

TESIS

**KLASIFIKASI GAMBAR PENGGUNAAN MASKER PADA WAJAH
MENGUNAKAN LOCAL BINARY PATTERNS (LBP) DENGAN
METODE CONVOLUTIONAL NEURAL NETWORK (CNN)**



Disusun oleh:

Nama : Muhammad Firdaus Abdi
NIM : 20.77.1254
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA
2022**

TESIS

**KLASIFIKASI GAMBAR PENGGUNAAN MASKER PADA WAJAH
MENGUNAKAN LOCAL BINARY PATTERNS (LBP) DENGAN
METODE CONVOLUTIONAL NEURAL NETWORK (CNN)**

**IMAGE CLASSIFICATION OF THE USE OF MASKS ON THE FACE
USING LOCAL BINARY PATTERNS (LBP) WITH THE
CONVOLUTIONAL NEURAL NETWORK (CNN) METHOD**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

Nama : Muhammad Firdaus Abdi
NIM : 20.77.1254
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2022

HALAMAN PENGESAHAN

**KLASIFIKASI GAMBAR PENGGUNAAN MASKER PADA WAJAH
MENGUNAKAN LOCAL BINARY PATTERNS (LBP) DENGAN METODE
CONVOLUTIONAL NEURAL NETWORK (CNN)**

**IMAGE CLASSIFICATION OF THE USE OF MASKS ON THE FACE USING
LOCAL BINARY PATTERNS (LBP) WITH THE CONVOLUTIONAL NEURAL
NETWORK (CNN) METHOD**

Dipersiapkan dan Disusun oleh

Muhammad Firdaus Abdi

20.77.1254

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Senin, 01 Agustus 2022

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 01 Agustus 2022

Rektor

Prof. Dr. M. Suvanto, M.M.
NIK. 190302001

HALAMAN PERSETUJUAN

**KLASIFIKASI GAMBAR PENGGUNAAN MASKER PADA WAJAH
MENGUNAKAN LOCAL BINARY PATTERNS (LBP) DENGAN METODE
CONVOLUTIONAL NEURAL NETWORK (CNN)**

**IMAGE CLASSIFICATION OF THE USE OF MASKS ON THE FACE USING
LOCAL BINARY PATTERNS (LBP) WITH THE CONVOLUTIONAL NEURAL
NETWORK (CNN) METHOD**

Dipersiapkan dan Disusun oleh

Muhammad Firdaus Abdi

20.77.1254

Telah Ditujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Senin, 01 Agustus 2022

Pembimbing Utama

Prof. Dr. Kusriani, M.Kom
NIK. 190302106

Anggota Tim Penguji

Dr. Andi Sunyoto, M.Kom
NIK. 190302052

Pembimbing Pendamping

Mei P. Kurniawan, M.Kom
NIK. 190302187

Dhani Ariatmanto, M.Kom., Ph.D
NIK. 190302197

Prof. Dr. Kusriani, M.Kom
NIK. 190302106

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 01 Agustus 2022
Direktur Program Pascasarjana

Prof. Dr. Kusriani, M.Kom.
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : **Muhammad Firdaus Abdi**
NIM : **20.77.1254**
Konsentrasi : **Business Intelligence**

Menyatakan bahwa Tesis dengan judul berikut:
Klasifikasi Gambar Penggunaan Masker Pada Wajah Menggunakan *Local Binary Patterns (LBP)* Dengan Metode *Convolutional Neural Network (CNN)*

Dosen Pembimbing Utama : Prof. Dr. Kusriani, M.Kom
Dosen Pembimbing Pendamping : Mei P. Kurniawan, M.Kom

1. Karya tulis ini adalah benar-benar **ASLI** dan **BELUM PERNAH** diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian **SAYA** sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab **SAYA**, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini **SAYA** buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka **SAYA** bersedia menerima **SANKSI AKADEMIK** dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 01 Agustus 2022
Yang Menyatakan,



Muhammad Firdaus Abdi

HALAMAN PERSEMBAHAN

Puji syukur atas kehadiran Allah SWT yang telah memberikan rahmat dan ridho-Nya, sehingga penulis dapat menyelesaikan karya tulis tesis ini. Semoga dari penelitian ini dapat diterima sebagai amal kebajikan. Selanjutnya karya ini saya persembahkan kepada kedua orang tua Abah dan Mama untuk segala dukungan dan do'a sehingga memberikan saya energi positif untuk menyelesaikan studi dan penelitian ini dengan baik.


Penelitian ini juga saya persembahkan kepada almamater saya, Universitas AMIKOM Yogyakarta dan para pembaca semoga semua yang terdapat pada naskah laporan tesis ini dapat memberikan wawasan tambahan dan kontribusi keilmuan yang baik dan bermanfaat.

HALAMAN MOTTO

"Maka sesungguhnya bersama kesulitan ada kemudahan. Maka apabila engkau telah selesai (dari sesuatu urusan), tetaplah bekerja keras (untuk urusan yang lain). Dan hanya kepada Tuhanmulah engkau berharap." (QS. Al-Insyrah, 6-8)

"Sesungguhnya Allah tidak akan mengubah nasib suatu kaum hingga mereka mengubah diri mereka sendiri." (QS. Ar-Ra'd:11)

"Bila kamu tidak tahan lelahnya belajar, maka kamu harus menanggung perihnya kebodohan." (Imam Al-Safi'i)



KATA PENGANTAR

Puji syukur atas kehadiran Allah SWT yang telah memberikan rahmat dan ridho-Nya, sehingga peneliti dapat menyelesaikan tesis yang merupakan salah satu syarat dalam menyelesaikan jenjang pendidikan S2 Pascasarjana PJJ Teknik Informatika Universitas AMIKOM Yogyakarta tepat waktu. Pada kesempatan kali ini penulis ingin berterima kasih kepada :

1. Kedua orang tua saya, bapak Aspul, S.Pd,SD dan ibu Masrinawati yang tiada hentinya memberikan nasehat, tidak pernah lelah merawat, mendidik penulis dari kecil hingga sekarang. Selalu memberikan dukungan dan perhatian serta memberikan doa yang terbaik kepada anak-anaknya.
2. Istri dan Anak tercinta Noorliyani, S.Kom dan Muhammad Zakir Firdaus yang telah memberikan dukungan penuh sehingga saya berhasil menyelesaikan jenjang studi magister ini.
3. Kakak Linda Purnasari, S.Pd,SD, Maulina Astia, S.Pd,SD, dan Hadi Fauzy, S.Pd, terimakasih telah mendukung dan memberikan semangat kepada saya.
4. Bapak Prof. Dr Mohammad Suyanto, M.M. Selaku Rektor Universitas AMIKOM Yogyakarta.
5. Ibu Prof. Dr. Kusriani, M.Kom. Selaku Direktur Program Pascasarjana Universitas AMIKOM Yogyakarta dan juga sebagai pembimbing 1 yang selalu ramah dan lugas, sehingga saya dapat menyelesaikan tesis ini tepat waktu.
6. Bapak Mei P. Kurniawan, M. Kom. Selaku pembimbing 2 yang mengarahkan saya agar penelitian ini dapat diselesaikan dengan baik.

7. PT. Talenta Bumi yang telah mengizinkan saya melanjutkan studi magister S2 di Universitas AMIKOM Yogyakarta.

Penulis menyadari bahwa dalam penyusunan tesis ini banyak terdapat kekurangan. Oleh karena itu penulis senang hati menerima kritik dan saran yang membangun dari pembaca. Akhir kata, penulis berharap semoga tesis ini dapat memberikan manfaat baik untuk penulis sendiri maupun yang membacanya.

Yogyakarta, 01 Agustus 2022

Penulis



DAFTAR ISI


HALAMAN JUDUL	ii
HALAMAN PENGESAHAN	iii
HALAMAN PERSETUJUAN	iv
HALAMAN PERNYATAAN KEASLIAN TESIS	v
HALAMAN PERSEMBAHAN	vi
HALAMAN MOTTO	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xiv
INTISARI	xvii
<i>ABSTRACT</i>	xviii
BAB I PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	5
1.3. Batasan Masalah	6
1.4. Tujuan Penelitian	7
1.5. Manfaat Penelitian	7
BAB II TINJAUAN PUSTAKA	8
2.1. Tinjauan Pustaka	8
2.2. Keaslian Penelitian	12

2.3. Landasan Teori.....	20
BAB III METODE PENELITIAN	28
3.1. Jenis, Sifat, dan Pendekatan Penelitian	28
3.1.1. Jenis Penelitian	28
3.1.2. Sifat Penelitian	28
3.2. Metode Pengumpulan Data.....	28
3.3. Metode Analisis Data.....	29
3.4. Alur Penelitian.....	29
BAB IV HASIL PENELITIAN DAN PEMBAHASAN.....	31
4.1. Pengumpulan Data.....	31
4.2. Preprocessing Data.....	33
4.2.1. <i>Cropping Image</i>	33
4.2.2. <i>Resize Image</i>	34
4.3. Ekstraksi Fitur Gambar.....	37
4.4. Arsitektur <i>Convolutional Neural Network (CNN)</i>	38
4.4.1. <i>Convolutional Layers</i>	38
4.4.2. <i>Max pooling and Batch Normalization layers</i>	38
4.4.3. <i>Dropout, Flatten and Fully connected Dense Layers</i>	39
4.5. <i>Baseline</i> pengujian atau pengujian dasar.....	39
4.5.1. <i>VGG16 with transfer learning</i>	39
4.6. Percobaan Skenario.....	41
4.7. Hasil <i>Training dan Testing Data</i>	42
4.7.1. Skenario pertama.....	43

4.7.2. Skenario kedua	46
4.7.3. Skenario ketiga	49
4.7.4. Skenario keempat LBP-CNN	52
4.7.5. Skenario kelima LBP-CNN	55
4.7.6. Skenario keenam LBP-CNN	58
4.7.7. Skenario ketujuh Dataset Gambar masker warna biru	61
4.7.8. Skenario ketujuh Dataset Gambar masker warna putih	65
4.7.9. Perbandingan Hasil	68
4.7.10. Perbandingan Hasil Dataset berbeda	69
4.7.11. Perbandingan Waktu Proses	70
4.7.12. Analisa Penelitian Terkait	71
BAB V PENUTUP	73
5.1. Kesimpulan	73
5.2. Saran	74
DAFTAR PUSTAKA	76

DAFTAR TABEL

Tabel 2. 1 Matriks literatur review dan posisi penelitian.....	12
Tabel 2. 2 <i>Confusion Matrix</i>	26
<u>Tabel 4. 1 Skenario percobaan</u>	42
<u>Tabel 4. 2 Akurasi Validasi untuk setiap deskriptor fitur</u>	43
<u>Tabel 4. 3 Akurasi Validasi untuk setiap deskriptor fitur berbeda</u>	43
<u>Tabel 4. 4 Waktu Proses Komputasi</u>	71




DAFTAR GAMBAR

Gambar 2. 1 Operator LBP asli	20
Gambar 2. 2 <i>Deep learning</i>	22
Gambar 2. 3 Arsitektur CNN secara umum	23
Gambar 2. 4 Contoh Convolution Layer	24
Gambar 2. 5 Contoh dari max pooling	25
Gambar 3. 1 Alur penelitian	29
<u>Gambar 4. 1 Contoh gambar wajah menggunakan masker medis</u>	32
<u>Gambar 4. 2 Folder pembagian kelas</u>	32
<u>Gambar 4. 3 Pembagian data uji dan latih</u>	33
<u>Gambar 4. 4 <i>Cropping image</i></u>	33
<u>Gambar 4. 5 Hasil pemotongan gambar</u>	34
<u>Gambar 4. 6 <i>Resize image</i></u>	34
<u>Gambar 4. 7 Contoh hasil <i>resize</i> gambar</u>	35
<u>Gambar 4. 8 <i>Rotate image</i></u>	36
<u>Gambar 4. 9 Hasil rotas gambar</u>	36
<u>Gambar 4. 10 <i>Local Binary Pattern (LBP)</i></u>	37
<u>Gambar 4. 11 Arsitektur <i>Convolutional Neural Network (CNN)</i> dengan 6 layer</u>	38
<u>Gambar 4. 12 VGG16 arsitektur Convolutional Neural Net (CNN)</u>	39
<u>Gambar 4. 13 Model akurasi</u>	40
<u>Gambar 4. 14 Model loss</u>	40
<u>Gambar 4. 15 Hasil prediksi VGG16</u>	41

<u>Gambar 4. 16 Grafik <i>training</i> dan <i>validation accuracy</i> skenario pertama</u>	44
<u>Gambar 4. 17 Grafik <i>training</i> dan <i>validation loss</i> skenario pertama</u>	44
<u>Gambar 4. 18 <i>Confusion matrix</i> pengujian skenario pertama</u>	45
<u>Gambar 4. 19 Grafik <i>training</i> dan <i>validation accuracy</i> skenario kedua</u>	47
<u>Gambar 4. 20 Grafik <i>training</i> dan <i>validation loss</i> skenario kedua</u>	47
<u>Gambar 4. 21 <i>Confusion matrix</i> pengujian skenario kedua</u>	48
<u>Gambar 4. 22 Grafik <i>training</i> dan <i>validation accuracy</i> skenario ketiga</u>	50
<u>Gambar 4. 23 Grafik <i>training</i> dan <i>validation loss</i> skenario ketiga</u>	50
<u>Gambar 4. 24 <i>Confusion matrix</i> pengujian skenario ketiga</u>	51
<u>Gambar 4. 25 Grafik <i>training</i> dan <i>validation accuracy</i> skenario keempat</u>	53
<u>Gambar 4. 26 Grafik <i>training</i> dan <i>validation loss</i> skenario keempat</u>	53
<u>Gambar 4. 27 <i>Confusion matrix</i> pengujian skenario keempat</u>	54
<u>Gambar 4. 28 Grafik <i>training</i> dan <i>validation accuracy</i> skenario kelima</u>	56
<u>Gambar 4. 29 Grafik <i>training</i> dan <i>validation loss</i> skenario kelima</u>	56
<u>Gambar 4. 30 <i>Confusion matrix</i> pengujian skenario kelima</u>	57
<u>Gambar 4. 31 Grafik <i>training</i> dan <i>validation accuracy</i> skenario keenam</u>	59
<u>Gambar 4. 32 Grafik <i>training</i> dan <i>validation loss</i> skenario keenam</u>	59
<u>Gambar 4. 33 <i>Confusion matrix</i> pengujian skenario keenam</u>	60
<u>Gambar 4. 34 Dataset gambar masker warna biru</u>	61
<u>Gambar 4. 35 Grafik <i>training</i> dan <i>validation accuracy</i> skenario ketujuh</u>	62
<u>Gambar 4. 36 Grafik <i>training</i> dan <i>validation loss</i> skenario ketujuh</u>	63
<u>Gambar 4. 37 <i>Confusion matrix</i> pengujian skenario ketujuh</u>	64
<u>Gambar 4. 38 Dataset gambar masker warna putih</u>	65

<u>Gambar 4. 39 Grafik <i>training</i> dan <i>validation accuracy</i> skenario kedelapan</u>	66
<u>Gambar 4. 40 Grafik <i>training</i> dan <i>validation loss</i> skenario kedelapan</u>	66
<u>Gambar 4. 41 <i>Confusion matrix</i> pengujian skenario kedelapan</u>	67
<u>Gambar 4. 42 Grafik hasil pengujian</u>	69
<u>Gambar 4. 43 Grafik hasil pengujian dataset berbeda</u>	70



INTISARI

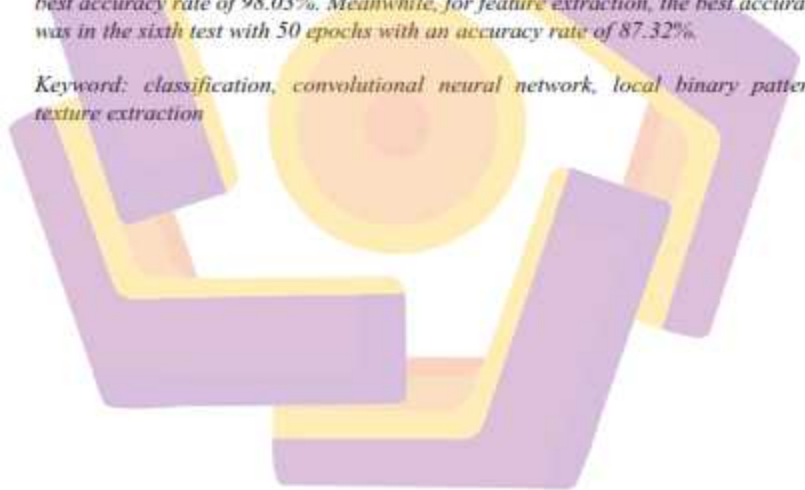
Diakhir tahun 2021 pandemi covid-19 sudah mulai menurun dan mobilitas sudah mulai tidak dibatasi akan tetapi varian baru covid-19 atau corona virus omicron mulai terdeteksi di Indonesia untuk itu masyarakat dihimbau dan diwajibkan selalu menggunakan masker ketika berada di luar rumah. Dan juga selalu menjaga jarak, menghindari kerumunan dan juga rajin mencuci tangan. Diwajibkannya selalu memakai masker menjadi point penting pada penelitian ini yang dimana fokus penelitian yang akan dilakukan yaitu citra gambar wajah menggunakan masker medis. Dalam penelitian ini melakukan pengujian gambar wajah menggunakan masker dan tanpa masker yang dimana dilakukan dengan metode ekstraksi fitur *local binary pattern* (LBP) dan original gambar. *Convolutional Neural Network* (CNN) digunakan untuk mengklasifikasi pada penelitian ini. Dataset yang digunakan sebanyak 1914 gambar latih dan 1885 gambar uji, dimana pada gambar latih dataset gambar menggunakan masker sebanyak 896 dan tanpa masker sebanyak 896. Sedangkan pada gambar uji dataset gambar menggunakan masker sebanyak 850 dan tanpa masker sebanyak 1035. Hasil pengujian terbaik dari skenario gambar asli tanpa ekstraksi fitur pada pengujian ketiga dengan *epoch* 10 dengan tingkat akurasi terbaik 98.03%. Sedangkan untuk ekstraksi fitur akurasi terbaik pada pengujian ke enam dengan *epoch* 50 dengan tingkat akurasi 87.32%.

Kata kunci: masker, klasifikasi, *convolutional neural network*, *local binary pattern*, ekstraksi tekstur

ABSTRACT

At the end of 2021 the covid-19 pandemic had begun to decline and movement was no longer limited, but a new variant of covid-19 or the corona virus omicron was detected in Indonesia. For this reason, people are encouraged and must always wear masks when outside their homes. And also always keep your distance, avoid and also wash your hands diligently. The obligation to always wear a mask is an important point in this study, where the focus of the research to be carried out is facial images using medical masks. In this study, we tested facial images using masks and without masks using the local binary pattern (LBP) feature extraction method and the original image. convolutional neural network (CNN) is used to classify in this study. The dataset used is 1914 training images and 1885 test images, where in the training image the image dataset uses 896 masks and without masks as many as 896, While in the test images the image dataset uses 850 masks and without masks as many as 1035. The best test results from the image scenario original without feature extraction in the third test with epoch 10 with the best accuracy rate of 98,03%. Meanwhile, for feature extraction, the best accuracy was in the sixth test with 50 epochs with an accuracy rate of 87.32%.

Keyword: classification, convolutional neural network, local binary pattern, texture extraction



BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Pandemi yang melanda seluruh dunia dengan adanya wabah virus corona atau covid-19 yang dimana virus ini masuk ke Indonesia pada tanggal 02 maret 2020 meski telah 1 lebih tahun berlalu akan tetapi virus ini masih ada sampai sekarang, berbagai cara dilakukan untuk terhindar dari virus corona atau covid-19 ini dengan cara 4M yang dimana wajib memakai masker, mencuci tangan, menjaga jarak, menghindari kerumunan.

Meski vaksinasi untuk covid-19 sudah ditemukan semua kegiatan didalam maupun diluar masih harus menggunakan masker sebagai pelindungan utama terhadap penularan virus, apalagi varian virus corona semakin banyak seperti varian Delta dan Kappa, hingga Alpha dan Beta yang sudah menyebar sebagian besar kota-kota di Indonesia <https://www.who.int/health-topics/coronavirus>. Untuk itu pemerintah menghimbau kegiatan diluar rumah masih diwajibkan untuk patuh jaga jarak, menghindari kerumunan dan lebih penting yaitu selalu memakai masker.

Menurut (sinar Rizky A, Anita Trisiana, Farid Ajrur R , Lauriend Algileri M, Iqbal Syaibani 2020) kesadaran akan kesehatan pada masyarakat untuk mematuhi protokol kesehatan salah satunya memakai masker yang masih banyak dihiraukan hingga saat ini, pihak pemerintah juga menghimbau dan menertibkan masyarat ketika tidak menggunakan masker maka akan dihukum sosial, tetapi pengawasan tersebut tidak bisa dilakukan setiap saat sehingga perlu adanya

pengawasan secara *real time* agar tempat-tempat yang berpotensi menjadi keramaian, menjadi tertib atas kewajiban memakai masker. Tetapi jika penggunaan masker wajah tidak tepat, maka efektifitas masker itu sendiri menjadi tidak bermanfaat.

Saat ini pengolahan citra banyak digunakan untuk berbagai objek penelitian baik berupa gambar, teks maupun video. Penelitian tentang pengolahan citra tentang deteksi masker wajah seperti yang dilakukan oleh (Oumina, El Makhfi, and Hamdi 2020) tentang tindakan cara kontrol pandemi covid-19 dengan cara mendeteksi pengguna masker pada wajah dengan sistem *transfer learning* yang dimana pendeteksian dilakukan dari dataset gambar yang diambil diekstrak fitur dengan menggunakan *Convolutional Neural Networks (CNN)* selanjutnya dilakukan klasifikasi dengan *Support Vector Machine (SVM)* dan *K-Nearest Neighbors (K-NN)*.

Convolutional Neural Network (CNN) (Militante and Dionisio 2020b) merupakan bagian dari *Deep Learning* yang dalam beberapa tahun terakhir menjadi perhatian karena CNN sendiri mampu memproses jumlah data yang besar. CNN termasuk jenis *neural network* yang sering digunakan dalam data gambar dan juga digunakan dalam mendeteksi dan mengenali object pada sebuah gambar yang dapat mengungguli metode lama dalam tugas *computer vision* dan *pattern recognition*.

Seperti yang dilakukan oleh (Hermawan 2021) bagaimana mengklasifikasi gambar orang memakai masker dan tidak yang dimana dilakukan urutan seperti objek yang digunakan yaitu wajah, selanjutnya dilakukan deteksi wajah dan dilakukan proses citra digital dengan menggunakan metode *Convolutional Neural*

Networks (CNN). Deteksi masker pada wajah juga dilakukan oleh (Aprilian Anarki, Auliasari, and Orisa 2021) yang dimana ditujukan untuk mengurangi penularan penyakit COVID-19 saat ini, penelitian ini dilakukan dengan aplikasi yang dimana gambar citra dihasilkan dari sebuah gambar yang diambil lalu diproses dengan citra digital dengan metode *HAAR CASCADE*.

Pada penelitian (Septiana et al. 2020) tentang sistem deteksi masker (*Face mask detection*) menggunakan pengolahan citra dengan metode *Convolutional Neural Networks (CNN)* memanfaatkan ekstraksi fitur dari citra, klasifikasi deteksi objek, gambar, dan pelacakan objek. Dari hasil pengujian mendapatkan nilai akurasi 0.9933% dan training loss 0.0213%. Oleh (Rahim, Kusri, and Luthfi 2020) Penerapan klasifikasi penggunaan masker dengan objek gambar menggunakan metode *Convolutional Neural Networks (CNN)* dengan *epoch* 50 dan rasio dataset 90% data latih dan 10% data uji mendapatkan akurasi terbaik mencapai 96%.

Beberapa penelitian lain (Hosseini et al. 2018) tentang klasifikasi usia dan gender menggunakan *Gabor filter* yang dikombinasikan dengan CNN menghasilkan akurasi sebesar 61,3% untuk usia dan 88,9% untuk gender, selain itu penelitian dilakukan oleh (Melange and Asble, 2018) mengenali kelompok usia dan gender dari citra wajah menggunakan *local binary pattern (LBP)* dan SVM menghasilkan akurasi 85% untuk kelompok usia dan 95% untuk klasifikasi gender.

Penelitian lain oleh (Ayuningsih, Sari, and Adikara 2019) tentang citra makanan *Color Moment (HSV)* dan *Local Binary Pattern* dengan *Naïve Bayes Classifie* yang dimana penggunaan *local binary pattern (LBP)* sebagai ekstraksi fitur

untuk menghasilkan nilai keabuan yang dimana dilakukan ekstraksi fitur warna gambar dari RGB ke *Hue Saturation Value (HSV)* dan menghasilkan akurasi penggunaan HSV sebesar 65% dan LBP 60%.

Penelitian (Mujib, Hidayatno, and Prakoso 2018) tentang pengenalan wajah menggunakan *local binary pattern (LBP)* dengan klasifikasi *support vector machine (SVM)* penelitian ini untuk identifikasi wajah yang dimana citra wajah diambil dengan kamera selanjutnya dilakukan ekstraksi ciri dengan LBP, setelah ciri wajah diperoleh diklasifikasi menggunakan *support vector machine (SVM)* hasil akurasi yang didapat 100% itu artinya wajah berhasil dikenali dari penelitian ini.

Berdasarkan penelitian terdahulu dari klasifikasi dan deteksi pengguna masker dan tidak maka pada penelitian ini dilakukan penerapan ekstraksi ciri tekstur dengan *local binary pattern (LBP)* dengan klasifikasi menggunakan *Convolutional Neural Networks (CNN)* untuk mengetahui pengaruh terhadap performa *accuracy*, *precision*, dan *recall* dari penelitian ini. Penggunaan deep learning *Convolutional Neural Networks (CNN)* untuk klasifikasi gambar terdahulu menghasilkan performa yang baik dalam klasifikasi gambar wajah bermasker, dan juga ekstraksi ciri dengan *local binary pattern (LBP)* dengan klasifikasi *support vector machine (SVM)* pada identifikasi wajah mendapatkan akurasi tinggi dan juga sangat baik. Pengujian dalam penelitian ini menggunakan dataset dari beberapa sumber yaitu kaggle, github dan pencarian manual melalui internet, setelah dataset didapat dilakukan *Pre-processing*, fitur ekstraksi ciri *Local Binary Pattern (LBP)* dan klasifikasi *Convolutional Neural Networks (CNN)* untuk mengetahui *accuracy*, *precision*, dan *recall*. Pengujian juga dengan menentukan dataset yang akan diuji

lalu diberikan beberapa perlakuan terhadap gambar yaitu bagian pertama dilakukan *Pre-processing* (*cropping* gambar, gambar dijadikan *Grayscale*, segmentasi warna dan fitur ekstraksi LBP), bagian kedua dilakukan *Pre-processing* (*cropping* gambar, gambar dijadikan *Grayscale*, segmentasi warna), bagian ketiga dilakukan *Pre-processing* (*cropping* gambar, gambar dijadikan *Grayscale*, fitur ekstraksi LBP), dari ketiga perlakuan tersebut dilakukan klasifikasi menggunakan metode *Convolutional Neural Networks (CNN)* untuk mengetahui akurasi terbaik terhadap performa *accuracy*, *precision*, dan *recall* dalam klasifikasi gambar menggunakan masker dan tidak.

1.2. Rumusan Masalah

Adapun rumusan masalah dari penelitian yang akan dilakukan ini berdasarkan latar belakang yang telah diuraikan, yaitu :

- a. Bagaimana pengaruh segmentasi warna dan fitur ekstraksi ciri *Local Binary Patern (LBP)* terhadap *accuracy*, *precision*, dan *recall* dari klasifikasi gambar menggunakan masker dan tidak?
- b. Bagaimana pengaruh segmentasi warna terhadap *accuracy*, *precision*, dan *recall* dari gambar menggunakan masker dan tidak?
- c. Bagaimana pengaruh segmentasi fitur ekstraksi ciri *Local Binary Patern (LBP)* terhadap *accuracy*, *precision*, dan *recall* dari gambar menggunakan masker dan tidak?
- d. Berapa tingkat *accuracy*, *precision*, dan *recall* keberhasilan yang diperoleh dalam menentukan gambar menggunakan masker atau tidak dengan penerapan

ekstraksi tekstur *local binary patterns (LBP)* dengan klasifikasi *convolutional neural network (CNN)*?

1.3. Batasan Masalah

Batasan masalah penelitian yaitu:

- a. Objek yang digunakan yaitu berupa gambar wajah dengan masker dan tidak menggunakan masker.
- b. Objek masker yang digunakan adalah masker medis.
- c. Dataset yang digunakan merupakan *dataset* yang sudah tersedia di <https://www.kaggle.com/shreyashwaghe/medical-mask-dataset>, serta pencarian melalui internet dikumpulkan secara manual.
- d. Ekstraksi tekstur dengan *local binary patterns (LBP)*.
- e. Gambar berupa RGB di konversi ke HSV.
- f. Library yang digunakan yaitu *tensorflow* untuk klasifikasi CNN, *skimage* untuk LBP.
- g. Output dari hasil penelitian ini berupa hasil atau performa tingkat *accuracy*, *precision*, dan *recall* dalam penentuan gambar dengan masker wajah atau tidak.
- h. Penggunaan *hardware* pada penelitian ini laptop ASUS dengan spesifikasi Core i5, Ram 8 GB dan VGA Nvidia 930MX.

1.4. Tujuan Penelitian

Tujuan penelitian yaitu:

- a. Mengetahui *accuracy*, *precision*, dan *recall* penerapan ekstraksi tekstur *local binary pattern (LBP)* terhadap klasifikasi gambar masker pada wajah dengan metode *convolutional neural network(CNN)*.
- b. Mengetahui *accuracy*, *precision*, dan *recall* penerapan segmentasi warna dan tekstur pada klasifikasi gambar menggunakan masker dan tidak.
- c. Mengetahui *accuracy*, *precision*, dan *recall* penerapan segmentasi warna pada klasifikasi gambar menggunakan masker dan tidak.
- d. Mengetahui *accuracy*, *precision*, dan *recall* penerapan segmentasi tekstur pada klasifikasi gambar menggunakan masker dan tidak.

1.5. Manfaat Penelitian

Manfaat pada penelitian ini yaitu :

- a. Bisa menjadi referensi yang akan datang terhadap penelitian tentang klasifikasi gambar masker pada wajah.
- b. Bisa menjadi referensi yang digunakan untuk pengawasan seperti area kerja yang wajib menggunakan masker pada wajah.
- c. Bisa diterapkan untuk dapat meningkatkan pengawasan dalam kawasan wajib menggunakan masker pada wajah dengan hanya menempatkan kamera dan peringatan berupa sirine atau *alarm*.

BAB II

TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

Penelitian yang akan dilakukan memiliki beberapa rujukan penelitian sebelumnya. Penelitian sebelumnya akan dijadikan sebagai referensi dan juga sebagai rujukan untuk memperoleh ide atau gagasan yang dapat dilakukan untuk tujuan pengembangan. Selain itu penulis juga menjadikan penelitian sebelumnya sebagai bahan kajian untuk mengetahui keterkaitan dari penelitian terdahulu dengan penelitian yang akan dilakukan sehingga menghindari terjadinya duplikasi yang akan dilakukan penulis. Berikut beberapa ulasan jurnal tentang penelitian yang sebelumnya yang berkaitan dengan metode sebagai acuan dalam penelitian ini.

Penelitian yang dilakukan oleh (Oumina, El Makhfi, and Hamdi 2020) mengontrol pandemi covid-19 dengan deteksi masker wajah menggunakan *transfer learning*. Penelitian ini dilakukan dengan menggunakan *Convolutional Neural Networks (CNN)* sebagai ekstraksi fitur setelah itu dilakukan klasifikasi dengan *Support Vector Machine (SVM)* dan *K-Nearest Neighbourx (K-NN)*. Dan hasil dari klasifikasi ini menggunakan model MobileNet dengan SVM mendapatkan akurasi terbaik 97.11 %.

Penelitian tentang klasifikasi pengguna masker dengan *Convolutional Neural Networks (CNN)* dilakukan oleh (Rahim, Kusri, and Luthfi 2020) dengan 1000 gambar data latih dengan sistem deep learning mendapatkan akurasi terbaik

96%. Dari penelitian ini bahwa *deep leaning* dapat di terapkan dalam deteksi gambar wajah bermasker.

Penelitian lain dilakukan oleh (Qin and Li 2020) tentang mengembangkan metode identifikasi kondisi pemakaian masker wajah baru dengan menggabungkan gambar *super-resolution* dan *classification networkx (SRCNet)* yang dimana dengan gabungan jaringan SR dengan identifikasi wajah CNN menghasilkan akurasi 98,70% dengan SRCNet yang diusulkan.

Penelitian yang dilakukan oleh (Mujib, Hidayatno, and Prakoso 2018) tentang “Pengenalan Wajah Menggunakan *Local Binary Pattern (LBP)* Dan *Support Vector Machine (SVM)*”. Penelitian tersebut merancang mendeteksi wajah dengan mengidentifikasi seseorang berdasarkan metode biometrik jenis fisiologis, yang dimana klasifikasi dilakukan menggunakan *support vector machine (SVM)*. Yang dimana mendapatkan akurasi sebesar 96,0%. Perbedaan penelitian selanjutnya yaitu dari dataset yang digunakan, juga kombinasi *Local Binary Pattern (LBP)* dan *Convolutional Neural Network (CNN)*.


Klasifikasi gambar pose kepala multi sudut saat menggunakan masker dimasa pandemi covid-19 oleh (Li et al. 2020) dalam penelitian ini menerapkan metode HGL dengan menggabungkan H-channel dari ruang warna HSV dengan potret wajah dan citra grayscale, dan melatih CNN untuk mengekstrak fitur untuk klasifikasi. Hasil evaluasi dataset MAFA yang digunakan akurasi dari klasifikasi gambar menghasilkan gambar tampak depan sebesar 93,64% dan gambar bagian sisi atau samping sebesar 87,17%.

Penelitian lainnya oleh (Militante and Dionisio 2020a) tentang implementasi *deep learning* pada wajah bermasker dan deteksi jarak fisik menggunakan sistem peringatan. Teknologi *deep learning* telah menunjukkan capaian dalam hal klasifikasi untuk memproses sebuah gambar. Penelitian ini pada dataset gambar dilakukan dengan memotong gambar atau *cropping* gambar secara merata dengan ukuran 224x224 piksel. Dan hasil dari *cropping* gambar dilakukan klasifikasi menggunakan CNN menghasilkan akurasi 97%.

Penelitian tentang penggunaan metode fitur warna HSV dan fitur tekstur LBP digunakan untuk mendapatkan karakteristik dari setiap citra yang dilakukan oleh (Ayuningsih, Sari, and Adikara 2019) untuk klasifikasi citra makanan menggunakan *Naïve Bayes Classifier*. Proses tahapan awal dengan *pre-processing* memisahkan objek makanan dengan *background*, selanjutnya dengan ekstraksi fitur warna HSV setelah itu ekstraksi fitur tekstur *Local Binary Pattern (LBP)* menghasilkan nilai keabuan dalam histogram. Dan hasil dari klasifikasi *Naïve Bayes Classifier* hanya menggunakan metode HSV sebesar 65% dan LBP sebesar 60%.

Dari penelitian tentang penggunaan *deep learning* sebagai metode untuk mengklasifikasikan gambar mendapatkan akurasi yang baik, dari penelitian sejenis tentang penggunaan metode ekstraksi ciri dengan metode *Local Binary Pattern (LBP)* untuk klasifikasi citra makanan. Sehingga pada penelitian dilakukan beberapa kombinasi perlakuan untuk mengetahui pengaruh terhadap *accuracy*, *precision*, dan *recall* untuk klasifikasi gambar wajah menggunakan masker dan tidak menggunakan masker. Dan dapat diketahui hasil *accuracy*, *precision*, dan

recall dari penerapan ekstraksi ciri menggunakan *Local Binary Pattern (LBP)* dan klasifikasi menggunakan metode *Convolutional Neural Network (CNN)*.



2.2. Keaslian Penelitian

Tabel 2. 1 Matriks literatur review dan posisi penelitian
Klasifikasi Gambar Penggunaan Masker Pada Wajah Menggunakan Local Binary Patterns (LBP) Dengan Metode Convolutional Neural Network (CNN)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Control The COVID-19 Pandemic: Face Mask Detection Using Transfer Learning	Abdellah Oumina, Nouredine El Makhfi, Mustapha Hamdi, IEEE 2nd International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS) 2020	Penelitian ini tentang pendeteksian masker wajah	Menggunakan 2 teknik klasifikasi Support Vector Machine (SVM) dan K-Nearest Neighbours (K-NN) untuk wajah menggunakan toeping dan wajah tanpa toeping. Kombinasi model MobileNet-V2 dengan SVM mendapatkan hasil (97,11%)	Mencoba menggunakan teknik fitur baru dan algoritma baru dan kumpulan data yang bervariasi	Menggunakan fitur ekstraksi untuk langkah awal klasifikasi gambar menggunakan masker pada wajah dan yang tidak menggunakan masker pada wajah.
2	Convolutional neural networks and local binary patterns for hyperspectral image classification	Xiangpo Wei , Xuchu Yu , Bing Liu & Lu Zhi Informa UK Limited, trading as Taylor & Francis Group. 2019	Klasifikasi gambar hiperspektral yang dimana menggabungkan metode CNN dan LBP untuk mengekstrak fitur	Hasil dari penerapan CNN dan LBP didapatkan hasil 98,52%, 99,54% dan 99,54% akurasi klasifikasi pada data Indian Pines, University of Pavia dan Salinas.	Mencoba metode CNN dengan gambar yang lebih banyak dalam citra klasifikasi Peta	Menggunakan gabungan LBP dan CNN untuk klasifikasi gambar penggunaan masker pada wajah.

Tabel 2. 1 Matriks literatur review dan posisi penelitian
 Klasifikasi Gambar Penggunaan Masker Pada Wajah Menggunakan Local Binary Patterns (LBP) Dengan Metode Convolutional
 Neural Network (CNN) (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
3	Identifying Facemask-Wearing Condition Using Image Super-Resolution with Classification Network to Prevent COVID-19	Bosheng Qin, dan Dongxiao Li Information Science and Electronic Engineering, Zhejiang University, Hangzhou, 2020	Melakukan metode indentifikasi pemakaian masker wajah dengan jaringan klasifikasi dan resolusi super (SRCNet)	Metode (SRCNet) mendapatkan akurasi 98,70% dan mengungguli metode klasifikasi tradisional	Klasifikasi gambar masker wajah tidak mencakup semua postur dan lingkungan, dataser yang cenderung sedikit.	Klasifikasi gambar dengan LBP dan CNN untuk mendeteksi gambar penggunaan masker pada wajah.
4	Convolutional Neural Network Untuk Kalasifikasi Penggunaan Masker	Arham Rahim1, Kusri2, Dan Erba Taufiq Luthfi Jurnal Teknologi Informasi dan Komunikasi Volume 10, Nomor 2, Desember 2020	Pemanfaatan klasifikasi gambar masker dengan metode CNN	Hasil penerapan CNN dalam klasifikasi mendapatkan uji awal dan ketiga mendapatkan akurasi 94%, uji kedua 96%, dan uji keempat mendapatkan akurasi 95%.	Jumlah data latih sangat mempengaruhi hasil.	Mercapkan metode LBP dan CNN untuk klasifikasi gambar menggunakan masker, dengan dataset yang beragam.
5	A Facial Expression Recognition Algorithm based on CNN and LBP Feature	Qintao Xu, Najing Zhao IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC 2020)	Pengenalan ekspresi wajah dengan CNN dan LBP menggunakan model AlexNet	Penggunaan algoritma CNN dan LBP dapat meningkatkan pengenalan ekspresi sampai rotasi tertentu.	Masih terganggu dengan latar belakang yang kompleks	Merapkan preprocessing dengan cropping atau pemotongan gambar agar terfokus pada objek masker.

Tabel 2. 1 Matriks literatur review dan posisi penelitian
 Klasifikasi Gambar Penggunaan Masker Pada Wajah Menggunakan Local Binary Patterns (LBP) Dengan Metode Convolutional
 Neural Network (CNN) (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
6	Face Mask Detection Covid-19 Using Convolutional Neural Network (Cnn)	Tri Septiana Nadia Puspita Putri, Mohamad Al Fikih, Novendra Setyawan Seminar Nasional Teknologi dan Rekayasa (SENTRA) 2020	Pendeteksi wajah bermasker dan tidak dengan CNN untuk ekstraksi fitur	Implementasi metode CNN untuk deteksi wajah bermasker dan tidak memperoleh akurasi sebesar 0.9933%	Pendeteksian terkendala jarak yang maksimal 2,3 meter	Menerapkan metode LBP dan CNN untuk klasifikasi wajah bermasker.
7	Face Mask Detection Using MobileNetV2 in The Era of COVID-19 Pandemic	Samuel Ady Sanjaya, Suryo Adi Rakhmawan International Conference on Data Analytics for Business and Industry 2020	Membuat pengenalan masker wajah untuk digunakan sebagai pencegahan terhadap covid-19 dengan klasifikasi citra MobileNetV2	Setelah preprocessing data, membagi data dan menguji didapatkan hasil akurasi sebesar 96,85% dalam pendeteksian masker wajah	Mencoba menerapkan klasifikasi yang berbeda	Menerapkan metode LBP dan CNN untuk deteksi gambar menggunakan masker pada wajah
8	Real-Time Facemask Recognition with Alarm System using Deep Learning	Sammy V. Militante, Nanette V. Dionisio IEEE Control and System Graduate Research Colloquium (ICSGRC 2020)	Menggunakan deep learning untuk pengenalan dan klasifikasi gambar orang tersebut menggunakan masker atau tidak	Deteksi real-time dengan resolusi 224x224 menggunakan model CNN VGG-16 mencapai akurasi 96% dengan raspberry Pi sebagai alat pendeteksian secara real-time.	Mencoba dengan model CNN dan dataset yang bervariasi	Menerapkan variasi dataset dan dengan Metode LBP dan CNN untuk klasifikasi gambar wajah bermasker.

Tabel 2. 1 Matriks literatur review dan posisi penelitian
 Klasifikasi Gambar Penggunaan Masker Pada Wajah Menggunakan Local Binary Patterns (LBP) Dengan Metode Convolutional
 Neural Network (CNN) (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
9	Multi-angle Head Pose Classification when Wearing the Mask for Face Recognition under the COVID-19 Coronavirus Epidemic	Shuang Li, Xin Ning, Lina Yu1, Liping Zhang, Xiaoli Dong, Yuan Shi, Wei He International Conference on High Performance Big Data and Intelligent Systems (HPBD&IS) 2020	Menggunakan metode HGL untuk klasifikasi pose kepala dengan mengadopsi analisis tekstur warna gambar dan potret garis.	Metode HGL yang digabungkan dengan H-channel dari warna CSV dengan gambar wajah selanjutnya dengan citra grayscale dan CNN sebagai klasifikasi menghasilkan akurasi gambar depan 93,64% dan gambar sisi 87,17%.	Mencoba menerapkan model atau metode CNN yang berbeda	Menerapkan kombinasi model klasifikasi gambar dengan LBP dan CNN
10	Deep Learning Implementation of Facemask and Physical Distancing Detection with Alarm Systems	Sammy V. Militante, Nanette V. Dionisio International Conference on Vocational Education and Electrical Engineering (ICVEE) 2020	Implementasi model yang sudah dibuat sebagai deteksi orang memakai masker dengan python dan opencv untuk peringatan orang yang tidak memakai masker.	Hasil implementasi dari penggunaan python dan opencv dan mengukur jarak fisik studi ini menghasilkan jika orang terdeteksi tidak menggunakan masker maka peringatan akan berbunyi	Mencoba kombinasi model CNN untuk mengevaluasi dan mencari tingkat akurasi yang lebih tinggi	Menerapkan metode LBP dan CNN untuk klasifikasi gambar pengguna masker pada wajah untuk mendapatkan hasil akurasi yang lebih baik.

Tabel 2. 1 Matriks literatur review dan posisi penelitian
 Klasifikasi Gambar Penggunaan Masker Pada Wajah Menggunakan Local Binary Patterns (LBP) Dengan Metode Convolutional
 Neural Network (CNN) (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
11	Face mask detection using YOLOv3 and faster R-CNN models: COVID-19 environment	Sunil Singh, Umang Abuja, Munish Kumar, Krishan Kumar, Monika Sachdeva Springer, Multimedia Tools and Applications (2021)	Pendeteksian penggunaan masker pada wajah dengan YOLOv3 dan R-CNN	Hasil dari penggunaan deep learning dengan YoLoV3 dan R-CNN menghasilkan presisi rata-rata 55 dan waktu 0,0045s untuk YoloV3 dan presisi rata-rata 62 dengan waktu 0,15s untuk R-CNN	Mencoba model lain dalam pencirapan deteksi wajah menggunakan masker	Menerapkan deteksi gambar wajah menggunakan masker dan tidak dengan LBP dan CNN
12	Klasifikasi Citra Makanan Menggunakan HSV Color Moment dan Local Binary Pattern dengan Naïve Bayes Classifier	Yuita Arum Sari Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer 2019	Klasifikasi citra makanan dengan HSV, LBP dan Nivebayes classifier	Hasil dari model LBP dan HSV dari klasifikasi dengan naivebayes menghasilkan nilai akurasi sebesar 65%	Menggunakan dataset yang beragam dan algoritma yang berbeda	Menerapkan dataset yang beragam dengan model algoritma LBP dan CNN

Tabel 2. 1 Matriks literatur review dan posisi penelitian
 Klasifikasi Gambar Penggunaan Masker Pada Wajah Menggunakan Local Binary Patterns (LBP) Dengan Metode Convolutional
 Neural Network (CNN) (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
13	A Modified Local Binary Pattern Descriptor for SAR Image Matching	Mohammad Amin Ghannadi, IEEE Geoscience and Remote Sensing Letters, Tahun 2019	Tujuan penelitian untuk melakukan pencocokan gambar untuk citra SAR dengan pola biner lokal (LBP) yang dimodifikasi.	Kesimpulan pada penelitian ini yaitu metode yang diusulkan telah meningkatkan jumlah true cocok dibandingkan dengan LBP tradisional dan LBP termodifikasi. Ketepatan metode yang diusulkan tidak berubah secara signifikan dibandingkan dengan metode lain.	Penelitian akan datang multiresolusi MTF LBP bisa dikembangkan untuk gambar dengan resolusi berbeda. Juga, konsepnya Analisis tekstur gambar akan dipertimbangkan untuk meningkatkan deskriptor tradisional lainnya.	Penelitian sebelumnya menggunakan Local Binary Patterns (LBP) untuk pencocokan gambar SAR, pada penelitian selanjutnya dengan menggunakan Local Binary Patterns (LBP) dan CNN sebagai uji dari hasil yang akan diharapkan.
14	Pengenalan Wajah Menggunakan Local Binary Pattern (LBP) Dan Support Vector Machine (SVM)	Khusnil Mujib, Transient, Tahun 2018.	Mendeteksi wajah dengan mengidentifikasi asi seseorang berdasarkan metode biometrik jenis fisiologis.	Sistem pengenalan wajah menggunakan ekstraksi ciri LBP telah berjalan dengan baik. Nilai akurasi untuk pengujian dengan data latih untuk kedua kernel sebesar 100,0% dan nilai akurasi untuk pengujian dengan data uji sebesar 96,0%.	Bisa penelitian selanjutnya dengan sistem klasifikasi lainnya sebagai perbandingan akurasi pada hasil akhir.	Menerapkan metode LBP dan CNN untuk klasifikasi gambar wajah menggunakan masker.

Tabel 2. 1 Matriks literatur review dan posisi penelitian
 Klasifikasi Gambar Penggunaan Masker Pada Wajah Menggunakan Local Binary Patterns (LBP) Dengan Metode Convolutional
 Neural Network (CNN) (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
15	An Asian Face Dataset and How Race Influences Face Recognition	Zhangyang Xiong, springer, Tahun 2018	Mengumpulkan gambar wajah dari Internet dan membangun skala besar. Kumpulan data wajah Asia (AFD) untuk diproses dengan kombinasi AFD, WebFace, campuran WebFace & AFD sebagai pengenalan wajah orang asia.	cara semi-otomatis untuk mengumpulkan foto wajah dari Internet dan membangun kumpulan data wajah Asia berskala besar yang berisi subjek 2019 dan 360.000. model yang dilatih oleh citra wajah Asia mampu memberikan gambaran kinerja pengenalan wajah yang lebih baik pada orang Asia dari pada model yang dilatih oleh Wajah Barat.	Bisa lebih banyak gambar wajah, seperti Jepang dan Korea, untuk membangun yang lebih besar dan kumpulan data gambar wajah Asia yang lebih komprehensif.	Menerapkan klasifikasi gambar yang dimana gambar tersebut menggunakan masker dan tidak.
16	Face Segmentor-Enhanced Deep Feature Learning for Face Recognition	Xiaojuan Cheng, IEEE Transactions on Biometrics, Behavior, and Identity Science, Tahun 2019	Face Segmentor-Enhanced Network (FSENet) untuk pengenalan wajah guna memanfaatkan pelokalan wajah. Eksperimen ekstensif pada set data domain publik populer termasuk Labeled Face in the Wild (LFW), Youtube Faces (YTF), IARPA IJB-A, IJB-B dan IJB-C,	Dari hasil pengujian hasil eksperimental yang ekstensif menunjukkan bahwa metode yang telah tercapai kinerja yang sangat kompetitif.	Pekerjaan dimasa depan bisa dengan metode pengenalan wajah lain, agar bisa jadi acuan dalam penelitian selanjutnya.	Penelitian sebelumnya deteksi wajah dengan Face Segmentor-Enhanced Network (FSENet), penelitian selanjutnya dengan pengenalan gambar menggunakan penutup wajah atau masker.

Tabel 2. 1 Matriks literatur review dan posisi penelitian
 Klasifikasi Gambar Penggunaan Masker Pada Wajah Menggunakan Local Binary Patterns (LBP) Dengan Metode Convolutional
 Neural Network (CNN) (lanjutan)


No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
17	Face Detection With Different Scales Based on Faster R-CNN	Wenqi Wu, IEEE Transactions On Cybernetics, 2018	Tujuan penelitian untuk mendeteksi wajah berskala kecil.	Penggunaan metode deteksi wajah R-CNN lebih cepat, Eksperimental hasil menunjukkan bahwa metode DSFD yang kami usulkan mencapai hasil yang menjanjikan kinerja pada tolok ukur populer termasuk FDDB, AFW, PASCAL face, dan WIDER FACE.	Pekerjaan masa depan kita akan mengeksplorasi bagaimana meningkatkan efisiensi R-CNN cepat tipe paralel dan mengoptimalkan pembangkitan proses proposal wajah.	Penelitian sebelumnya bagaimana mendeteksi sebuah wajah yang berukuran kecil, penelitian yang akan dilakukan yaitu mendeteksi masker yang ada pada wajah.
18	Local directional mask maximum edge patterns for image retrieval and face recognition	Santosh Kumar Vipparthi, IET Computer Vision, Tahun 2016	Tujuan Penelitian ini mengusulkan deskriptor fitur baru, pola tepi maksimum-topeng terarah lokal, untuk pengambilan citra dan aplikasi pengenalan wajah. Pola biner lokal (LBP) dan varian LBP mengumpulkan hubungan antara pusat piksel dan sekitarnya dalam sebuah gambar.	Kesimpulannya penelitian ini telah melakukan pendekatan baru yang disebut LDMA MEP untuk pengambilan gambar dan pengenalan wajah. Hasil setelah diteliti metode yang diusulkan menunjukkan signifikan peningkatan dibandingkan dengan fitur varian LBP dan LBP di hal pengukuran evaluasi mereka pada database masing-masing.	Penelitian akan datang bisa dengan fitur ekstraksi gambar yang lebih mendalam.	Penelitian sebelumnya menggunakan Local Binary Patterns (LBP) dengan pola tepi maksimum untuk pengambilan citra pada pengenalan wajah, yang akan dilakukan penelitian selanjutnya yaitu pengenalan gambar wajah menggunakan masker.

2.3. Landasan Teori

2.3.1. Local Binary Patterns (LBP)

Local binary patterns (LBP) merupakan salah satu texture *descriptor* yang diperkenalkan oleh (Ojala, Pietikäinen, and Harwood 1994). LBP dikenal sebagai operator sederhana dan juga sangat efisien yang dimana cara kerjanya dengan memberikan label pada piksel dan dengan melakukan peng-ambangan (*thresholding*) pada setiap piksel tetangga yang mempertimbangkan hasil sebagai bilangan biner, (Pietikäinen et al. 2011).

Operator LBP asli bekerja dengan delapan piksel tetangga, menggunakan nilai piksel pusatnya sebagai *threshold* seperti pada gambar 2.1 berikut :



Gambar 2. 1 Operator LBP asli

Secara matematis, operator LBP dapat ditulis menggunakan persamaan (1), dimana notasi (P,R) menyatakan titik sampling P pada radius R .

$$s_x = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1)$$

$$LBP_{P,R} = \sum_{p=0}^{P-1} s_{g_p} - g_c 2^p$$

Dimana,


g_p = nilai derajat keabuan pada piksel tetangga ke- p

g_c = nilai derajat keabuan pada piksel diposisi tengah

2.3.2. *Deep Learning*

Deep learning merupakan sub bagian dari machine learning. Machine learning adalah sebuah program komputer yang dapat belajar dari pengalaman dan semakin banyak pengalaman yang diberikan kepada program tersebut maka performa akan semakin baik. Akan tetapi, algoritma machine learning tradisional tidak akan membaik secara signifikan ketika sudah sampai titik tertentu, sebanyak apapun data yang diberikan. Andrew Ng, Co-founder dari Coursera, mantan Chief Scientist dari Baidu dan founder Google Brain, menyebutkan dari sebuah slide miliknya bahwa deep learning dapat menyelesaikan masalah performa yang ada pada algoritma machine learning tradisional ketika data sudah semakin banyak (Suyanto, 2019).

Secara garis besar, komponen dari algoritma deep learning adalah jaringan syaraf tiruan, sebuah teknik untuk meniru cara berpikir otak manusia yang terdiri dari layer yang berlapis-lapis. Gambar 2 menunjukkan terdapat 4 sel pada hidden layer 1. Lapisan tersebut mendapatkan informasi dari layer input. Bukan hanya satu sel saja yang menjadi masukan, akan tetapi semua sel di layer input. Dengan demikian, hidden layer 1 menjadi tahu kombinasi dari masukan yang menurutnya berpengaruh besar pada hasil. Begitu pun hidden layer 2 akan mendapat masukan dari lapisan sebelumnya, yaitu hidden layer 1 sehingga hidden layer 2 menjadi tahu kombinasi hidden layer 1 seperti apakah yang berpengaruh kepada hasil dapat dilihat pada gambar 2.2 dibawah ini.



Gambar 2. 2 *Deep learning*


Hal berbeda terjadi pada machine learning tradisional yang akan memproses dari input layer langsung ke output layer tanpa ada hidden layer sehingga diperlukan kombinasi input tambahan (fitur) yang perlu dihitung oleh manusia.

Deep learning sangat baik dalam pemrosesan data yang tidak terstruktur, seperti gambar, teks, dan audio. Untuk memproses data yang berbeda diperlukan juga arsitektur yang berbeda agar hasil yang diperoleh lebih maksimal.

2.3.3. *Convolutional Neural Networks (CNN)*

Convolutional Neural Networks (CNN) adalah salah satu kelas *deep feed-forward artificial neural networks* yang banyak diaplikasikan pada analisis citra, (Alom et al. 2018). CNN terinspirasi oleh proses-proses biologi dimana pola konektifitas antar neurons menyerupai organisasi visual cortex pada binatang. *Cortical neurons* menanggapi stimulasi hanya dalam suatu area terbatas pada bidang visual atau bidang reseptif (*receptive field*). Bidang-bidang reseptif neurons tumpang tindih secara parsial (*partially overlap*) sedemikian hingga mencakup seluruh bidang reseptif, (Zhang and Zhu 2018).

Convolutional Neural Networks (CNN) menggunakan arsitektur 3 dimensi: lebar (*width*), tinggi (*hight*), dan dalam (*depth*), seperti gambar 2.3 dibawah ini :



Gambar 2. 3 Arsitektur CNN secara umum

2.3.4. Feature Learning

Lapisan-lapisan yang terdapat dalam Feature Learning berguna untuk mentranslasikan suatu input menjadi menjadi features berdasarkan ciri dari input tersebut yang berbentuk angka-angka dalam vektor. Lapisan ekstraksi fitur ini terdiri dari Convolutional Layer dan Pooling Layer.

a. Convolutional Layer

Convolutional Layer adalah sebuah inti utama dari CNN, dimana layer ini memiliki sebuah kumpulan filter yang dapat digunakan untuk mempelajari citra masukan. Pada layer ini, akan dilakukan operasi konvolusi terhadap input ataupun output dari layer sebelumnya. Konvolusi adalah suatu istilah matematis yang berarti mengaplikasikan sebuah fungsi pada output fungsi lain secara berulang. Tujuan dilakukannya konvolusi pada data citra adalah untuk mengekstraksi fitur dari citra input. Konvolusi akan menghasilkan transformasi linear dari data input sesuai informasi spasial pada data. Bobot pada layer tersebut menspesifikasikan kernel konvolusi yang digunakan, sehingga kernel konvolusi dapat dilatih berdasarkan input pada CNN. Berikut Persamaan yang digunakan untuk menghitung pergeseran matriks :

$$h(i,j) = A*P1 + B*P2 + C*P3 + D*P4 + E*P5 + F*P6 + G*P7 + H*P8 + I*P9 \quad (2)$$

Keterangan :

$h(i,j)$ = hasil dari perkalian matriks kernel A dengan input

P A-I = nilai matriks input yang dikalikan dengan matriks kernel

P1-9 = nilai matriks kernel yang dikalikan dengan matriks input *image* P

Contoh *Convolution Layer* dapat dilihat pada gambar 2.4 dibawah ini.

1	1	1	0	0	<table border="1"> <tbody> <tr> <td>4</td><td>3</td><td>4</td> </tr> <tr> <td>2</td><td>4</td><td>3</td> </tr> <tr> <td>2</td><td>3</td><td>4</td> </tr> </tbody> </table>	4	3	4	2	4	3	2	3	4
4	3	4												
2	4	3												
2	3	4												
0	1	1	1	0										
0	0	1x1	1x0	1x1										
0	0	1x0	1x1	0x0										
0	1	1x1	0x0	0x1										

Gambar 2. 4 Contoh Convolution Layer

b. *Rectified Linear Unit (ReLU)*

Rectified Linear Unit (ReLU) akan menghilangkan vanishing gradient dengan cara menerapkan fungsi aktivasi element sebagai $f(x) = \max(0, x)$ alias aktivasi elemen akan dilakukan saat berada di ambang batas 0. Kelebihan dan kekurangan dalam penggunaan ReLU :


(+) : Bisa mempercepat gradien stokastik dibandingkan dengan fungsi sigmoid / tan h karena ReLU berbentuk linear

(+) : Tidak menggunakan operasi eksponensial seperti sigmoid/tan h, sehingga bisa melakukan dengan pembuatan matriks aktivasi saat ambang batas berada pada nilai 0.

(-) : ReLU bisa rapuh saat masa training dan mati karena gradien besar yang mengalir melalui ReLU menyebabkan update bobot, sehingga neuron tidak aktif pada datapoint lagi. Jika ini terjadi, maka gradien yang mengalir melalui unit akan selamanya nol dari titik itu. Artinya, unit ReLU dapat mati secara ireversibel selama pelatihan karena mereka dapat melumpuhkan data manifold. Misalnya, Anda mungkin menemukan bahwa sebanyak 40% dari jaringan Anda dapat “mati” (yaitu neuron yang tidak pernah aktif di seluruh dataset pelatihan) jika tingkat pembelajaran ditetapkan terlalu tinggi. Dengan pengaturan tingkat pembelajaran yang tepat, ini lebih jarang menjadi masalah.

c. Pooling Layer

Pooling layer adalah lapisan yang mengurangi dimensi dari feature map atau lebih dikenal dengan langkan untuk downsampling, sehingga mempercepat komputasi karena parameter yang harus diupdate semakin sedikit dan mengatasi overfitting. Pooling yang biasa digunakan adalah Max Pooling dan Average Pooling. Max Pooling untuk menentukan nilai maksimum tiap pergeseran filter, sementara Average Pooling akan menentukan nilai rata-ratanya, dapat dilihat pada gambar 2.5 dibawah ini.



Gambar 2. 5 Contoh dari max pooling

2.3.5. Confusion Matrix

Merupakan salah satu metode yang digunakan untuk mengevaluasi kinerja dari algoritma klasifikasi (Han, Kamber, and Pei 2012). Tabel 2.2 merupakan gambaran sederhana untuk mempermudah pemahaman tentang istilah confusion matrix dalam melakukan evaluasi atau pengujian dari model klasifikasi.

Tabel 2.2 *Confusion Matrix*

		Kelas Prediksi	
		Positif	Negatif
Kelas Aktual	Positif	TP	FN
	Negatif	FP	TN

Tabel 1 di atas menunjukkan beberapa variabel yang berperan untuk proses evaluasi model klasifikasi. Variabel True Negative (TN) merupakan data yang tepat diklasifikasi oleh sistem sebagai nilai negatif atau salah, kemudian variabel True Positive (TP) merupakan data yang tepat diklasifikasi sebagai nilai positif atau benar. Lalu untuk variabel False Positive (FP) merupakan data yang diklasifikasikan tidak tepat apabila keluaran berupa positif atau benar kemudian untuk variabel False Negatif (FN) merupakan data yang diklasifikasikan dengan kurang tepat.

Metode confusion matrix ini memiliki beberapa parameter penilaian terhadap kinerja dari model klasifikasi yang dihasilkan adalah :

1. *Precision*

Presisi adalah untuk mengukur tingkat kepastian, yaitu berapa tingkat persentasi tuple positif yang dilabeli positif adalah bernilai benar yang di rumuskan sebagai berikut.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3)$$

2. Recall

Parameter penilaian ukuran kelengkapan, yaitu berapa tingkat persentasi tuple positif yang dilabeli positif. Sehingga *recall* adalah sama dengan *true positive rate*.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (4)$$

3. Accuracy

Accuracy adalah tingkat kedekatan nilai prediksi dengan nilai aktual yang dihasilkan, untuk menentukan sebuah akurasi maka dilakukan perhitungan menggunakan formula seperti ini.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

BAB III

METODE PENELITIAN

3.1. Jenis, Sifat, dan Pendekatan Penelitian

3.1.1. Jenis Penelitian

a) Eksperimen

Penelitian ini bersifat eksperimen dengan dilakukan beberapa kombinasi atau perlakuan terhadap dataset gambar wajah menggunakan wajah bermasker dan tidak untuk mendapatkan nilai *accuracy*, *precision*, dan *recall* dengan menggunakan ekstraksi tekstur LBP dan klasifikasi dengan CNN.

3.1.2. Sifat Penelitian

a) Deskriptif

Tujuan penelitian dengan tentang mendeskripsikan sesuatu, dimana sebuah data didapatkan dan dilakukan pembersihan data, selanjutnya dilakukan testing dan uji terhadap data tersebut untuk membuktikan hipotesa yang dibuat.

3.2. Metode Pengumpulan Data

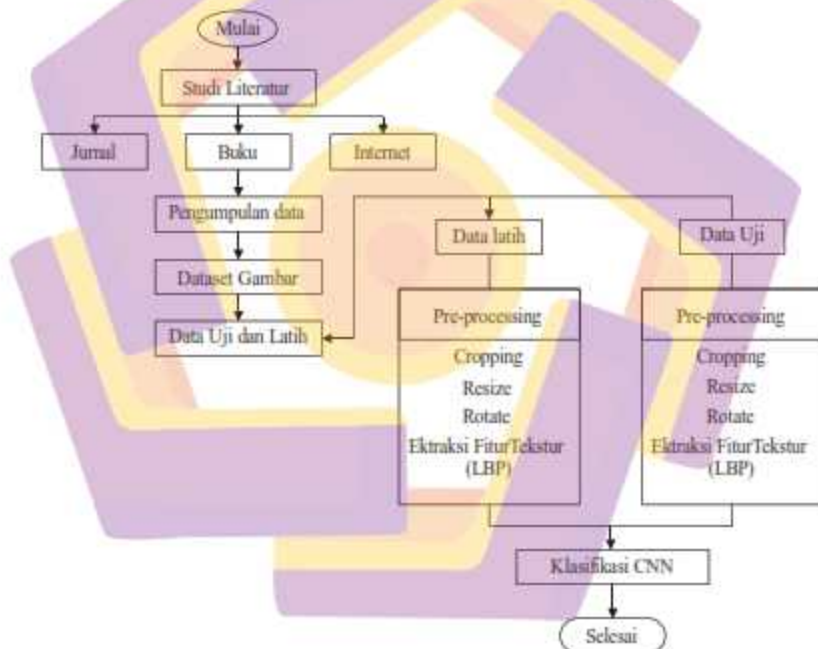
Metode pengumpulan data dilakukan agar mendapatkan data yang dibutuhkan dalam penelitian ini yaitu dari website pertama <https://www.kaggle.com/shreyashwaghe/medical-mask-dataset>, kedua <https://humansintheloop.org/resources/datasets/medical-mask-dataset/> dan ketiga <https://www.kaggle.com/datasets/ashishjangra27/face-mask-12k-images-dataset>.

3.3. Metode Analisis Data

Setelah data didapat dan terkumpul, dilakukan pemilahan data, Pre-processing, selanjutnya dilakukan segmentasi gambar, dan klasifikasi untuk memperoleh hasil *accuracy*, *precicion*, dan *recall* dari penerapan penerapan *local binary pattern (LBP)* dengan *convolutional neural network (CNN)*.

3.4. Alur Penelitian


Berikut adalah diagram alur langkah penelitian :



Gambar 3. 1 Alur penelitian

Pada gambar 3.1 dapat dilihat alur penelitian yang akan dilakukan dari mulai studi literatur, pengumpulan dataset, pembagian dataset untuk data latih dan uji, dilakukan *preprocessing data*, ekstraksi fitur dan tahapan akhir untuk menguji

dilakukan klasifikasi data gambar dengan menggunakan metode klasifikasi *convolutional neural network* (CNN).



BAB IV

HASIL PENELITIAN DAN PEMBAHASAN

Pada bab ini menjelaskan hasil dari analisa dan implementasi dari rancangan tahapan alur penelitian. Proses yang dilakukan ada beberapa tahapan yaitu pengumpulan dataset, penentuan arsitektur, skenario penelitian, *preprocessing* dataset, ekstraksi fitur, dan evaluasi hasil dari arsitektur LBP (*Local Binary Pattern*) + CNN (*Convolutional Neural Network*).

4.1. Pengumpulan Data

Dataset sendiri diambil dari beberapa sumber yang pertama dari website <https://www.kaggle.com/datasets/sumansid/facemask-dataset>, yang kedua dari <https://humansintheloop.org/resources/datasets/medical-mask-dataset/>, dan yang ketiga dari <https://www.kaggle.com/datasets/ashishjangra27/face-mask-12k-images-dataset>. Selanjutnya dataset gambar yang didapat dilakukan pemilahan karena data gambar yang digunakan pada penelitian kali ini yaitu data gambar wajah menggunakan masker medis. Untuk masker lain seperti kain dan lainnya itu tidak dipakai. Contoh gambar wajah dengan menggunakan masker medis pada gambar 4.1 dibawah.



Gambar 4. 1 Contoh gambar wajah menggunakan masker medis

Klasifikasi gambar yang akan dilakukan yaitu 2 kelas yaitu wajah dengan masker dan wajah tanpa masker seperti gambar 4.2 dibawah.



Gambar 4. 2 Folder pembagian kelas

Setelah gambar terpilah seperti pada gambar 4.2 diatas, dilakukan pembagian untuk data latih dan data uji. Untuk data latih gambar menggunakan masker sebanyak 896 gambar dan tanpa masker sebanyak 1018 gambar. Sedangkan untuk data uji menggunakan masker sebanyak 850 gambar dan tanpa masker sebanyak 1035 gambar.



Gambar 4. 3 Pembagian data uji dan latihan

Dari gambar 4.3 dataset gambar dibagi menjadi 2 bagian yaitu dataset gambar latihan dan dataset gambar uji, dimana setiap data latihan dan uji terdapat folder wajah menggunakan masker dan tanpa masker.

Dataset yang sudah dilakukan pelabelan antara wajah menggunakan masker medis dan wajah tanpa menggunakan masker, maka selanjutnya proses dilanjutkan ketahapan persiapan atau *preprocessing*.

4.2. Preprocessing Data

4.2.1. Cropping Image

Langkah pemotongan gambar dilakukan untuk memudahkan dalam pengujian, sehingga gambar di potong menjadi bagian-bagian per wajah seperti gambar 4.4 dibawah ini.



Gambar 4. 4 *Cropping image*

Pemotongan gambar dilakukan untuk gambar wajah menggunakan masker saja, karena gambar wajah tanpa masker dari dataset yang didapat sudah terpotong sesuai yang diinginkan.



Gambar 4. 5 Hasil pemotongan gambar

Hasil gambar 4.5 yang di potong masih memiliki ukuran size yang berbeda-beda sehingga untuk memudahkan dan agar hasil yang diharapkan dapat maksimal dilakukan penyesuaian size dengan dilakukan resize gambar.

4.2.2. *Resize Image*

Penyesuaian ukuran gambar dilakukan karena gambar yang dilakukan pemotongan beragam ukuran sehingga perlu dilakukan penyesuaian ukuran gambar 150x150 dengan program menggunakan bahasa python 3.7 dengan *jupyter notebook* seperti pada gambar 4.6 dibawah ini.

```
In [1]: path = "dataset/rotata dan resize/lib masker/"
        img_re = resize_aspect_fit(path,150)

In [2]: path = "dataset/rotata dan resize/lib nomasker/"
        ncar_re = resize_aspect_fit(path,150)

In [3]: print(ncar_re.shape)
        print(ncar_re.shape)
        (150, 150, 150, 3)
        (150, 150, 150, 3)
```

Gambar 4. 6 *Resize image*

Hasil dari *resize* yang dilakukan pada penelitian ini terlihat pada gambar 4.7 bahwa gambar yang sebelumnya memiliki perbedaan ukuran disamakan untuk mempermudah dalam komputasi agar hasil yang diharapkan dapat mendapatkan akurasi terbaik.

```
Out[12]: <matplotlib.image.AxesImage at 0x20127527788>
```



Gambar 4. 7 Contoh hasil *resize* gambar

Contoh hasil *resize* gambar 4.7 diatas semua gambar disamakan ukuran sebesar 150x150.

4.2.3. *Rotate Image*

Rotasi gambar dilakukan untuk menjadikan dataset yang bervariasi sehingga diharapkan agar hasil dari variasi dataset dapat memaksimalkan hasil dari pengujian yang dilakukan. rotasi gambar 180 derajat dilakukan dengan program menggunakan bahasa python dengan *jupyter notebook* seperti pada gambar 4.8 dibawah ini.

```

In [11]: def image_rotate(path, save_path, rotate_deg):
        img = cv.imread(path)
        for i in range(0, 255):
            if i % 10 == 0:
                print(i)
            if cv.waitKey(1) < 0:
                break
            image_rot = image_rotate_rotate_deg(
                image_rot = image_rotate_rotate_deg(
                    save_path = save_path + str(i) + ".jpg",
                    save_img = save_path + str(i) + ".img",
                    rotate_deg = rotate_deg)
            image_rot, save_path, i)

In [12]: path = "D:\dataset\dataset"
        save_path = "D:\dataset\dataset\dataset"

In [13]: image_rotate(path, save_path, 180)

```

Gambar 4. 8 Rotate image

Hasil dari pemotongan gambar, menyamakan ukuran gambar dan rotasi gambar diatas didapatkan gambar menggunakan masker sejumlah 896 gambar menggunakan masker dan 1018 gambar tanpa menggunakan masker untuk dataset gambar latih.

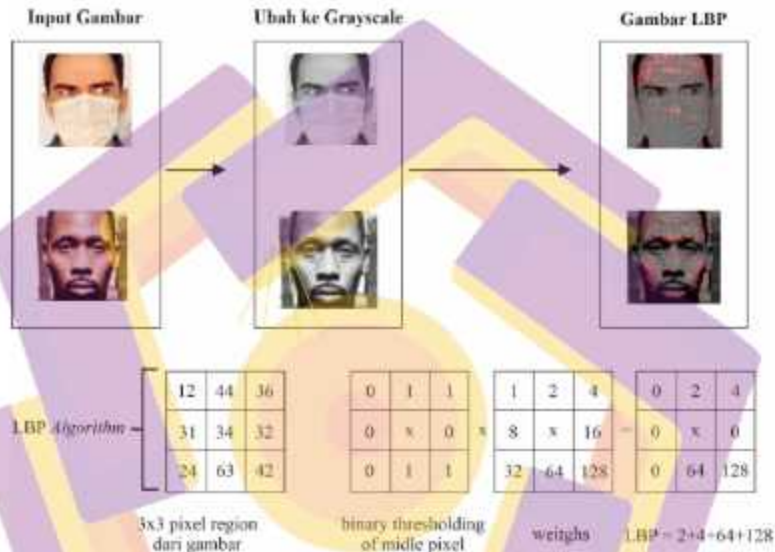


Gambar 4. 9 Hasil rotasi gambar

Hasil dari rotasi gambar terlihat pada gambar 4.9 diatas, gambar rotasi ini dimaksudkan untuk mengimbangi dataset wajah yang tanpa masker, sehingga antara gambar menggunakan masker dan tanpa masker dapat seimbang.

4.3. Ekstraksi Fitur Gambar

Penelitian ini menggunakan ekstraksi fitur *Local binary pattern* (LBP) yang dimana gambar berukuran 150x150 diubah ke gambar skala abu-abu dan menghasilkan gambar LBP.

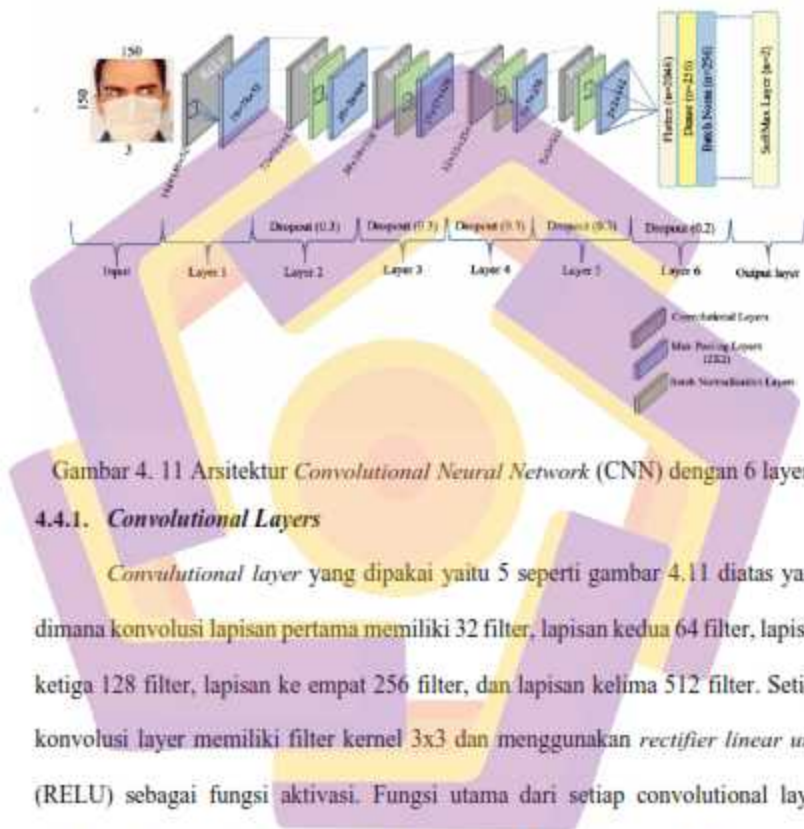


Gambar 4.10 *Local Binary Pattern* (LBP)

Proses gambar 4.10 diatas menjelaskan proses dari algoritma LBP yaitu contoh gambar di proses dengan skala 3x3 pixel selanjutnya dijadikan nilai binary atau jika nilai titik pusat lebih besar dari nilai ketetangaan maka nilainya adalah 0 dan sebaliknya jika nilai titik pusat maka nilai diberikan adalah 1. Setelah proses binary dikalikan dengan bobot dan hasil dari perkalian bobot didapat nilai dari *Local Binary Pattern* (LBP).

4.4. Arsitektur *Convolutional Neural Network* (CNN)

Penelitian ini menggunakan *convolutional layers*, *pooling layers*, *normalization layers*, *dropout layers*, and *fully connected dense layers*.



Gambar 4. 11 Arsitektur *Convolutional Neural Network* (CNN) dengan 6 layer

4.4.1. *Convolutional Layers*

Convolutional layer yang dipakai yaitu 5 seperti gambar 4.11 diatas yang dimana konvolusi lapisan pertama memiliki 32 filter, lapisan kedua 64 filter, lapisan ketiga 128 filter, lapisan ke empat 256 filter, dan lapisan kelima 512 filter. Setiap konvolusi layer memiliki filter kernel 3x3 dan menggunakan *rectifier linear unit* (RELU) sebagai fungsi aktivasi. Fungsi utama dari setiap convolutional layer adalah untuk mengekstrak dan mempelajari fitur dari gambar masukan.

4.4.2. *Max pooling and Batch Normalization layers*

Setiap lapisan konvolusi diikuti oleh lapisan normalisasi batch dan lapisan max-pooling. Semua lapisan max-pooling memiliki filter 2x2. Lapisan normalisasi batch menggunakan mean dan standar deviasi dari mini-batch saat ini untuk

menormalkan aktivasi node. Dengan penurunan dimensi dari gambar yang difilter, lapisan max-pooling berfokus pada fitur atau objek penting gambar.


4.4.3. Dropout, Flatten and Fully connected Dense Layers

Over-fitting dihindari dengan menambahkan lapisan *dropout* setelah *max-pooling* dan *Fully connected Dense*, *dropout* diatur $p = 0:3$ and $p = 0:2$. Output yang dihasilkan setelah blok terakhir dari lapisan *convolution-normalization-pooling*, diratakan ke vektor fitur satu dimensi menggunakan *flatten layer*. Output dari layer *flatten* dengan 2048 neuron digunakan sebagai input untuk layer padat pertama *Fully connected Dense layer*. Lapisan padat pertama memiliki total 256 neuron dengan fungsi aktivasi ReLu. Lapisan padat kedua adalah digunakan untuk klasifikasi dengan fungsi aktivasi *softmax*.

4.5. Baseline pengujian atau pengujian dasar


4.5.1. VGG16 with transfer learning

Pengujian ini dilakukan untuk dijadikan dasar pada pengujian penelitian yang dilakukan, struktur VGG16 arsitektur Convolutional Neural Net (CNN) dipilih menjadi acuan dan dapat dilihat pada gambar dibawah ini.



Gambar 4. 12 VGG16 arsitektur Convolutional Neural Net (CNN)

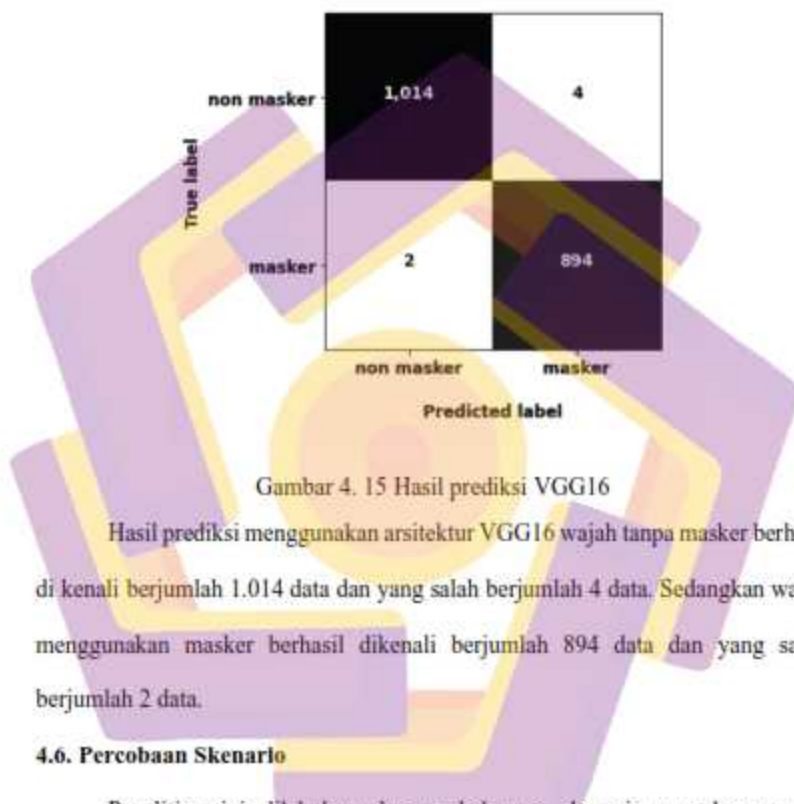
Dari dataset gambar wajah menggunakan masker dan tanpa masker yang sudah dibuat model dilakukan proses komputasi seperti terlihat pada gambar arsitektur VGG16 diatas. Jumlah epoch yang dilakukan yaitu epoch 50. Hasil dari proses komputasi menggunakan VGG16 mendapatkan akurasi terbaik sebesar 99.69%.



Gambar 4. 13 Model akurasi

Gambar 4. 14 Model loss

Pada gambar model akurasi terlihat peningkatan akurasi dan mendapatkan akurasi terbaik 99.69%. pada gambar model loss mengalami penurunan didapat hasil 0.3%.



Gambar 4. 15 Hasil prediksi VGG16

Hasil prediksi menggunakan arsitektur VGG16 wajah tanpa masker berhasil di kenali berjumlah 1.014 data dan yang salah berjumlah 4 data. Sedangkan wajah menggunakan masker berhasil dikenali berjumlah 894 data dan yang salah berjumlah 2 data.

4.6. Percobaan Skenario

Penelitian ini dilakukan dengan beberapa skenario percobaan untuk mendapatkan hasil terbaik dari proses klasifikasi gambar wajah menggunakan masker dan tanpa menggunakan masker. Skenario yang dilakukan ada delapan yaitu dimana skenario pertama sampai ketiga menggunakan gambar asli menggunakan metode *Convolutional Neural Network (CNN)* yang sudah dilakukan *preprocessing* sebelumnya perbedaannya dari pengujian perulangan atau *Epoch* (10, 25 dan 50).

Skenario ke empat sampai ke enam dengan menambahkan ekstraksi fitur *Local binary pattern* (LBP) pada gambar dan dilanjutkan dengan klasifikasi menggunakan metode *Convolutional Neural Network* (CNN) perbedaan skenario ke empat sampai ke enam dari pengujian perulangan atau *Epoch* (10, 25 dan 50). Skenario ke tujuh dilakukan perbedaan dataset dimana dataset khusus masker medis warna biru dan yang ke delapan dataset masker dengan warna putih. Skenario penelitian ini terlihat pada table 4.1 dibawah ini.

Tabel 4. 1 Skenario percobaan

No.	Skenario	Keterangan
1	S1	Gambar Asli + CNN (Epoch=10)
2	S2	Gambar Asli + CNN (Epoch=25)
3	S3	Gambar Asli + CNN (Epoch=50)
4	S4	LBP + CNN (Epoch=10)
5	S5	LBP + CNN (Epoch=25)
6	S6	LBP + CNN (Epoch=50)
7	S7	Dataset masker medis (biru) + CNN
8	S8	Dataset masker medis (putih) + CNN

4.7. Hasil Training dan Testing Data

Setelah proses *dataset*, *preprocessing* dan *segmentasi* gambar dilakukan maka selanjutnya pengujian dilakukan dengan enam skenario yang dimana tiga skenario dengan gambar asi atau *original image*, tiga skenario fokus penelitian yang diambil menggunakan ekstraksi fitur *local binary pattern* (LBP), dan dua skenario mencoba dengan dataset berbeda dimana digunakan kelompok masker warna biru dan masker warna putih. Dan dilakukan proses klasifikasi untuk menguji model yang telah dibuat menggunakan metode *convolutional neural network* (CNN).

Tabel 4. 2 Akurasi Validasi untuk setiap deskriptor fitur

Deskripsi Fitur	Gambar Asli + CNN			LBP + CNN		
	epoch=10	epoch=25	epoch=50	epoch=10	epoch=25	epoch=50
Akurasi Terbaik (%)	98.90	100	99.27	87.91	99.27	99.63
Rata-rata (%)	98.07 (+/- 1.78)	98.43 (+/- 1.63)	99.22 (+/- 0.53)	82.96 (+/- 4.91)	93.99 (+/- 5.28)	95.40 (+/- 4.29)

Tabel 4. 3 Akurasi Validasi untuk setiap deskriptor fitur berbeda

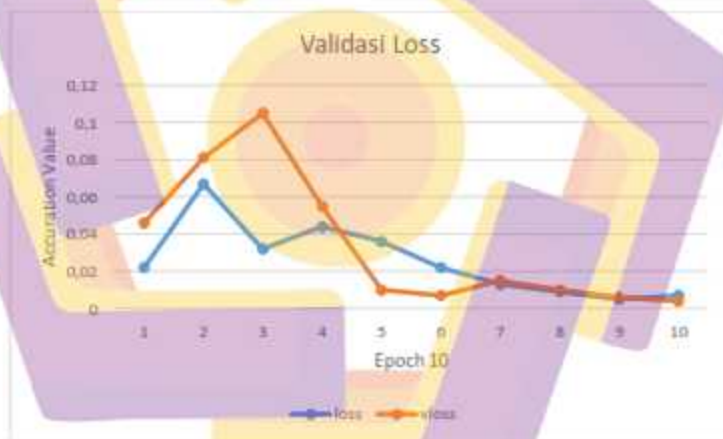
Deskripsi Fitur	Gambar Masker (biru) + CNN	Gambar Masker (putih) + CNN
	epoch=25	epoch=25
Akurasi Terbaik (%)	97.62	69.05
Rata-rata (%)	99.00 (+/- 1.70)	91.92 (+/- 10.46)

4.7.1. Skenario pertama

Skenario pertama pengujian menggunakan *dataset* gambar asli yang sudah dilakukan *preprocessing* dan *segmentasi*. Klasifikasi pengujian ini dilakukan metode *convolutional neural network* (CNN) dengan layer sebanyak 6 layer dan *epoch* sebanyak 10. Pada table 4.2 di atas menunjukkan akurasi terbaik yang dicapai pada data validasi adalah 98.90%, dari *dataset* citra yang diujikan sebanyak 1914 citra dan memperoleh rata-rata 97.08% dari semua pengujian yang dilakukan. Hasil dari proses *training* dan *validation* pada pengujian dibuat dalam bentuk grafik maka akan terlihat pada gambar 4.16 dan gambar 4.17 dibawah ini.



Gambar 4.16 Grafik *training* dan *validation accuracy* skenario pertama



Gambar 4.17 Grafik *training* dan *validation loss* skenario pertama

Gambar 4.16 terlihat proses *training* dan *validation* dari *epoch* pertama sampai dengan 10 mengalami turun naik dan menghasilkan *training accuracy* 99.9%, sedangkan *validation accuracy* mencapai 99.9%. Pada gambar 4.17 terlihat nilai *loss* dari *epoch* pertama sampai dengan 10 mengalami penurunan dimana *training loss* mencapai 0.007 dan *validation loss* mencapai 0.004. Model yang

sudah terbentuk dari proses *training* dan *testing* diuji kembali menggunakan *confusion matrix*.

True label	tanpa masker	1,021	14
	Masker	23	827
		tanpa masker	Masker

Gambar 4. 18 *Confusion matrix* pengujian skenario pertama

Dari gambar 4.18 terlihat prediksi menggunakan 1885 data uji, dimana 1885 data yang terbagi dalam kelas tanpa masker 1035 data dan 850 kelas masker. Diketahui 1035 data kelas tanpa masker diprediksi benar 1020 data dan salah 14 data. Sedangkan 850 data kelas masker di prediksi benar 827 data dan salah 23 data. Dari proses ini didapatkan hasil *accuracy*, *precision*, dan *recall*.

$$Accuracy = \frac{1021 + 827}{1885} = 0,9803 \quad (6)$$

$$Precision \text{ (tanpa masker)} = \frac{1021}{1021 + 14} = 0,9864 \quad (7)$$

$$Precision \text{ (masker)} = \frac{827}{827 + 23} = 0,9729 \quad (8)$$

$$\textit{Precision} = \frac{0,9864 + 0,9729}{2} = 0,97965 \quad (9)$$

$$\textit{Recall (tanpa masker)} = \frac{1021}{1021 + 23} = 0,9779 \quad (10)$$

$$\textit{Recall (masker)} = \frac{827}{827 + 14} = 0,9833 \quad (11)$$


Dari perhitungan diatas, pengujian terhadap model yang telah dibangun diketahui menghasilkan nilai *accuracy* 0,9803, nilai *precision* 0,9796, dan nilai *recall* 0,9806.

4.7.2. Skenario kedua

Skenario pertama pengujian menggunakan *dataset* gambar asli yang sudah dilakukan *preprocessing* dan *segmentasi*. Klasifikasi pengujian ini dilakukan metode *convolutional neural network* (CNN) dengan *layer* sebanyak 6 *layer* dan *epoch* sebanyak 25. Pada table 4.2 di atas menunjukkan akurasi terbaik yang dicapai pada data validasi adalah 100%. dari *dataset* citra yang diujikan sebanyak 1914 citra dan memperoleh rata-rata 98.43% dari semua pengujian yang dilakukan. Hasil dari proses *training* dan *validation* pada pengujian dibuat dalam bentuk grafik maka akan terlihat pada gambar 4.19 dan gambar 4.20 dibawah ini.




Gambar 4.19 Grafik *training* dan *validation accuracy* skenario kedua



Gambar 4.20 Grafik *training* dan *validation loss* skenario kedua

Gambar 4.19 terlihat proses *training* dan *validation* dari *epoch* pertama sampai dengan 25 mengalami turun naik dan menghasilkan *training accuracy* 0,9971%, sedangkan *validation accuracy* mencapai 0,9979%. Pada gambar 4.20 terlihat nilai *loss* dari *epoch* pertama sampai dengan 25 mengalami penurunan dimana *training loss* mencapai 0.003 dan *validation loss* mencapai 0.003. Model

yang sudah terbentuk dari proses *training* dan *testing* diuji kembali menggunakan *confusion matrix*.



Gambar 4. 21 *Confusion matrix* pengujian skenario kedua

Dari gambar 4.21 terlihat prediksi menggunakan 1885 data pengujian, dimana 1885 data yang terbagi dalam kelas tanpa masker 1035 data dan 850 kelas masker. Diketahui 1035 data kelas tanpa masker diprediksi benar 1022 data dan yang salah 13 data. Sedangkan 850 data kelas masker di prediksi benar 700 data dan yang salah 150 data. Dari proses ini didapatkan hasil *accuracy*, *precision*, dan *recall*.

$$Accuracy = \frac{1022 + 700}{1885} = 0,9135 \quad (12)$$

$$Precision \text{ (tanpa masker)} = \frac{1022}{1022 + 13} = 0,9874 \quad (13)$$

$$Precision \text{ (masker)} = \frac{700}{700 + 150} = 0,8235 \quad (14)$$

$$\textit{Precision} = \frac{0,9874 + 0,8235}{2} = 0,9054 \quad (15)$$

$$\textit{Recall (tanpa masker)} = \frac{1022}{1022 + 150} = 0,872 \quad (16)$$

$$\textit{Recall (masker)} = \frac{700}{700 + 13} = 0,9817 \quad (17)$$

$$\textit{Recall} = \frac{0,872 + 0,9817}{2} = 0,9268 \quad (18)$$


Dari perhitungan diatas, pengujian terhadap model yang telah dibangun diketahui menghasilkan nilai *accuracy* 0,9135, nilai *precision* 0,9054, dan nilai *recall* 0,9268.

4.7.3. Skenario ketiga

Skenario ketiga pengujian menggunakan *dataset* gambar asli yang sudah dilakukan *preprocessing* dan *segmentasi*. Klasifikasi pengujian ini dilakukan metode *convolutional neural network* (CNN) dengan layer sebanyak 6 layer dan *epoch* sebanyak 50. Pada [table 4.2 di atas](#) menunjukkan akurasi terbaik yang dicapai pada data validasi adalah 99.27%. dari dataset citra yang diujikan sebanyak 1914 citra dan memperoleh rata-rata 99.22 % dari semua pengujian yang dilakukan. Hasil dari proses *training* dan *validation* pada pengujian dibuat dalam bentuk grafik maka akan terlihat pada gambar 4.22 dan gambar 4.23 dibawah ini.




Gambar 4.22 Grafik *training* dan *validation accuracy* skenario ketiga



Gambar 4.23 Grafik *training* dan *validation loss* skenario ketiga

Gambar 4.22 terlihat proses *training* dan *validation* dari *epoch* pertama sampai dengan 50 mengalami turun naik dan menghasilkan *training accuracy* 0.999%, sedangkan *validation accuracy* mencapai 0.998%. Pada gambar 4.23 terlihat nilai *loss* dari *epoch* pertama sampai dengan 50 mengalami penurunan dimana *training loss* mencapai 0.001 dan *validation loss* mencapai 0.002. Model

yang sudah terbentuk dari proses *training* dan *testing* diuji kembali menggunakan *confusion matrix*.



Gambar 4. 24 *Confusion matrix* pengujian skenario ketiga

Dari gambar 4.24 terlihat prediksi menggunakan 1885 data uji, dimana 1885 data yang terbagi dalam kelas tanpa masker 1035 data dan 850 kelas masker. Diketahui 1035 data kelas tanpa masker diprediksi benar 1030 data dan yang salah data. Selanjutnya 850 data kelas masker di prediksi benar 764 data dan yang salah 86 data. Dari proses ini didapatkan hasil *accuracy*, *precision*, dan *recall*.

$$Accuracy = \frac{1030 + 764}{1885} = 0,9517 \quad (19)$$

$$Precision \text{ (tanpa masker)} = \frac{1030}{1030 + 5} = 0,9951 \quad (20)$$

$$Precision \text{ (masker)} = \frac{764}{764 + 86} = 0,8988 \quad (21)$$

$$\textit{Precision} = \frac{0,9951 + 0,8988}{2} = 0,9469 \quad (22)$$

$$\textit{Recall (tanpa masker)} = \frac{1030}{1030 + 86} = 0,9229 \quad (23)$$

$$\textit{Recall (masker)} = \frac{764}{764 + 5} = 0,9934 \quad (24)$$

$$\textit{Recall} = \frac{0,9229 + 0,9934}{2} = 0,9581 \quad (25)$$

Dari perhitungan diatas, pengujian terhadap model yang telah dibangun diketahui menghasilkan nilai *accuracy* 0.9517, nilai *precision* 0.9469, dan nilai *recall* 0.9581.

4.7.4. Skenario keempat LBP-CNN

Skenario keempat pengujian menggunakan *dataset* gambar asli yang sudah dilakukan *preprocessing* dan *segmentasi*. Sebelum dilakukan proses klasifikasi dilakukan ekstraksi fitur dengan metode *local binary patter* (LBP), untuk mengetahui apakah metode yang dilakukan dengan penambahan fitur LBP terlebih dahulu dapat meningkatkan hasil akurasi penelitian. Klasifikasi pengujian ini dilakukan metode *convolutional neural network* (CNN) dengan layer sebanyak 6 layer dan *epoch* sebanyak 10. Pada table 4.2 di atas menunjukkan akurasi terbaik yang dicapai pada data validasi adalah 87.91%. dari dataset citra yang diujikan sebanyak 1914 citra dan memperoleh rata-rata 82.96% dari semua pengujian yang

dilakukan. Hasil dari proses *training* dan *validation* pada pengujian dibuat dalam bentuk grafik maka akan terlihat pada gambar 4.25 dan gambar 4.26 dibawah ini.



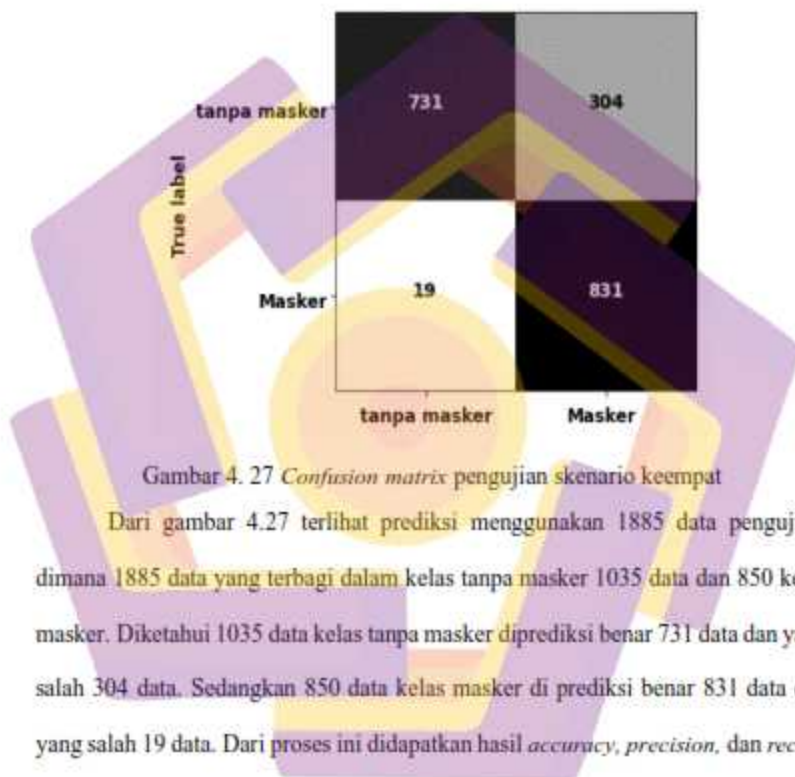
Gambar 4. 25 Grafik *training* dan *validation accuracy* skenario keempat



Gambar 4. 26 Grafik *training* dan *validation loss* skenario keempat

Gambar 4.25 terlihat proses *training* dan *validation* dari *epoch* pertama sampai dengan 10 mengalami turun naik dan menghasilkan *training accuracy* 0.995%, sedangkan *validation accuracy* mencapai 0.879%. Pada gambar 4.26

terlihat nilai *loss* dari *epoch* pertama sampai dengan 10 mengalami penurunan dimana *training loss* mencapai 0.013 dan *validation loss* mencapai 0.308. Model yang sudah terbentuk dari proses *training* dan *testing* diuji kembali menggunakan *confusion matrix*.



$$Accuracy = \frac{731 + 831}{1885} = 0,8286 \quad (26)$$

$$Precision (tanpa masker) = \frac{731}{731 + 304} = 0,7062 \quad (27)$$

$$\textit{Precision (masker)} = \frac{831}{831 + 19} = 0,9776 \quad (28)$$

$$\textit{Precision} = \frac{0,7062 + 0,9776}{2} = 0,8419 \quad (29)$$

$$\textit{Recall (tanpa masker)} = \frac{731}{731 + 19} = 0,9746 \quad (30)$$

$$\textit{Recall (masker)} = \frac{831}{831 + 304} = 0,7321 \quad (31)$$


$$\textit{Recall} = \frac{0,9746 + 0,7321}{2} = 0,8533 \quad (32)$$

Dari perhitungan diatas, pengujian terhadap model yang telah dibangun diketahui menghasilkan nilai *accuracy* 0.8286, nilai *precision* 0.8419, dan nilai *recall* 0.8533.


4.7.5. Skenario kelima LBP-CNN

Skenario kelima pengujian menggunakan *dataset* gambar asli yang sudah dilakukan *preprocessing* dan *segmentasi*. Sebelum dilakukan proses klasifikasi dilakukan ekstraksi fitur dengan metode *local binary patter* (LBP), untuk mengetahui apakah metode yang dilakukan dengan penambahan fitur LBP terlebih dahulu dapat meningkatkan hasil akurasi penelitian. Klasifikasi pengujian ini dilakukan metode *convolutional neural network* (CNN) dengan layer sebanyak 6 layer dan *epoch* sebanyak 25. Pada table 4.2 di atas menunjukkan akurasi terbaik yang dicapai pada data validasi adalah 99.27%. dari dataset citra yang diujikan

sebanyak 1914 citra dan memperoleh rata-rata 93.99% dari semua pengujian yang dilakukan. Hasil dari proses *training* dan *validation* pada pengujian dibuat dalam bentuk grafik maka akan terlihat pada gambar 4.28 dan gambar 4.29 dibawah ini.



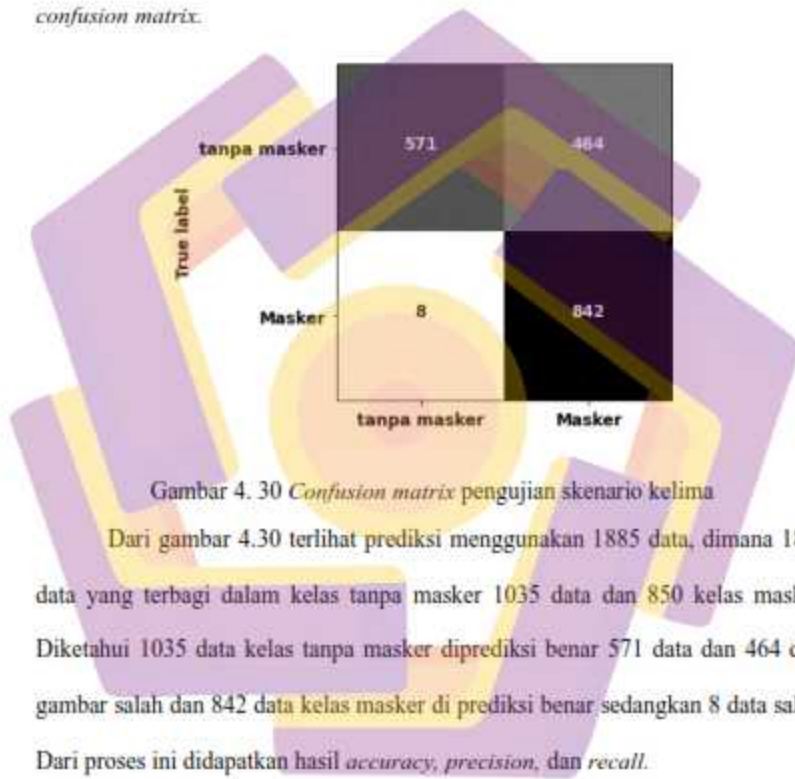
Gambar 4. 28 Grafik *training* dan *validation accuracy* skenario kelima



Gambar 4. 29 Grafik *training* dan *validation loss* skenario kelima

Gambar 4.28 terlihat proses *training* dan *validation* dari *epoch* pertama sampai dengan 25 mengalami turun naik dan menghasilkan *training accuracy*

0,996%, sedangkan *validation accuracy* mencapai 0,769%. Pada gambar 4.29 terlihat nilai *loss* dari *epoch* pertama sampai dengan 25 mengalami penurunan dimana *training loss* mencapai 0,012 dan *validation loss* mencapai 0,880. Model yang sudah terbentuk dari proses *training* dan *testing* diuji kembali menggunakan *confusion matrix*.



$$Accuracy = \frac{571 + 842}{1885} = 0,7496 \quad (33)$$

$$Precision \text{ (tanpa masker)} = \frac{571}{571 + 464} = 0,5516 \quad (34)$$

$$\textit{Precision (masker)} = \frac{842}{842 + 8} = 0,9905 \quad (35)$$

$$\textit{Precision} = \frac{0,5516 + 0,9905}{2} = 0,771 \quad (36)$$

$$\textit{Recall (tanpa masker)} = \frac{571}{571 + 8} = 0,9861 \quad (37)$$

$$\textit{Recall (masker)} = \frac{842}{842 + 464} = 0,6447 \quad (38)$$


$$\textit{Recall} = \frac{0,9861 + 0,6447}{2} = 0,8154 \quad (39)$$

Dari perhitungan diatas, pengujian terhadap model yang telah dibangun diketahui menghasilkan nilai *accuracy* 0.7496, nilai *precision* 0.771, dan nilai *recall* 0.8154.


4.7.6. Skenario keenam LBP-CNN

Skenario keenam pengujian menggunakan *dataset* gambar asli yang sudah dilakukan *preprocessing* dan *segmentasi*. Sebelum dilakukan proses klasifikasi dilakukan ekstraksi fitur dengan metode *local binary patter* (LBP), untuk mengetahui apakah metode yang dilakukan dengan penambahan fitur LBP terlebih dahulu dapat meningkatkan hasil akurasi penelitian. Klasifikasi pengujian ini dilakukan metode *convolutional neural network* (CNN) dengan layer sebanyak 6 layer dan *epoch* sebanyak 50. Pada table 4.2 di atas menunjukkan akurasi terbaik

yang dicapai pada data validasi adalah 99,63%. dari dataset citra yang diujikan sebanyak 1914 citra dan memperoleh rata-rata 95,40% dari semua pengujian yang dilakukan. Hasil dari proses *training* dan *validation* pada pengujian dibuat dalam bentuk grafik maka akan terlihat pada gambar 4.31 dan gambar 4.32 dibawah ini.



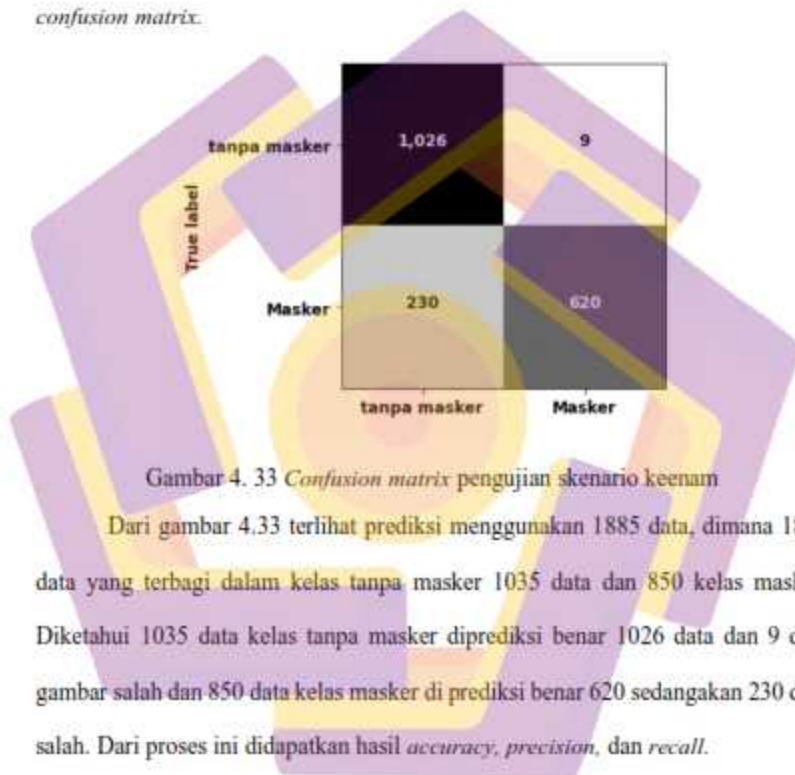
Gambar 4. 31 Grafik *training* dan *validation accuracy* skenario keenam



Gambar 4. 32 Grafik *training* dan *validation loss* skenario keenam

Gambar 4.31 terlihat proses *training* dan *validation* dari *epoch* pertama sampai dengan 50 mengalami turun naik dan menghasilkan *training accuracy*

0,999%, sedangkan *validation accuracy* mencapai 0,996%. Pada gambar 4.32 terlihat nilai *loss* dari *epoch* pertama sampai dengan 50 mengalami penurunan dimana *training loss* mencapai 0,003 dan *validation loss* mencapai 0,007. Model yang sudah terbentuk dari proses *training* dan *testing* diuji kembali menggunakan *confusion matrix*.



$$Accuracy = \frac{1026 + 620}{1885} = 0,8732 \quad (40)$$

$$Precision \text{ (tanpa masker)} = \frac{1026}{1026 + 9} = 0,9913 \quad (41)$$

$$\textit{Precision (masker)} = \frac{620}{620 + 230} = 0,7294 \quad (42)$$

$$\textit{Precision} = \frac{0,9913 + 0,7294}{2} = 0,8603 \quad (43)$$

$$\textit{Recall (tanpa masker)} = \frac{1026}{1026 + 230} = 0,8168 \quad (44)$$

$$\textit{Recall (masker)} = \frac{620}{620 + 9} = 0,9856 \quad (45)$$

$$\textit{Recall} = \frac{0,8168 + 0,9856}{2} = 0,9012 \quad (46)$$

Dari perhitungan diatas, pengujian terhadap model yang telah dibangun diketahui menghasilkan nilai *accuracy* 0.8732, nilai *precision* 0.8603, dan nilai *recall* 0.9012.

4.7.7. Skenario ketujuh Dataset Gambar masker warna biru

Skenario ketiga pengujian menggunakan *dataset* gambar masker berwarna biru seperti pada gambar 4.34 dibawah ini.




Gambar 4. 34 Dataset gambar masker warna biru

Dataset gambar masker warna biru pada gambar 4.34 diatas berjumlah 600 data dimana 300 data latih dan 300 data uji. Selanjutnya gambar dilakukan *preprocessing* dan *segmentasi*. Klasifikasi pengujian ini dilakukan metode *convolutional neural network* (CNN) dengan layer sebanyak 6 layer dan *epoch* sebanyak 25. Pada table 4.3 di atas menunjukkan akurasi terbaik yang dicapai pada data validasi adalah 97.62%, dari dataset citra yang diujikan sebanyak 300 citra dan memperoleh rata-rata 89.67 % dari semua pengujian yang dilakukan. Hasil dari proses *training* dan *validation* pada pengujian dibuat dalam bentuk grafik maka akan terlihat pada gambar 4.35 dan gambar 4.36 dibawah ini.



Gambar 4. 35 Grafik *training* dan *validation accuracy* skenario ketujuh



Gambar 4.36 Grafik *training* dan *validation loss* skenario ketujuh

Gambar 4.35 terlihat proses *training* dan *validation* dari *epoch* pertama sampai dengan 25 mengalami turun naik dan menghasilkan *training accuracy* 0,977%, sedangkan *validation accuracy* mencapai 0,976%. Pada gambar 4.36 terlihat nilai *loss* dari *epoch* pertama sampai dengan 25 mengalami penurunan dimana *training loss* mencapai 0,012 dan *validation loss* mencapai 0,014. Model yang sudah terbentuk dari proses *training* dan *testing* diuji kembali menggunakan *confusion matrix*.

True label	tanpa masker	150	0
	Masker	31	119
		tanpa masker	Masker

Predicted label
Test accuracy=89.67%; Misclass=10.33%

Gambar 4. 37 *Confusion matrix* pengujian skenario ketujuh

Dari gambar 4.37 terlihat prediksi menggunakan 300 data uji, dimana 300 data yang terbagi dalam kelas tanpa masker 150 data dan 150 kelas masker. Diketahui 150 data kelas tanpa masker diprediksi benar 150 data dan yang salah 0 data. Selanjutnya 150 data kelas masker di prediksi benar 119 data dan yang salah 31 data. Dari proses ini didapatkan hasil *accuracy*, *precision*, dan *recall*.

$$Accuracy = \frac{150 + 119}{300} = 0,8966 \quad (47)$$

$$Precision \text{ (tanpa masker)} = \frac{150}{150 + 0} = 1 \quad (48)$$

$$Precision \text{ (masker)} = \frac{119}{119 + 31} = 0,7933 \quad (49)$$

$$Precision = \frac{1 + 0,7993}{2} = 0,8996 \quad (50)$$

$$\text{Recall (tanpa masker)} = \frac{150}{150 + 31} = 0,8287 \quad (51)$$

$$\text{Recall (masker)} = \frac{119}{119 + 0} = 1 \quad (52)$$

$$\text{Recall} = \frac{0,8996 + 1}{2} = 0,9498 \quad (53)$$

Dari perhitungan diatas, pengujian terhadap model yang telah dibangun diketahui menghasilkan nilai *accuracy* 0.8966, nilai *precision* 0.8966, dan nilai *recall* 0.9498.

4.7.8. Skenario ketujuh Dataset Gambar masker warna putih

Skenario ketiga pengujian menggunakan *dataset* gambar masker berwarna putih seperti pada gambar 4.38 dibawah ini.




Gambar 4. 38 Dataset gambar masker warna putih

Dataset gambar masker warna biru pada gambar 4.38 diatas berjumlah 600 data dimana 300 data latih dan 300 data uji. Selanjutnya gambar dilakukan *preprocessing* dan *segmentasi*. Klasifikasi pengujian ini dilakukan metode *convolutional neural network* (CNN) dengan layer sebanyak 6 layer dan *epoch*

sebanyak 25. Pada table 4.3 di atas menunjukkan akurasi terbaik yang dicapai pada data validasi adalah 69.05%. dari dataset citra yang diujikan sebanyak 300 citra dan memperoleh rata-rata 91.92 % dari semua pengujian yang dilakukan. Hasil dari proses *training* dan *validation* pada pengujian dibuat dalam bentuk grafik maka akan terlihat pada gambar 4.39 dan gambar 4.40 dibawah ini.

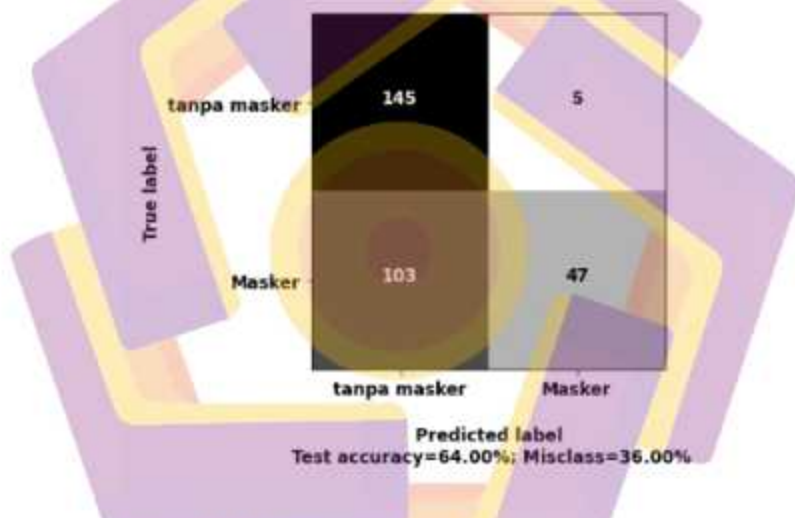


Gambar 4. 39 Grafik *training* dan *validation accuracy* skenario kedelapan



Gambar 4. 40 Grafik *training* dan *validation loss* skenario kedelapan

Gambar 4.39 terlihat proses *training* dan *validation* dari *epoch* pertama sampai dengan 25 mengalami turun naik dan menghasilkan *training accuracy* 0.981%, sedangkan *validation accuracy* mencapai 0.690%. Pada gambar 4.40 terlihat nilai *loss* dari *epoch* pertama sampai dengan 25 mengalami penurunan dimana *training loss* mencapai 0.067 dan *validation loss* mencapai 0.007. Model yang sudah terbentuk dari proses *training* dan *testing* diuji kembali menggunakan *confusion matrix*.



Gambar 4. 41 *Confusion matrix* pengujian skenario kedelapan

Dari gambar 4.41 terlihat prediksi menggunakan 300 data uji, dimana 300 data yang terbagi dalam kelas tanpa masker 150 data dan 150 kelas masker. Diketahui 150 data kelas tanpa masker diprediksi benar 145 data dan yang salah 5 data. Selanjutnya 150 data kelas masker di prediksi benar 47 data dan yang salah 103 data. Dari proses ini didapatkan hasil *accuracy*, *precision*, dan *recall*.

$$\text{Accuracy} = \frac{145 + 47}{300} = 0,64 \quad (54)$$

$$\text{Precision (tanpa masker)} = \frac{145}{145 + 5} = 0,9666 \quad (55)$$

$$\text{Precision (masker)} = \frac{47}{47 + 103} = 0,3133 \quad (56)$$

$$\text{Precision} = \frac{0,9666 + 0,3133}{2} = 0,6399 \quad (57)$$

$$\text{Recall (tanpa masker)} = \frac{145}{145 + 103} = 0,9177 \quad (58)$$

$$\text{Recall (masker)} = \frac{47}{47 + 5} = 0,9038 \quad (59)$$

$$\text{Recall} = \frac{0,9177 + 0,9038}{2} = 0,9491 \quad (60)$$

Dari perhitungan diatas, pengujian terhadap model yang telah dibangun diketahui menghasilkan nilai *accuracy* 0.6400, nilai *precision* 0.6399, dan nilai *recall* 0.9491.

4.7.9. Perbandingan Hasil

Dalam pengujian yang dilakukan perbandingan hasil berdasarkan nilai *accuracy*, *precision* dan *recall* dari keenam pengujian yang dilakukan berikut grafik hasil dari pengujian yang dilakukan seperti pada gambar 4.42 dibawah ini.



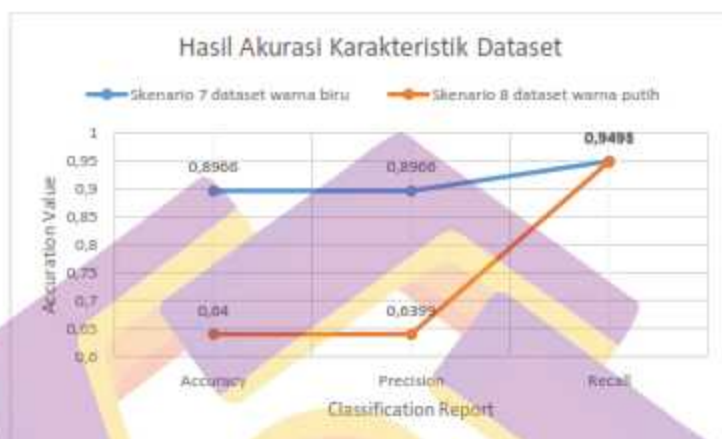
Gambar 4. 42 Grafik hasil pengujian

Pada gambar 4.42 memperlihatkan nilai persentase dari *accuracy*, *precision* dan *recall* antara keenam skenario yang diujikan. Dari grafik diatas terlihat S1 (skenario pertama) mendapatkan nilai tertinggi, urutan kedua S3, urutan ketiga S2, urutan keempat S6, urutan kelima S4 dan yang urutan terakhir yaitu S5 atau skenario lima. Dari tingkat *accuracy*, *precision* dan *recall* diatas terdapat 2 skenario yang berbeda dimana skenario 1-3 itu menggunakan dataset gambar asli sedangkan skenario 4-6 itu menggunakan dataset yang dilakukan ekstraksi fitur, hasilnya gambar asli mendapatkan akurasi lebih tinggi dari dataset dengan ekstraksi fitur. Hal ini dikarenakan gambar yang dilakukan ekstraksi fitur mengalami kehilangan fitur-fitur warna gambar itu sendiri.

4.7.10. Perbandingan Hasil Dataset berbeda

Dalam pengujian yang dilakukan perbandingan hasil berdasarkan nilai *accuracy*, *precision* dan *recall* dari pengujian ke tujuh dan ke delapan dengan

dataset berbeda warna masker putih dan biru pengujian yang dilakukan berikut grafik hasil dari pengujian yang dilakukan seperti pada gambar 4.43 dibawah ini.



Gambar 4. 43 Grafik hasil pengujian dataset berbeda

Pada gambar 4.43 memperlihatkan nilai persentase dari *accuracy*, *precision* dan *recall* antara keenam skenario yang diujikan. Dari grafik diatas terlihat S7 (skenario tujuh) mendapatkan nilai tertinggi dibandingkan dengan S8 (skenario delapan), sehingga masker dengan warna biru atau pengujian ke tujuh mendapatkan akurasi tertinggi dibandingkan dengan pengujian ke delapan masker warna putih. Hasil yang jauh berbeda memungkinkan pada pengujian sebelumnya menjadi rendah akurasi karena gambar masker warna putih tidak efektif pada komputasi klasifikasi yang dilakukan pada penelitian ini.

4.7.11. Perbandingan Waktu Proses

Pengambilan waktu proses terbaik dari penelitian ini diambil dari arsitektur 6 layer CNN yang dipakai pada penelitian ini dan arsitektur dasar atau *baseline* dengan VGG-16. Dapat terlihat pada table 4.4 dibawah ini :

Tabel 4. 4 Waktu Proses Komputasi

Arsitektur	Jumlah Dataset	Epoch	Akurasi %	Waktu (s)
Original Image+CNN	3772	50	95,17	22,418
LBP+CNN	3772	50	87,32	22,427
VGG-16 - transfer learning	3772	50	99,69	25,577

Dari table 4.4 diatas dengan jumlah dataset yang sama dan jumlah epoch yang sama VGG-16 sebagai dasar atau *baseline* dari penelitian ini akurasi lebih unggul dari arsitektur yang diajukan yaitu 99,69%, sedangkan untuk akurasi waktu komputasi arsitektur yang dipakai pada penelitian ini lebih unggul dari arsitektur dasar. Sehingga arsitektur yang dipakai pada penelitian ini dalam komputasi lebih cepat dari arsitektur VGG-16 atau dasar pengujian.

4.7.12. Analisa Penelitian Terkait

Dari literatur sebagian besar peneliti menggunakan model transfer learning atau pembelajaran lanjutan tentang klasifikasi gambar menggunakan masker dan tanpa menggunakan masker. Dibandingkan dengan peneliti sebelumnya dimana dataset semua jenis masker dipakai untuk proses klasifikasi, maka pada penelitian ini dilakukan pengujian satu jenis masker medis dan ditambah pengujian berdasarkan karakteristik warna masker biru dan putih.

Militante et al (2020b) model yang digunakan yaitu transfer learning menggunakan model CNN VGG16 dimana akurasi yang diperoleh sebesar 96%. Sedangkan model pada penelitian yang diusulkan mendapatkan akurasi gambar menggunakan ekstraksi fitur sebesar 87.32%, sedangkan gambar tanpa ekstraksi fitur memperoleh akurasi sebesar 98.03%. Dari hasil akurasi gambar dengan ekstraksi fitur lebih rendah dari model VGG16 akan tetapi akurasi waktu komputasi model

yang dibangun pada penelitian ini lebih baik dengan waktu 3.150 detik lebih unggul dari model CNN VGG16.

Mujib, dkk (2018) mengusulkan metode menggunakan fitur LBP dengan klasifikasi *Support Vector Machine (SVM)*. Hasil dari klasifikasi menggunakan fitur LBP mendapatkan akurasi sebesar 96%. Sedangkan penelitian yang dilakukan hanya mendapatkan akurasi terbaik 87.32%. Oleh karena itu, fitur LBP bekerja lebih baik dengan pengklasifikasi SVM dari pada model arsitektur CNN yang dilakukan pada penelitian ini.

Ayuningsih, dkk (2019) mengusulkan metode menggunakan fitur LBP, HSV dengan klasifikasi *naïve bayes*. Dengan fitur LBP, HSV yang dimana dilakukan proses klasifikasi menggunakan metode *naïve bayes* akurasi didapat sebesar 65%. Namun pada penelitian ini menggunakan fitur LBP dengan klasifikasi menggunakan CNN mendapatkan akurasi 87.32%. maka pada penelitian ini fitur LBP bekerja lebih baik menggunakan CNN dibandingkan menggunakan *naïve bayes*.

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan analisa hasil pada percobaan yang telah dilakukan dengan enam skenario percobaan dapat disimpulkan bahwa :

- a. Pengaruh segmentasi warna pada pengujian dengan gambar original selanjutnya dilakukan ekstraksi fitur LBP terlihat pada pengujian mendapatkan akurasi terbaik pada pengujian dengan *epoch* 50 yang pada pengujian S6. Akurasi yang didapat lebih rendah dibanding dengan gambar tanpa ekstraksi fitur karena gambar yang dilakukan ekstraksi fitur kehilangan beberapa fitur warna awal proses klasifikasi menggunakan CNN pada penelitian yang telah dilakukan.
- b. Hasil dari pengaruh segmentasi warna pada pengujian dengan menerapkan gambar asli yang sebelumnya dilakukan *preprocessing* pengujian S1 dengan *epoch* 10 mendapatkan akurasi terbaik dengan nilai akurasi 98.03%.
- c. Pengaruh dari segmentasi fitur ekstraksi ciri pada gambar yang dilakukan dengan ekstraksi fitur *local binary pattern* (LBP) pengujian terbaik pada S6 dengan *epoch* 50 dengan *accuracy*, *precision* dan *recall* sebesar 87.32%. Sehingga pada pengujian ini ekstraksi fitur LBP berfungsi dengan baik untuk mendapatkan akurasi terbaik dalam klasifikasi gambar wajah menggunakan masker dan tanpa menggunakan masker.
- d. Tingkat akurasi yang didapatkan dari ekstraksi fitur LBP dan CNN pengujian dilakukan pada skenario empat atau S4, S5, dan S6 yang dimana S6 menjadi

akurasi terbaik dengan 87.32% dengan *epoch* 50, sedangkan S4 dan S5 mengalami penurunan tingkat akurasi yang didapat S4 sebesar 82.86% dan S5 sebesar 74.96%.


- e. Pengujian dengan karakteristik yang berbeda dimana dilakukan pengujian ke tujuh dengan masker warna biru dan pengujian ke delapan dengan masker warna putih, didapat hasil pengujian ke tujuh mendapatkan akurasi terbaik sebesar 89.66%, sedangkan untuk pengujian ke delapan akurasi didapat lebih rendah sebesar 64%.

5.2. Saran

Berikut ini adalah beberapa saran yang dapat dijadikan pedoman untuk melakukan pengembangan pada penelitian ini, diantaranya adalah :

- a. Penelitian selanjutnya dapat mencoba arsitektur CNN yang lainnya apakah berpengaruh terhadap hasil.
- b. Ukuran gambar pada pengujian dapat dilakukan dengan ukuran lain.
- c. Pengujian memang lebih baik jika dilakukan dengan komputer lokal seperti pada penelitian ini. Karena dari beberapa pengujian yang peneliti coba lakukan menggunakan google colab komputasi terhenti karena jaringan internet.
- d. Bisa dilakukan percobaan yang lebih variative, bisa dengan metode lainnya untuk sebagai perbandingan hasil.
- e. Untuk penggunaan ekstraksi fitur gambar dengan *local binary pattern* (LBP) pada klasifikasi gambar wajah menggunakan masker dan tanpa masker belum optimal, peneliti selanjutnya bisa dicoba dengan ekstraksi fitur yang lain.

- f. Gambar masker warna biru dari komputasi yang dilakukan lebih unggul dalam pengenalan hasil akurasi dibanding masker warna putih, sehingga bisa dipertimbangkan jika ingin mendalami pengenalan masker berwarna biru atau putih dalam pengenalan secara realtime bisa dilakukan apakah banyak kesalahan pembacaan untuk kedua masker tersebut.



DAFTAR PUSTAKA

PUSTAKA BUKU

Suyanto., 2019, Deep Learning. Modernisasi Machine Learning Untuk Big Data. Bandung:Informatika Bandung.

PUSTAKA MAJALAH, JURNAL ILMIAH ATAU PROSIDING

Alom, Md Zahangir et al. 2018. "The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches." *arXiv*.

Aprilian Anarki, Galang, Karina Auliasari, and Mira Orisa. 2021. "Penerapan Metode Haar Cascade Pada Aplikasi Deteksi Masker." *JATI (Jurnal Mahasiswa Teknik Informatika)* 5(1): 179–86.

Ayuningsih, Karunia, Yuita Arum Sari, and Putra Pandu Adikara. 2019. "Klasifikasi Citra Makanan Menggunakan HSV Color Moment Dan Local Binary Pattern Dengan Naïve Bayes Classifier." Ayuningsih, Karunia, Yuita Arum Sari, and Putra Pandu Adikara. 2019. "Klasifikasi Citra Makanan Menggunakan HSV Color Moment Dan Local Binary Patt." *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (J-PTIIK) Universitas Brawijaya* 3(4): 3166–73.

Han, Jiawei, Micheline Kamber, and Jian Pei. 2012. Data Mining: Concepts and Techniques *Data Mining: Concepts and Techniques*.

Hermawan, Egie. 2021. "Klasifikasi Pengenalan Wajah Menggunakan Masker Atau Tidak Dengan Mengimplementasikan Metode CNN (Convolutional Neural Network)." 1: 33–43.

Hosseini, Sepidehsadat et al. 2018. "Age and Gender Classification Using Wide Convolutional Neural Network and Gabor Filter." In *2018 International Workshop on Advanced Image Technology, IWAIT 2018*.

Li, Shuang et al. 2020. "Multi-Angle Head Pose Classification When Wearing the Mask for Face Recognition under the COVID-19 Coronavirus Epidemic." *2020 International Conference on High Performance Big Data and Intelligent Systems, HPBD and IS 2020*.

Militante, Sammy V., and Nanette V. Dionisio. 2020a. "Deep Learning Implementation of Facemask and Physical Distancing Detection with Alarm Systems." *Proceeding - 2020 3rd International Conference on Vocational Education and Electrical Engineering: Strengthening the framework of Society 5.0 through Innovations in Education, Electrical, Engineering and*

Informatics Engineering, ICVEE 2020.

- . 2020b. "Real-Time Facemask Recognition with Alarm System Using Deep Learning." *2020 11th IEEE Control and System Graduate Research Colloquium, ICSGRC 2020 - Proceedings* (August): 106–10.
- Mujib, Khusnil, Achmad Hidayatno, and Teguh Prakoso. 2018. "Pengenalan Wajah Menggunakan Local Binary Pattern (Lbp) Dan Support Vector Machine (Svm)." *Transient* 7(1): 123.
- Ojala, Timo, Matti Pietikäinen, and David Harwood. 1994. "Performance Evaluation of Texture Measures with Classification Based on Kullback Discrimination of Distributions." In *Proceedings - International Conference on Pattern Recognition*.
- Oumina, Abdellah, Nouredine El Makhfi, and Mustapha Hamdi. 2020. "Control the COVID-19 Pandemic: Face Mask Detection Using Transfer Learning." *2020 IEEE 2nd International Conference on Electronics, Control, Optimization and Computer Science, ICECOCS 2020*: 10–14.
- Pietikäinen, Matti, Abdenour Hadid, Guoying Zhao, and Timo Ahonen. 2011. "Computer Vision Using Local Binary Patterns."
- Qin, Bosheng, and Dongxiao Li. 2020. "Identifying Facemask-Wearing Condition Using Image Super-Resolution with Classification Network to Prevent COVID-19." *Sensors (Switzerland)* 20(18): 1–23.
- Rahim, Arham, Kusri Kusri, and Emha Taufiq Luthfi. 2020. "Convolutional Neural Network Untuk Kalasifikasi Penggunaan Masker." *Inspiration: Jurnal Teknologi Informasi dan Komunikasi* 10(2): 109.
- Septiana, Tri, Nadia Puspita, Mohamad Al Fikih, and Novendra Setyawan. 2020. "Face Mask Detection Covid-19 Using Convolutional Neural Network (Cnn).": 27–32.
- sinar Rizky A, Anita Trisiana, Farid Ajrur R, Lauriend Algileri M, Iqbal Syaibani, Septiana Nur. 2020. "Menumbuhkan Kesadaran Masyarakat Indonesia Untuk Memutus Rantai Penyebaran Wabah Covid-19." *Jurnal Global Citizen: : Jurnal Ilmiah Kajian Pendidikan Kewarganegaraan.*
- Zhang, Quan shi, and Song chun Zhu. 2018. "Visual Interpretability for Deep Learning: A Survey." *Frontiers of Information Technology and Electronic Engineering* 19(1).

PUSTAKA ELEKTRONIK

<https://www.who.int/health-topics/coronavirus> diakses 08 Juni 2021

<https://www.kaggle.com/shreyashwaghe/medical-mask-dataset> diakses 07 Maret 2021

<https://www.kaggle.com/datasets/ashishjangra27/face-mask-12k-images-dataset> diakses 07 Maret 2021

<https://humansinthe-loop.org/resources/datasets/medical-mask-dataset/> diakses 29 Desember 2021

