Kegunaan dari fungsi aktivasi adalah untuk membuat model *neural network* supaya tidak linear. Hal ini diperlukan agar klasifikasi menjadi lebih presisi. ReLU pada dasarnya membuat pembatas pada bilangan 0, jika $x \leq 0$ maka $x = 0$ dan jika $x > 0$ maka $x = x$. Rumus fungsi aktivasi ReLU dinyatakan sebagai persamaan (1).

$$f(x) = \max(0, x) \quad (1)$$

Di mana x adalah jumlah neuron

Pada layer terakhir kami menggunakan fungsi aktivasi softmax dengan 3 neuron, yang merepresentasikan label kelas yang memakai masker dengan benar, memakai masker dengan tidak benar, dan tidak memakai masker. Fungsi aktivasi softmax menerima input i vektor z dari K bilangan real dan menormalkannya ke distribusi probabilitas yang sebanding dengan eksponensial angka input. Sebelum menerapkan softmax, beberapa komponen vektor mungkin negatif atau lebih besar dari satu dan mungkin tidak berjumlah satu; namun, setelah menerapkan softmax, setiap komponen akan berada dalam interval $[0, 1]$ dengan tampilan $[0, 1]$ [0,1], dan komponen akan berjumlah satu, memungkinkan untuk ditafsirkan sebagai probabilitas. Selain itu, semakin besar komponen

input, semakin besar kemungkinannya. Persamaan (2) mewakili rumus fungsi softmax.

$$\theta(z)_i = \sum_z^i k_1, k_2, \dots$$

untuk $i = 1, \dots, k$ dan $z(z_1, z_2, \dots) \in R^j$ (2)

2.4 Training dan Evaluasi Model

Setelah model dibuat, model akan dilatih dengan *dataset* yang telah dipra-proses sebelumnya. Proses pelatihan model menggunakan parameter 300 epoch, optimizer Adam, dan learning rate default 0.01. Tolak ukur pengujian model meliputi evaluasi *deep transfer learning* dan *image augmentation*. Sebagai metrik untuk mengevaluasi model, kami menggunakan akurasi, presisi, *recall*, dan skor F1. Persamaan yang digunakan untuk menghitung akurasi, presisi, *recall*, dan skor F1 ditunjukkan pada persamaan 3 sampai 6. Sedangkan *pseudocode* untuk melatih model ditampilkan pada gambar 5.

```
model.compile(optimizer=tf.optimizers.Adam(),
              loss='categorical_crossentropy',
              metrics = ['accuracy'], ['precision'],
                       ['recall'], ['f1_score'])
model.fit(train, val, epochs=300)
```

Gambar 5. Pseudocode pelatihan model

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (3)$$

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

$$F1\ score = \frac{2 * (Recall * Precision)}{Recall + Precision} \quad (6)$$

Di mana, TP (True-Positive), TN (True-Negative), FP (False-Positive) dan FN (False-Negative).

Selama fase penelitian ini, lingkungan perangkat lunak yang digunakan untuk pengumpulan data sampai evaluasi model adalah sistem operasi Windows 10, bahasa pemrograman Python, IDE Jupyter Notebook, dan pustaka Mathlib plot, TensorFlow dan Keras. Adapun *setting* perangkat keras yang digunakan adalah, prosesor Intel Core I7 11050H, memori DDR-4 32GB, dan kartu grafis GPU Quadro T-2000 8GB.

3. HASIL DAN PEMBAHASAN

Kami memproses total sebanyak 205.016 *dataset* gambar yang didapatkan selama tahap pengumpulan data. *Dataset* gambar tersebut termasuk 67.193 gambar yang memakai masker wajah dengan benar, 69.823 gambar yang memakai masker wajah dengan tidak benar, dan sisanya 68.000 gambar yang tidak memakai masker. Model akan dilatih dan diuji menggunakan *dataset* yang telah dipra-proses sebelumnya. Sebanyak 164.013 data digunakan untuk melatih model, sedangkan sisanya 41.003 digunakan untuk memvalidasi model.

Strategi pengujian yang dilakukan melibatkan 3 pendekatan. Pendekatan pertama kami secara langsung mencatat hasil pelatihan dan validasi model tanpa melalui augmentasi gambar dan *transfer learning*. *Dataset* akan dibagi menjadi dua bagian: 80 persen akan digunakan untuk melatih model, sedangkan 20 persen sisanya akan menguji model tanpa menggunakan teknik validasi silang. Strategi pengujian kedua menggunakan augmentasi gambar sebelum model diuji. Adapun strategi pengujian ketiga menggunakan teknik *deep transfer learning* yang dijelaskan dalam sub-bab metodologi penelitian. Pendekatan ini diperlukan untuk menentukan seberapa jauh augmentasi gambar dan *deep transfer learning* meningkatkan kinerja. Gambar 6 menggambarkan akurasi pada saat pelatihan dan validasi.



Gambar 6. Akurasi pada saat pelatihan dan validasi model

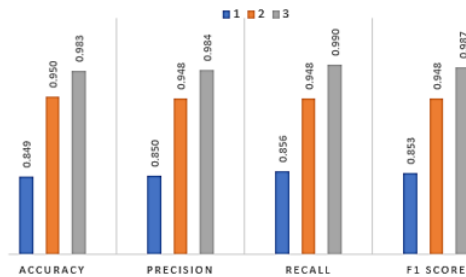
Gambar 6 menunjukkan akurasi model ketika pelatihan mencapai sekitar 90% sedangkan akurasi untuk validasi hanya mencapai kisaran 85%. Dari hasil tersebut didapatkan hasil *training* sudah mencapai nilai yang relatif stabil ketika mencapai epoch ke 60. Adapun pada hasil validasi nilainya akurasi relatif tidak stabil.

Pada percobaan selanjutnya akan dilakukan teknik augmentasi gambar dengan tujuan memperkaya *dataset* dengan berbagai kondisi atribut pada gambar seperti tingkat kecerahan dan sebagainya. Kali ini akan digunakan teknik 5-fold validasi silang, dengan metrik yang diukur adalah akurasi, *recall*, presisi dan skor F1. Hasil pengujian ini dijabarkan pada tabel 2.

Tabel 2. Hasil pengujian model setelah augmentasi *dataset*

	Akurasi	Presisi	Recall	Skor F1
Fold-1	0.9309	0.9481	0.9455	0.9468
Fold-2	0.9448	0.9472	0.9495	0.9483
Fold-3	0.9422	0.9412	0.9497	0.9454
Fold-4	0.9499	0.9404	0.9482	0.9443
Fold-5	0.9437	0.9463	0.9490	0.9476
Avg.	0.9423	0.9446	0.9484	0.9465

Tabel 2 menunjukkan bahwa hasil pengujian menggunakan validasi silang dan augmentasi gambar memberikan hasil yang sangat signifikan lebih baik dari hasil validasi sebelum. Selain itu juga dapat terlihat hasil yang didapat relatif stabil. Hal ini menunjukkan bahwa model sudah fit. Pengujian berikutnya dilakukan dengan menggunakan transfer learning. Sebagai perbandingan kami ³⁶ga menyajikan hasil pengujian sebelumnya. Hasil pengujian ini ditampilkan pada gambar 7.



Gambar 7. Hasil pengujian setelah transfer learning

Gambar 7 menampilkan hasil metrik pengujian di mana kelompok 1 adalah skenario pengujian awal, kelompok 2 adalah setelah augmentasi gambar dan kelompok 3 adalah setelah augmentasi gambar dan transfer learning. Ketika transfer learning diimplementasikan, terjadi peningkatan yang cukup signifikan dalam kinerja model yakni sekitar 3-4% persen. Jika dibandingkan dengan model awal, gabungan teknik augmentasi gambar dan transfer learning memberikan kontribusi peningkatan kinerja sekitar 12-13%. Hasil ini didasarkan pada fakta model deep learning saat dilatih pada kumpulan data besar dapat meningkatkan kinerja secara keseluruhan. Ini dapat dicapai dengan menggunakan augmentasi gambar dan transfer learning. Melalui augmentasi gambar untuk menambah keragaman pada koleksi gambar untuk meniru pengaturan dunia nyata.

Transfer learning untuk pemrosesan gambar didasarkan pada premis bahwa model yang dilatih pada kumpulan data besar dari gambar yang tersedia dapat digunakan sebagai model dasar untuk mengenali properti objek di dunia nyata. Fitur yang dipelajari ini dapat digunakan tanpa melatih model dari awal. Transfer learning pada dasarnya merupakan proses penerapan model yang telah dilatih sebelumnya pada dataset lain dengan jumlah yang masif untuk model sendiri. Fakta ini memungkinkan untuk meningkatkan hasil akurasi secara signifikan.

4. KESIMPULAN ²³

Akibat dari pandemi COVID-19, dunia saat ini sedang mengalami bencana kesehatan yang sangat besar. Berbagai negara di belahan dunia berjuang untuk menghentikan penyebaran virus corona. ³³ngunakan masker wajah di tempat umum merupakan salah satu upaya mengurangi penularan

virus Covid-19. Bagaimana pun sulit untuk mengawasi penggunaan masker di tempat keramaian. Makalah ini mengusulkan sebuah model deep learning untuk mengenali orang yang tidak memakai masker dengan benar, mengenakan masker namun salah (seperti hanya menutup mulut) serta tidak mengenakan masker wajah sama sekali.

Berdasarkan pengujian yang dilakukan teknik augmentasi gambar terbukti meningkatkan kinerja model dengan mendiversifikasi data pelatihan. Selain itu, transfer learning juga terbukti dapat meningkatkan akurasi model secara keseluruhan. Penerapan kedua pendekatan tersebut memberikan kontribusi peningkatan kinerja sebesar 12-13%. Berdasarkan pengujian akhir model deep learning yang dibangun mencapai akurasi 98,3% dan skor F1 98,7% pada dataset validasi. Penelitian berikutnya dapat diarahkan untuk mendeteksi hal yang lebih kompleks seperti mendeteksi penggunaan masker ganda (masker bedah dan masker kain).

DAFTAR PUSTAKA

- [1] M. Ciotti, M. Ciccozzi, A. Terrinoni, W. C. Jiang, C. Bin Wang, and S. Bernardini, "The COVID-19 pandemic," *Critical Reviews in Clinical Laboratory Sciences*, vol. 57, no. 6, Taylor & Francis, pp. 365–388, Aug. 17, 2020, doi: 10.1080/10408363.2020.1783198.
- [2] T. P. Velavan and C. G. Meyer, "The COVID-19 epidemic," *Trop. Med. Int. Heal.*, vol. 25, no. 3, pp. 278–280, Mar. 2020, doi: 10.1111/tmi.13383.
- [3] Planas *et al.*, "Reduced sensitivity of SARS-CoV-2 variant Delta to antibody neutralization," *Nature*, vol. 596, no. 7871, pp. 276–280, Aug. 2021, doi: 10.1038/s41586-021-03777-9.
- [4] J.-M. Guo, C.-C. Lin, M.-F. Wu, C.-H. Chang, and H. Lee, "Complexity Reduced Face Detection Using Probability-Based Face Mask Prefiltering and Pixel-Based Hierarchical-Feature Adaboosting," *IEEE Signal Process. Lett.*, vol. 18, no. 8, pp. 447–450, Aug. 2020, doi: 10.1109/11.2146772.
- [5] K. Suresh, M. Palangappa, and S. Bhuvan, "Face Mask Detection by using Optimistic Convolutional Neural Network," in *2021 6th International Conference on Inventive Computation Technologies (ICICT)*, Jan. 2021, pp. 1084–1089, doi: 10.1109/ICICT.2021.9358653.
- [6] A. Oumina, N. El Makhfi, and M. Hamdi, "Control The COVID-19 Pandemic: Face Mask Detection Using Transfer Learning," in *2020 IEEE 2nd International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS)*, Dec. 2020, pp. 1–5, doi: 10.1109/ICECOCS

- 50124.2020.9314511.
- [7] C. Indonesia, "Kasus Covid-19 Melonjak, Dokter Sarankan Pakai Double Masker." <https://www.cnnindonesia.com/gaya-hidup/20210621140923-255-657254/kasus-covid-19-melonjak-dokter-sarankan-pakai-double-masker> (accessed Sep. 28, 2021).
- [8] L. Li, Z. Xia, X. Jiang, Y. Ma, F. Roli, and X. Feng, "3D face mask presentation attack detection based on intrinsic image analysis," *IET Biometrics*, vol. 9, no. 3, pp. 100–108, August 2020, doi: 10.1049/iet-bmt.2019.0155.
- [9] A. Chavda, J. Dsouza, S. Badgujar, and A. Damani, "Multi-Stage CNN Architecture for Face Mask Detection," in *2021 6th International Conference for Convergence in Technology (I2CT)*, Apr. 2021, pp. 1–8, doi: 10.1109/I2CT51068.2021.9418207.
- [10] P. Nagrath, R. Jain, A. Madan, R. Arora, P. Kataria, and J. Hemanth, "SSDMNV2: A real time DNN-based face mask detection system using single shot multibox detector and MobileNetV2," *Sustain. Cities Soc.*, vol. 66, p. 102692, Mar. 2021, doi: 10.1016/j.scs.2020.102692.
- [11] J. Yu and W. Zhang, "Face Mask Wearing Detection Algorithm Based on Improved YOLO-v4," *Sensors*, vol. 21, no. 9, p. 3263, May 2021, doi: 10.3390/s21093263.
- [12] A. Cabani, K. Hammoudi, H. Benhabiles, and M. Melkemi, "MaskedFace-Net -- A Dataset of Correctly/Incorrectly Masked Face Images in the Context of COVID-19," Aug. 2020.
- [13] O. M. Parkhi, A. Vedaldi, and A. Zisserman, "Deep Face Recognition," in *Proceedings of the British Machine Vision Conference 2015*, 2015, pp. 41.1–41.12, doi: 10.5244/C.29.41.
- [14] G. Jignesh Chowdary, N. S. Pun, S. K. Sonbhadra, and S. Agarwal, "Face Mask Detection Using Transfer Learning of InceptionV3," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 12581 LNCS, Springer Science and Business Media Deutschland GmbH, 2020, pp. 81–90.
- [15] G. Jignesh Chowdary, N. S. Pun, S. K. Sonbhadra, and S. Agarwal, "Face Mask Detection Using Transfer Learning of InceptionV3," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2020, vol. 12581 LNCS, pp. 81–90, doi: 10.1007/978-3-030-66665-1_6.
- [16] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," *Jan 28*, 2018.
- [17] A. G. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," Apr. 2017.
- [18] J. Zhang, F. Han, Y. Chun, and W. Chen, "A Novel Detection Framework About the Conditions of Wearing Face Mask for Preventing Control the Spread of COVID-19," *IEEE Access*, vol. 9, pp. 42975–42984, 2021, doi: 10.1109/ACCESS.2021.3066538.

ORIGINALITY REPORT

24%

SIMILARITY INDEX

18%

INTERNET SOURCES

16%

PUBLICATIONS

18%

STUDENT PAPERS

PRIMARY SOURCES

1	Submitted to Sekolah Tinggi Sandi Negara Student Paper	4%
2	repository.untag-sby.ac.id Internet Source	1%
3	jurnal.iaii.or.id Internet Source	1%
4	fedetd.mis.nsysu.edu.tw Internet Source	1%
5	Submitted to Macquarie University Student Paper	1%
6	Regina Lionnie, Catur Apriono, Dadang Gunawan. "Face Mask Recognition with Realistic Fabric Face Mask Data Set: A Combination Using Surface Curvature and GLCM", 2021 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS), 2021 Publication	1%
7	Xudong Chen, Shugong Xu, Qiaobin Ji, Shan Cao. "A Dataset and Benchmark Towards	1%

Multi-Modal Face Anti-Spoofing Under Surveillance Scenarios", IEEE Access, 2021

Publication

8

www.ijariit.com

Internet Source

1 %

9

AKM Bahalul Haque, A.K.M. Najmul Islam, Sami Hyrynsalmi, Bilal Naqvi, Kari Smolander. "GDPR Compliant Blockchains – A Systematic Literature Review", IEEE Access, 2021

Publication

1 %

10

Santosh Saranyan, Srivas Seshadri, Ramani Boothalingam. "Real-Time Facemask Detection and Analytics", 2021 International Conference on Automation, Control and Mechatronics for Industry 4.0 (ACMI), 2021

Publication

1 %

11

Suresh K, Adwitiya Mukhopadhyay. "Investigation on COVID-19 by using Machine Learning Techniques", 2021 IEEE 4th International Conference on Computing, Power and Communication Technologies (GUCON), 2021

Publication

1 %

12

Submitted to University of Surrey

Student Paper

1 %

13

revistaclinicapsicologica.com

Internet Source

1 %

14	Submitted to Universiti Tunku Abdul Rahman Student Paper	1 %
15	jifosi.upnjatim.ac.id Internet Source	1 %
16	Submitted to University of Cape Town Student Paper	1 %
17	Submitted to Flinders University Student Paper	1 %
18	Submitted to Queensland University of Technology Student Paper	1 %
19	Submitted to University of Teesside Student Paper	<1 %
20	Submitted to Universitas Amikom Student Paper	<1 %
21	Submitted to Universitas Wiraraja Student Paper	<1 %
22	"Novelties in Intelligent Digital Systems", IOS Press, 2021 Publication	<1 %
23	Ahmad Izzuddin. "Implementasi Pendekatan Saintifik pada Pembelajaran Daring Selama Masa Pandemi Covid-19 di Lembaga Pendidikan Dasar", AS-SABIQUN, 2021 Publication	<1 %

24	digitalcommons.montclair.edu Internet Source	<1 %
25	docplayer.info Internet Source	<1 %
26	www.bbc.com Internet Source	<1 %
27	Submitted to Roehampton University Student Paper	<1 %
28	digitalcommons.latech.edu Internet Source	<1 %
29	bangka.tribunnews.com Internet Source	<1 %
30	repository.unas.ac.id Internet Source	<1 %
31	www.kai.id Internet Source	<1 %
32	Bhuwan Bhattarai, Yagya Raj Pandeya, Joonwhoan Lee. "Deep Learning-based Face Mask Detection Using Automated GUI for COVID-19", 2021 6th International Conference on Machine Learning Technologies, 2021 Publication	<1 %
33	digilib.uns.ac.id Internet Source	<1 %

34

ejournal.unkhair.ac.id

Internet Source

<1 %

35

ind.makeoversbeautyclinic.com

Internet Source

<1 %

36

media.neliti.com

Internet Source

<1 %

37

repository.unpas.ac.id

Internet Source

<1 %

38

Ernawati Ernawati, Mar'atus Sholihah, Andi Rahmad Rahim, Sukaris Sukaris.

"PENCEGAHAN VIRUS COVID-19 DENGAN MENERAPKAN PEMAKAIAN SABUN CUCI TANGAN DAN MASKER YANG BENAR SERTA PENDAMPINGAN BELAJAR SECARA DARING (DUSUN NGAGLIK - CERME KIDUL)",
DedikasiMU(Journal of Community Service),
2021

Publication

<1 %

39

Murat Koklu, Ilkay Cinar, Yavuz Selim Taspinar. "CNN-based bi-directional and directional long-short term memory network for determination of face mask", Biomedical Signal Processing and Control, 2022

Publication

<1 %

40

jabar.tribunnews.com

Internet Source

<1 %

41

Ziwei Song, Kristie Nguyen, Tien Nguyen, Catherine Cho, Jerry Gao. "Camera-Based Security Check for Face Mask Detection Using Deep Learning", 2021 IEEE Seventh International Conference on Big Data Computing Service and Applications (BigDataService), 2021

Publication

<1 %

Exclude quotes Off

Exclude matches Off

Exclude bibliography Off