

BAB III

METODOLOGI PENELITIAN

3.1 Gambaran Umum Objek Penelitian

Penelitian ini berfokus kepada pendeteksian penggunaan masker pada wajah manusia dalam rangka membantu pengawasan terhadap persebaran virus COVID-19. COVID-19 (*Corona Virus Disease 2019*) sendiri adalah sebuah penyakit menular yang tersebar secara luas dan menjadi pandemi global bermula di kota Wuhan, China, pada bulan Desember 2019 [1]. Virus COVID-19 ini dapat menyebar melalui droplet yang terbuat dari batuk ataupun bersin yang dihasilkan dari manusia yang telah terinfeksi, dan yang dihirup oleh manusia lainnya.

Virus ini pun dapat hidup pada droplet yang dihasilkan oleh manusia hingga 8 jam. Hal tersebut membuat virus ini sangat mudah untuk menyebar. Dengan fakta tersebut, penggunaan masker dianjurkan dalam pencegahan penyebaran COVID-19 [3]. Penelitian ini menggunakan data RMFD (*Real-World Masked Face Dataset*) sebagai objek penelitiannya. Dataset tersebut berisikan data gambar dengan 2 klasifikasi, yaitu wajah yang menggunakan masker dan wajah yang tidak menggunakan masker [36].

3.2 Teknik Pengumpulan Data

Metode pengumpulan data yang digunakan adalah data sekunder. Hal tersebut dikarenakan dataset yang dijadikan objek penelitian ini didapat pada situs GitHub dengan nama RMFD (*Real-World Masked Face Dataset*) [36]. Dataset tersebut memiliki 2 klasifikasi dengan total data yaitu 4095, dengan komposisi masing-masing klasifikasi wajah manusia tanpa menggunakan masker dengan jumlah data 1930 dan wajah manusia yang menggunakan masker dengan jumlah data 2165 dengan *detail* seperti tabel 3.1. Pemilihan dataset tersebut juga dikarenakan pada penelitian sebelumnya, yaitu penelitian dengan judul “*Face Mask Detection by using Optimistic Convolutional Neural Network*” yang membicarakan mengenai penelitian

sebelumnya yang menggunakan *dataset* tersebut dan mendapatkan akurasi yang baik [9].

Table 3.1 Deskripsi Data Yang Digunakan

Klasifikasi data	Jumlah data	Deskripsi
<i>With_mask image</i>	2165.	Berisi gambar wajah manusia yang menggunakan masker dengan data sebanyak 2165 gambar.
<i>Without_mask image</i>	1930.	Berisi gambar wajah manusia tanpa menggunakan masker dengan data sebanyak 1930 gambar.
Total data	4095	


3.3 Teknik Pengambilan Sampel

Dilakukan juga *under-sampling* secara manual terhadap *dataset* tersebut dikarenakan ada beberapa data yang tidak relevan dalam penelitian ini, seperti penggunaan masker yang sangat tidak sesuai (misalnya pemakaian masker yang hanya menutupi dagu). *Under-sampling* sendiri adalah teknik pengurangan jumlah data untuk mengatasi terjadinya ketidakseimbangan jumlah data [37]. Teknik tersebut dipilih karena teknik *under-sampling* sesuai dengan kebutuhan penelitian, yang dimana penelitian ini mendapatkan dataset sebanyak 2165 data gambar dalam klasifikasi wajah yang menggunakan masker dan menjadi 1930 data yang dikarenakan

ketidaksesuaian terhadap kebutuhan penelitian, juga untuk menyeimbangkan kedua data klasifikasi, Pada data dengan klasifikasi wajah yang tidak menggunakan masker juga menjadi 1930 data untuk mengatasi ketidakseimbangan jumlah data dari masing-masing klasifikasi data yang digunakan.

3.4 Metode Penelitian

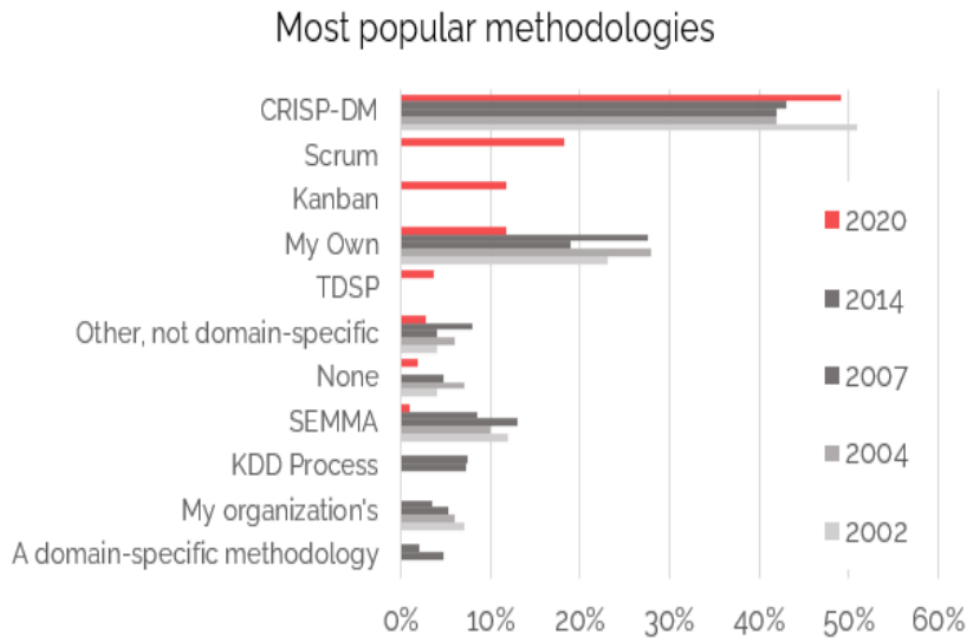
Metode penelitian ini menggunakan salah satu teknik data mining, yaitu CRISP-DM (*Cross Industry Standard Process for Data Mining*) yang menggunakan 6 siklus dalam proyek *data mining*, yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment* [17], yang tergambar pada gambar 3.1 mengenai siklus *framework* tersebut.



Gambar 3.1 CRISP-DM [18]

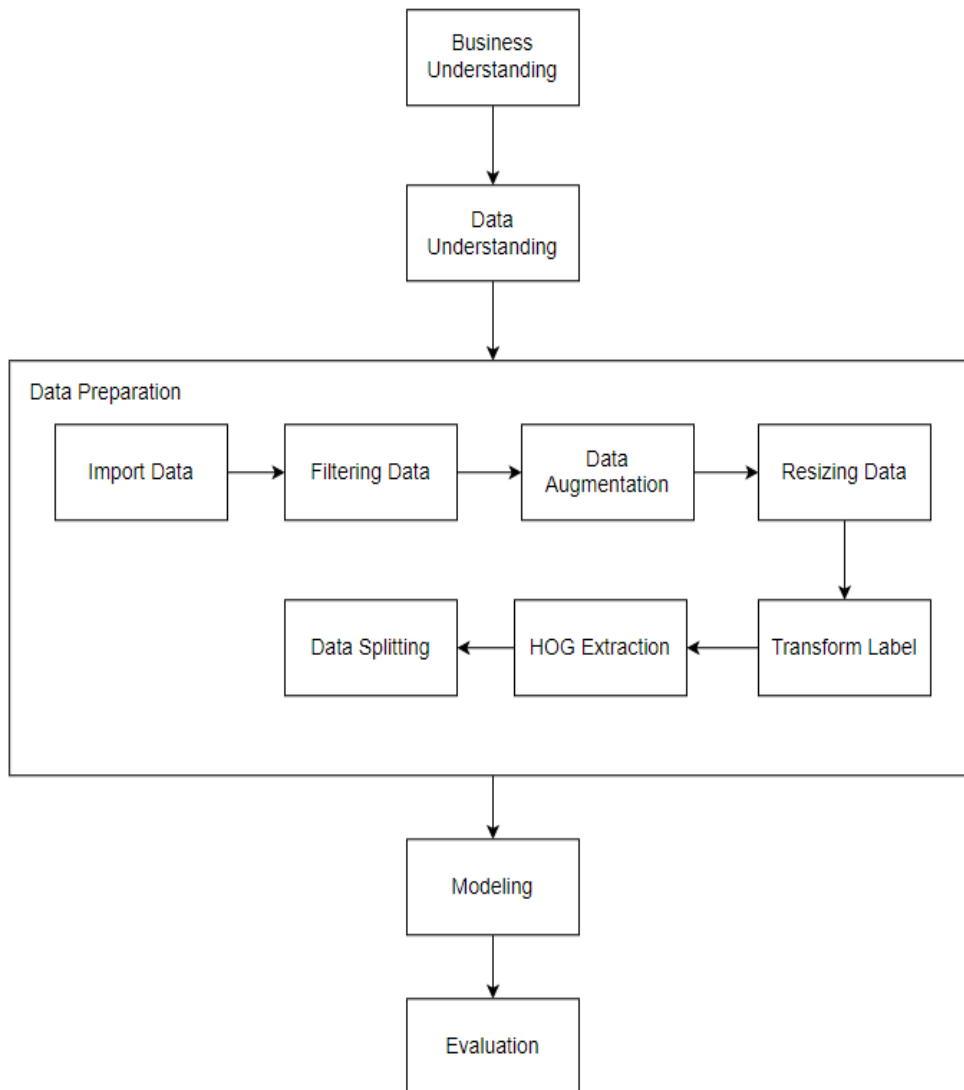
Pemilihan kerangka kerja CRISP-DM dikarenakan kerangka kerja tersebut merupakan kerangka kerja yang banyak digunakan dan melakukan penganalisisan terhadap proyek *data science* [38]. Hal tersebut dapat dilihat pada grafik di gambar 3.2 yang menjelaskan tingkat kepopuleran dari

kerangka kerja yang digunakan dalam penelitian-penelitian pada tiap periodenya mengenai penelitian yang bertemakan *data science*.



Gambar 3.2 Kerangka kerja terpopuler [38].

Kelebihan dari kerangka kerja CRISP-DM sendiri merupakan kerangka kerja yang memiliki beberapa tahapan yang dapat berulang (*iterative*) sesuai dengan tujuan dari penelitian atau *business understanding*, kerangka kerja yang ringkas dan juga efisien untuk digunakan dalam sebagian besar penelitian [38]. Kerangka kerja yang dilakukan dalam penelitian ini dapat dilihat seperti alur pada gambar 3.3, yaitu kerangka kerja yang berdasarkan pada kerangka kerja CRISP-DM.



Gambar 3.3 Alur penelitian CRISP-DM yang dilakukan

3.4.1 Business Understanding

Pada tahap awal yaitu Business Understanding, berguna untuk mengidentifikasi dan menentukan target serta tujuan dari penelitian yang ingin dilakukan [18]. Dalam penelitian ini, tujuan utamanya adalah pendeteksian penggunaan masker pada wajah manusia, yang memiliki 2 klasifikasi. Kedua klasifikasi tersebut adalah wajah manusia yang menggunakan masker dan wajah manusia tanpa atau tidak menggunakan

masker. Pengklasifikasian pada penelitian ini akan menggunakan metode *backpropagation*.


3.4.2 Data Understanding

Pada tahap kedua ini, terjadi proses pengumpulan data, pemahaman data, dan penganalisisan data [18]. Penelitian ini menggunakan data yang bernama “*Real World Masked Face (RMFD dataset)*” [36]. Data tersebut berasal dari GitHub (<https://github.com/X-zhangyang/Real-World-Masked-Face-Dataset>) yang berisi foto wajah manusia yang menggunakan masker seperti surgical mask, mask KN-95, dan lainnya, serta data tersebut berisi foto wajah manusia tanpa masker yang dibedakan kedalam 2 klasifikasi dengan nama *folder with_mask* dan *without_mask*.

Pemilihan dataset tersebut juga dikarenakan pada penelitian sebelumnya, yaitu penelitian dengan judul “*Face Mask Detection by using Optimistic Convolutional Neural Network*” yang membicarakan mengenai penelitian sebelumnya yang menggunakan *dataset* tersebut dan mendapatkan akurasi yang baik [9].



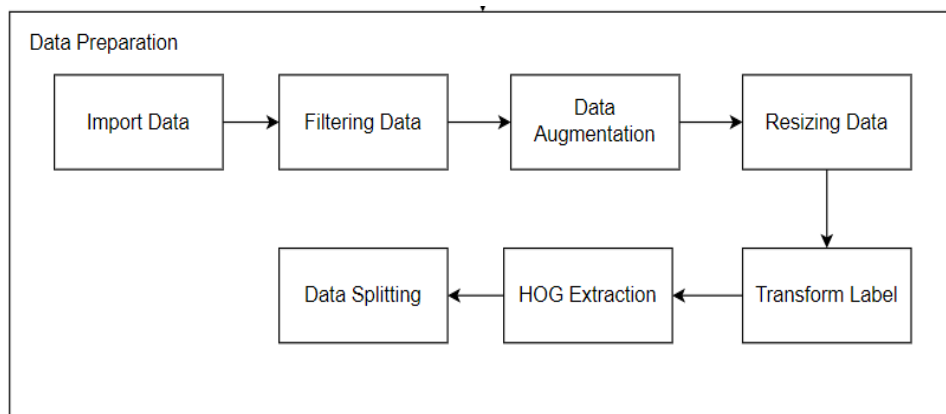
Gambar 3.4 Contoh gambar wajah manusia yang menggunakan masker [36]



Gambar 3.5 Contoh gambar wajah manusia yang tidak menggunakan masker [36]

3.4.3 Data Preparation

Data dari tahap sebelumnya akan diproses lagi agar data tersebut sesuai dan siap untuk diteliti seperti pada gambar 3.6.



Gambar 3.6 Data Preparation

Data RMFD tersebut akan dibagi menjadi 3, yaitu data untuk *training model*, *test model*, dan *validation model* dengan porsi 10% untuk *validation model*, 10% untuk *test model*, 80% untuk *training model*. Sebelum data dibagi kedalam 3 bagian tersebut, dataset yang telah

didapat, akan diimport terlebih dahulu kedalam tools yang digunakan dalam penelitian ini, yaitu *Google Colab* melalui *Google Drive*.

Setelah data berhasil di *import*, selanjutnya data akan melalui proses *filtering* data gambar. Gambar yang diterima akan diperiksa berdasarkan tipe datanya beserta fiturnya. Tipe data yang digunakan dalam penelitian ini adalah tipe data “*jpg*”. Ketika data yang ditemukan dalam tahap *filtering* tersebut terdapat data yang bukan bertipe data “*jpg*”, maka data tersebut akan diubah menjadi data dengan tipe “*jpg*”, dan *filtering* yang dilakukan kedua kalinya ialah fitur dari gambar itu sendiri. Fitur yang diterima hanya gambar yang memiliki fitur “RGB”. Hal tersebut dikarenakan *library* yang digunakan tidak dapat memproses data yang selain fitur data diatas. Maka jika ditemukan data yang memiliki fitur selain “RGB”, maka data tersebut akan dihapus.



Gambar 3.7 Augmentor [39]

Data dari hasil *filtering* akan langsung dilanjutkan ke tahap berikutnya lagi, yaitu tahap *augmentation data*. Tahap ini menggunakan *library augmentor*. *Augmentor* sendiri adalah sebuah *package* pada *python* yang bertujuan untuk mengaugmentasi data dan menghasilkan gambar-gambar buatan atau *artificial* untuk tugas-tugas dari pembelajaran mesin atau *machine learning* [39]. Tahap ini akan dilakukan untuk memperbanyak *dataset* yang ada hingga berjumlah 10000 data gambar (tiap label atau klasifikasi data memiliki 5000 data gambar). *Augmentation* yang dilakukan adalah *flipping* gambar dari

bawah ke atas, dari samping kiri ke kanan, serta rotasi gambar secara 90 derajat, 180 derajat, dan 270 derajat secara acak. Dalam *library augmentator*, rotasi gambar yang disediakan fiturnya hanya 3, yaitu 90 derajat, 180 derajat, dan 270 derajat [39].

Menurut Connor Shorten pada jurnalnya yang berjudul “*A survey on Image Data Augmentation for Deep Learning*” [40], augmentasi dengan *flipping image*, *rotating image*, dan *random cropping* sudah terbukti dampaknya terhadap pembuatan model pembelajaran mesin atau *machine learning*. Namun dalam kasus augmentasi data yang menggunakan augmentasi gambar yang lain seperti misalnya *patchshuffle* yang dapat mengubah pixel data gambar yang menyebabkan ketidakjelasan pada data gambar dengan contoh seperti pada gambar 3.8, *samplepairing* yang menggabungkan 2 gambar menjadi 1 yang menjadikan gambar menjadi berbayang terhadap kedua gambar dengan contoh seperti pada gambar 3.9, bahkan *color augmentation* yang mengubah warna dari data gambar yang ada seperti contoh pada gambar 3.10, belum terbukti berpengaruh secara positif terhadap pembelajaran mesin. Hal tersebut dikarenakan dapat menyebabkan bias terhadap karakteristik asli dari data *image* yang digunakan sebagai objek dari penelitian [40].






Gambar 3.8 PatchShuffling [41]



Gambar 3.9 SamplePairing [42]

U M U L T I M E D I A N U S A N T A R A A S



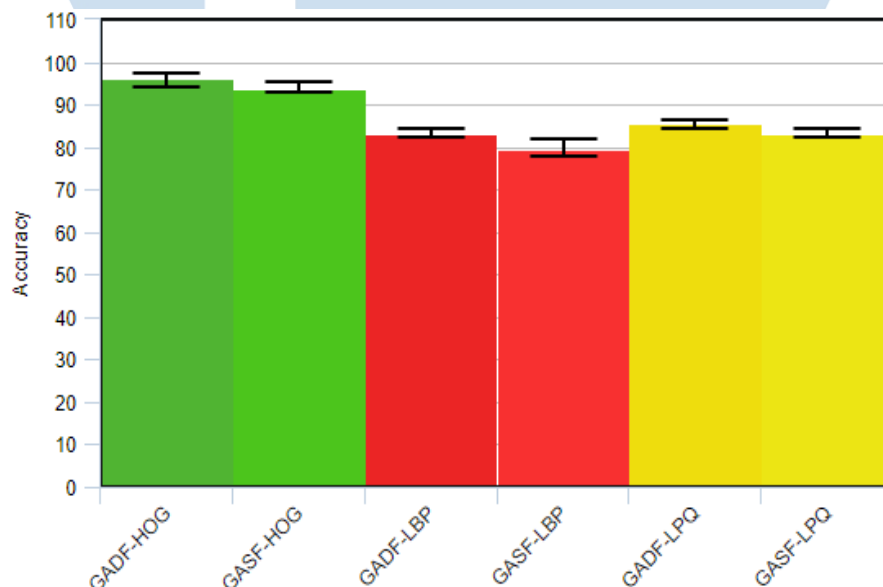
Gambar 3.10 Contoh untuk *Color Augmentation* [43]

Data dari hasil augmentasi akan berlanjut kepada proses *resizing* dengan ukuran 320x240 pixel, serta mengubah data tersebut ke dalam bentuk array. Hal tersebut sesuai dengan penelitian yang menjadi acuan pada penelitian ini, yaitu penelitian “*Detection of Fire With Image Processing Using Backpropagation Method*” yang berguna untuk memudahkan pembelajaran mesin dalam pembuatan model pendeteksian ini [10].

Mengubah label atau *transform* label juga dilakukan berdasarkan dari klasifikasi data yang digunakan. Data yang digunakan memiliki 2 klasifikasi, yaitu wajah manusia yang menggunakan masker dan wajah manusia tanpa menggunakan masker. Perubahan label tersebut menggunakan *LabelBinarizer* dari *library sklearn* dari label *multiclass* menjadi label dengan bentuk *binary* [30].

HOG extraction akan dilakukan pada data gambar yang telah berhasil diubah menjadi array. *HOG extraction* adalah sebuah *descriptor* dari elemen-elemen yang terdapat pada gambar atau foto dengan memisahkan elemen-elemen yang penting pada data (yang menjadi tujuan utama) dan membuang elemen-elemen yang tidak penting pada gambar yang diteliti. Biasanya *HOG extraction* digunakan untuk memproses data gambar yang akan dilakukan pengidentifikasian terkait dengan hal yang ingin diteliti [44].

Tiap elemen dari gambar akan diberi nilai berdasarkan hasil dari ekstraksi pada HOG. Nilai yang didapat dalam bentuk histogram yang berisi mengenai berbagai hal mengenai gambar, seperti garis, kontur dari objek, dan bentuk dari objek, berdasarkan dari area yang telah ditentukan pada tiap *cell* [19]. Penggunaan HOG *extraction* juga terbukti mendapatkan akurasi yang baik dibandingkan dengan *extraction* lainnya, seperti LBP (*Local Binary Pattern*) dan LPQ (*Local Phase Quantization*) [45]. Ketiga *extractor* tersebut biasanya digunakan dalam bidang pengklasifikasian gambar. Hal tersebut dapat dilihat pada gambar 3.11 yang membandingkan *extraction* HOG, LBP, dan LPQ. Dengan hasil bahwa HOG *extraction* mendapatkan akurasi tertinggi dibandingkan dengan yang lainnya.



Gambar 3.11 Perbandingan akurasi HOG, LBP, dan LPQ *extraction* [45]

Tahap terakhir dalam *data preparation* ialah *splitting* data yang akan membagi data menjadi 3 bagian, yaitu data *training*, data *testing*, dan data *validation*. Pembagian yang dilakukan terhadap keseluruhan data adalah 10% untuk data *testing*, 10% untuk data *validation*, dan 80% untuk data *training* untuk model yang akan dibangun.

3.4.4 Modeling

Setelah data telah siap, maka akan dilanjutkan ke tahap *modeling*. Pembangunan model akan berdasarkan data yang telah diproses pada tahap sebelumnya dengan tujuan untuk menjawab *business understanding* dari penelitian ini. Penelitian ini akan menggunakan metode *backpropagation neural network* dalam permodelannya untuk membangun model pendeteksian penggunaan masker pada wajah manusia yang dibangun menggunakan data hasil dari tahap sebelumnya yaitu data *training*, data *testing*, dan data *validation*. Proses permodelan tersebut akan menggunakan *tools google colab* yang menggunakan Bahasa pemrograman *Python*.

Table 3.2 Komparasi penelitian sebelumnya

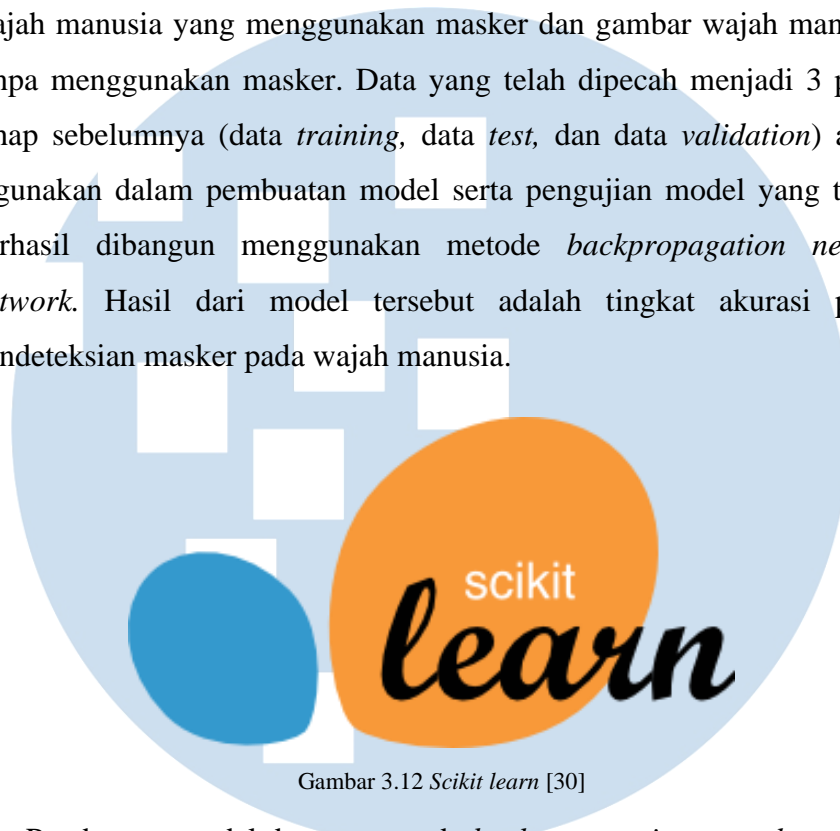
Jurnal	Akurasi yang dihasilkan (%)			
	PCA	DNN	CNN	Backpropagation
Implementation of Principal Component Analysis on Masked and Non-masked Face Recognition [46]	72			
SSDMNV2: A real time DNN-based face mask detection system using single shot multibox detector and MobileNetV2 [8]		93		
Covid-19 Face Mask Detection Using TensorFlow, Keras and OpenCV [47]			94.58	
Face Mask Detection by using Optimistic Convolutional Neural Network [9]			98	

Jurnal	Akurasi yang dihasilkan (%)			
	PCA	DNN	CNN	<i>Backpropagation</i>
Novel Face Mask Detection Technique using Machine Learning to control COVID'19 pandemic [48]				98.39

Pemilihan metode *backpropagation neural network* memiliki alasan tersendiri, yaitu karena metode tersebut dapat menghasilkan akurasi yang tinggi, yaitu diatas 90% pada penelitian “*Detection of Fire With Image Processing Using Backpropagation Method*” [10], serta metode *backpropagation neural network* juga dapat mengungguli performa dari algoritma PCA (*Principal Component Analysis*), DNN (*Deep Neural Network*), dan CNN (*Convolutional Neural Network*) seperti pada table 3.2. Adapun perbedaan penelitian penelitian ini adalah penggunaan augmentasi data serta HOG *extraction* pada data penelitian dengan data RMFD dan juga perbedaan objek penelitian, yang dimana penelitian ini menggunakan objek wajah manusia yang menggunakan masker dan wajah manusia yang tidak menggunakan masker, sedangkan penelitian “*Detection of Fire With Image Processing Using Backpropagation Method*” tersebut menggunakan objek penelitian foto atau gambar api. Perbedaan dengan penelitian yang berjudul “*Novel Face Mask Detection Technique using Machine Learning to control COVID'19 pandemic*” sendiri adalah tidak melakukan HOG *extraction*, tidak melakukan augmentasi data, serta menggunakan 2 *dataset*, yaitu dataset RMFD dan *dataset celebrities*.

Mulanya data yang telah ada, yaitu data foto manusia yang menggunakan masker dan data foto manusia yang tidak menggunakan masker akan di *import* ke *google colab*. Data tersebut kemudian akan diklasifikasikan menjadi 2 klasifikasi sesuai dengan klasifikasi yang

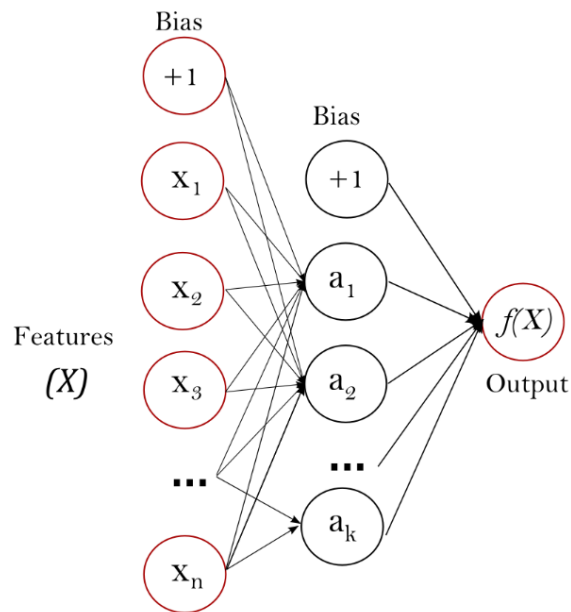
diberi penamaan pada *folder* data masing-masing gambar yaitu gambar wajah manusia yang menggunakan masker dan gambar wajah manusia tanpa menggunakan masker. Data yang telah dipecah menjadi 3 pada tahap sebelumnya (data *training*, data *test*, dan data *validation*) akan digunakan dalam pembuatan model serta pengujian model yang telah berhasil dibangun menggunakan metode *backpropagation neural network*. Hasil dari model tersebut adalah tingkat akurasi pada pendeteksian masker pada wajah manusia.



Gambar 3.12 Scikit learn [30]

Pembuatan model dengan metode *backpropagation neural network* akan menggunakan *MLPClassifier* atau *Multi-layer Perceptron Classifier* yang berasal dari *library scikit learn*. *MLPClassifier* sendiri merupakan *supervised learning* yang memiliki 1 *hidden layer* atau bahkan lebih dengan *link* atau *neuron* yang bertumpuk yang berasal dari *input* yang diterima, seperti pada gambar 3.13. Model yang dibuat menggunakan *MLPClassifier* akan dioptimasi lagi dengan menggunakan *log-loss function* yang didapat pada pembuatan model pertama kali [30]. *Log-loss function* sendiri merupakan seberapa dekat hasil probabilitas dari prediksi yang dibuat dengan data yang sebenarnya atau *actual data* [49].

U N I V E R S I T A S
M U L T I M E D I A
N U S A N T A R A



Gambar 3.13 *MLPClassifier one hidden layer* [30]

Dengan kata lain, model dari *MLPClassifier* akan memanfaatkan *Log-loss function* untuk mengecilkan tingkat error yang terjadi atau MSE (*Mean Squared Error*) yang diharapkan dapat membantu meningkatkan hasil prediksi secara benar yang dihasilkan dari model tersebut. Pengoptimasian model akan menggunakan *solver adam*. Hal tersebut dikarenakan *solver adam* akan sangat bagus untuk dataset yang besar seperti misalnya ribuan data *training* [30].

3.4.5 Evaluation

Di tahap kelima ini, hasil dari model tersebut akan dinilai dan dievaluasi. Hal ini berguna untuk menjadi tolak ukur, apakah model yang telah dihasilkan sudah sesuai dengan tujuan awal atau *business understanding* dari penelitian ini dengan hasil outputnya. Evaluasi dari penelitian ini sendiri adalah tingkat akurasi dari hasil pendeteksian masker pada wajah manusia. Berdasarkan tujuan penelitian ini, yang menjadi kunci dari penyelesaian masalahnya adalah apakah model ini dapat mendeteksi wajah yang menggunakan masker, dan wajah manusia yang tidak menggunakan masker.

Penelitian lain juga yang meneliti objek yang sama dengan hasil yang paparkan yaitu tingkat akurasi dari penelitian sebelumnya, dengan menggunakan algoritma yang berbeda dengan penelitian ini, yaitu algoritma DNN (*Deep Neural Network*) dan *Optimistic CNN* (*Convolutional Neural Network*) yang mendapatkan akurasi masing-masing sebesar 93% dan 98% [9], [12]. Percobaan model yang dibangun juga akan dilakukan dengan cara menggunakan foto sampel dengan ketentuan masing-masing sampel uji coba memiliki tipe 2 foto, yaitu foto manusia menggunakan masker dan foto manusia tanpa menggunakan masker.

3.4.6 Deployment

Penelitian ini tidak sampai pada tahap deployment. Hal tersebut dikarenakan penelitian ini hanya berfokus kepada perbandingan tingkat akurasi dari penelitian sebelumnya.

