



**CONVOLUTIONAL NEURAL NETWORK UNTUK  
KLASIFIKASI PENYAKIT DAUN TEH (*Camellia Sinensis*)**

**TESIS**

Oleh :

**Eliana Aida Rosyidah  
NIM 211820101002**

**KEMENTERIAN PENDIDIKAN, KEBUDAYAAN, RISET DAN TEKNOLOGI  
UNIVERSITAS JEMBER  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
MAGISTER MATEMATIKA  
JEMBER  
2023**



**CONVOLUTIONAL NEURAL NETWORK UNTUK  
KLASIFIKASI PENYAKIT DAUN TEH (*Camellia Sinensis*)**

**TESIS**

Oleh :

**Eliana Aida Rosyidah  
NIM 211820101002**

**KEMENTERIAN PENDIDIKAN, KEBUDAYAAN, RISET DAN TEKNOLOGI  
UNIVERSITAS JEMBER  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
MAGISTER MATEMATIKA  
JEMBER  
2023**



**CONVOLUTIONAL NEURAL NETWORK UNTUK  
KLASIFIKASI PENYAKIT DAUN TEH (*Camellia Sinensis*)**

diajukan untuk memenuhi sebagian persyaratan memperoleh gelar Magister pada  
Program Studi Magister Matematika (S2)

**TESIS**

Oleh :

**Eliana Aida Rosyidah  
NIM 211820101002**

**KEMENTERIAN PENDIDIKAN, KEBUDAYAAN, RISET DAN TEKNOLOGI  
UNIVERSITAS JEMBER  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
MAGISTER MATEMATIKA  
JEMBER  
2023**

### PERSEMBAHAN

Penulis panjatkan syukur kehadirat Allah yang Maha Pengasih dan Maha Penyayang serta sholawat dan salam selalu tercurahkan kepada Nabi Muhammad SAW, penulis persembahkan tesis ini kepada:

1. Mama Lilik Irianingsih dan Ayah Rusdianto serta seluruh keluarga yang selalu mendukung, memberikan doa, kasih sayang dan motivasi yang tiada henti.
2. Seluruh jajaran guru TK Al-Hidayah IV, Madrasah Ibtidaiyah Maarif Condro, SMPN 6 Jember, SMAN 2 Jember dan IAIN Jember yang telah memberikan banyak ilmu kepada penulis.
3. Sahabat dan teman-teman seperjuangan terkhusus M.D.S yang selama ini mendukung penulis sehingga tugas akhir ini bisa terselesaikan.
4. Semua pihak yang membantu penulis dalam menyelesaikan tugas akhir.

**MOTTO**

Sesungguhnya Allah tidak akan mengubah keadaan suatu kaum, sebelum mereka mengubah keadaan diri mereka sendiri. (Q.S Ar-Rad:11)



**PERNYATAAN ORISINALITAS**

Saya yang bertanda tangan di bawah ini :

Nama : Eliana Aida Rosyidah

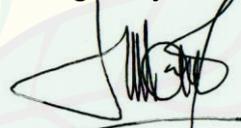
NIM : 211820101002

Menyatakan dengan sesungguhnya bahwa tugas akhir yang berjudul : *Convolutional Neural Network (CNN) untuk Klasifikasi Penyakit Daun Teh (Camellia Sinensis)* adalah benar-benar hasil karya sendiri, kecuali jika dalam pengutipan substansi disebutkan sumbernya, dan belum pernah diajukan pada instansi manapun, serta bukan karya jiplakan. Saya bertanggung jawab atas keabsahan dan kebenaran isinya sesuai dengan tulisan ilmiah yang harus dijunjung tinggi.

Demikian pernyataan ini saya buat dengan sebenarnya, tanpa adanya tekanan dan paksaan dari pihak manapun serta bersedia mendapat sanksi akademik jika ternyata di kemudian hari pernyataan ini tidak benar.

Jember, 21 Juni 2023

Yang menyatakan,



Eliana Aida Rosyidah

NIM. 211820101002

**HALAMAN PERSETUJUAN**

Tesis berjudul *Convolutional Neural Network (CNN) untuk Klasifikasi Penyakit Daun Teh (Camellia Sinensis)* telah diuji dan di sahkan oleh Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Jember pada :

Hari : Rabu  
Tanggal : 12 Juli 2023  
Tempat : R. Sidang/Lt1/E

Pembimbing Tanda Tangan

1. Pembimbing Utama

Nama : Dr. Alfian Futuhul Hadi, S.Si., M.Si ( )

NIP : 197407192000121001

2. Pembimbing Anggota

Nama : Dr. Yuliani Setia Dewi, S. Si., M.Si ( )

NIP : 197407162000032001

Penguji

1. Penguji Utama

Nama : Prof. Drs. I Made Tirta, M.Sc., Ph.D ( )

NIP : 195912201985031002

2. Penguji Anggota

Nama : Dr. Kiswara Agung Santoso, S.Si., M.Kom ( )

NIP : 197209071998031003

**ABSTRACT**

*Developments in Computer Vision have driven advancements in addressing various problems in economics, healthcare, and agriculture. One of the major contributors is Deep Learning. Deep Learning is a subfield of machine learning that develops algorithms and computational models that focus on learning by complex artificial neural networks with many layers (deep neural networks). One type of algorithm used in Deep Learning is Convolutional Neural Network (CNN). This research explores the ability of CNN to recognize and classify various types of diseases in tea leaves. The architecture used is darknet19 with adam optimizer and the use of 150 epochs, batch size 50, and learning rate  $10^{-4}$ . The dataset used consists of 400 data divided into 4 balance classes, namely Algal Leaf, Anthracnose, Bird Eye Spot, and Healthy. In this study, three types of classification testing were carried out, namely binary classification, multiclass classification with balance data, and multiclass classification with imbalance data. The results of binary classification testing show excellent accuracy, precision, recall, and specificity values, which are 100%. Multiclass classification testing with balance data achieved 95% accuracy with 100% recall for Algal Leaf and Healthy leaves, and 83% recall for Anthracnose leaves, and 96% recall for Bird Eye Spot leaves. Multiclass classification testing with imbalance data achieved 85% accuracy with 97% recall for Algal Leaf leaves and 100% for Healthy leaves, 60% recall for Anthracnose leaves, and 96% recall for Bird Eye Spot leaves. The evaluation results show that the CNN model is able to classify tea leaf diseases with a high level of accuracy. This gives the potential use of this model in supporting a real-time tea plant disease surveillance system.*

*Keywords: Tea Leaf Diseases, Binary Classification, Multiclass Classification, Convolutional Neural Networks, Imbalance Data*

## RINGKASAN

***Convolutional Neural Network (CNN) untuk Klasifikasi Penyakit Daun Teh (Camellia Sinensis)***; Eliana Aida Rosyidah; 211820101002; 2023; 43 halaman; Magister Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Jember.

Perkembangan teknologi mampu mempermudah pekerjaan seseorang. *Deep learning* merupakan salah satu kemajuan teknologi yang berguna bagi dunia pertanian yang mampu mengklasifikasi jenis penyakit pada tanaman. Menurut data statistik tahun 2020, Indonesia merupakan penghasil teh terbesar nomor 7 di dunia. Akan tetapi jumlah panen teh dipengaruhi oleh penyakit tanaman. *Deep learning* merupakan solusi untuk penanganan awal dalam menurunkan tingkat kegagalan panen dengan mengklasifikasi jenis penyakit daun teh.

Penelitian ini menggunakan algoritma *Convolutional Neural Network (CNN)* untuk mengklasifikasi jenis penyakit daun teh. Klasifikasi yang digunakan terdiri dari tiga jenis yaitu *Binary Classification*, *Multiclass Classification of Balance Data* dan *Multiclass Classification of Imbalance Data*. Data yang digunakan adalah gambar penyakit daun teh yang terdiri dari *Algal Leaf*, *Antracnose*, *Bird Eye Spot* dan daun *Healthy* berukuran 256x256 piksel.

Analisis dari metode yang digunakan menunjukkan bahwa algoritma CNN mampu melakukan klasifikasi terhadap penyakit daun teh dibuktikan dengan *accuracy*, *precision*, *recall* dan *specificity*. Tahap *binary classification* membagi data menjadi 70% sebagai data latih dan 30% sebagai data uji. Peneliti menggunakan 70 gambar data latih dan 30 gambar data uji dengan membandingkan antara *Healthy* dan *Algal Leaf*, *Healthy* dan *Antracnose*, *Healthy* dan *Bird Eye Spot*. Hasil *accuracy*, *precison*, *recall* dan *specificity* pada *binary classification* adalah 100%. Selanjutnya algoritma diuji menggunakan *multiclass classification* menggunakan data seimbang dengan perbandingan 70% : 30%.

Hasil dari *multiclass classification of balance data* adalah model dapat mengklasifikasi dengan benar sebesar 95% dan sisanya sebesar 5% model tidak dapat memprediksi dengan tepat. Rekayasa terakhir yang digunakan adalah menggunakan data tidak seimbang (*imbalance*). Data rekayasa pada pelatihan terdiri dari 80 gambar untuk kelas *Healthy*, 55 gambar untuk kelas *Antracnose*, 60 gambar untuk kelas *Algal\_Leaf* dan terakhir sebanyak 70 gambar untuk kelas *Bird\_Eye\_Spot*. Klasifikasi untuk data tidak seimbang, model hanya dapat memprediksi dengan benar sebesar 85% dan sisanya sebesar 15% model tidak dapat diprediksi dengan tepat.



## PRAKATA

Puji syukur kehadiran Allah SWT atas segala rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan tugas akhir dengan judul *Convolutional Neural Network (CNN) untuk Klasifikasi Penyakit Daun Teh (Camellia Sinensis)*. Tugas akhir ini disusun untuk memenuhi salah satu syarat untuk menyelesaikan pendidikan magister (S2) pada Program Studi Magister Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Jember.

Penyusunan tugas akhir ini tidak lepas dari bantuan dari berbagai pihak. Oleh karena itu, penulis menyampaikan terimakasih kepada :

1. Dr. Alfian Futuhul Hadi, S.Si., M.Si selaku Dosen Pembimbing Utama dan Dr. Yuliani Setia Dewi, S.Si.,M.Si selaku Dosen Pembimbing Anggota yang telah meluangkan waktu, pikiran dan perhatian dalam penulian tugas akhir ini.
2. Prof. Drs. I Made Tirta, M.Sc., Ph.D., selaku Dosen Penguji I dan Dr. Kiswara Agung Santoso, S.Si., M.Kom selaku Dosen Penguji II yang telah memberikan kritik dan saran yang membangun dalam penyempurnaan tugas akhir.
3. Dosen dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Jember.
4. Keluarga yang telah memberikan semangat dan doa tulus ikhlas.
5. Teman-teman dan semua pihak yang telah membantu

Semoga bantuan, bimbingan dan dorongan yang telah diberikan dicatat sebagai amal baik oleh Allah SWT. Penulis juga menerima kritik dan saran dari semua pihak demi kesempurnaan tugas akhir. Penulis berharap semoga tugas akhir ini dapat bermanfaat.

Jember, 04 Juli 2023

Penulis

DAFTAR ISI

HALAMAN JUDUL .....	i
PERSEMBAHAN.....	ii
MOTTO .....	iii
PERNYATAAN ORISINALITAS.....	iv
HALAMAN PERSETUJUAN .....	v
<i>ABSTRACT</i> .....	vi
RINGKASAN .....	vii
PRAKATA.....	ix
DAFTAR ISI.....	x
DAFTAR TABEL .....	xii
DAFTAR GAMBAR.....	xiii
DAFTAR LAMPIRAN .....	xv
<b>BAB 1. PENDAHULUAN</b> .....	1
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	2
1.3 Tujuan .....	3
1.4 Manfaat .....	3
<b>BAB 2. TINJAUAN PUSTAKA</b> .....	4
2.1 Tanaman Teh.....	4
2.1.1 Penyakit Daun Teh <i>Algal Leaf</i> .....	4
2.1.2 Penyakit Daun Teh <i>Antracnose</i> .....	4
2.1.3 Penyakit Daun Teh <i>Bird Eye Spot</i> .....	5
2.1.4 Daun Teh Sehat.....	5
2.2 Citra Digital.....	6
2.3 <i>Deep Learning</i> .....	6
2.4 <i>Convolutional Neural Network (CNN)</i> .....	7
2.4.1 <i>Convolution Layer</i> .....	8

2.4.2	Fungsi Aktivasi .....	9
2.4.3	<i>Pooling Layer</i> .....	10
2.4.4	<i>Flatten</i> .....	11
2.4.5	<i>Fully Connected Layer</i> .....	11
2.4.6	<i>Darknet-19</i> .....	11
2.4.7	<i>Confusion Matrix</i> .....	12
<b>BAB 3.</b>	<b>METODOLOGI PENELITIAN</b> .....	14
3.1	Data Penelitian .....	14
3.2	Algoritma <i>Convolutional Neural Network</i> .....	14
3.3	Tahapan Penelitian.....	16
3.4	MATLAB Toolbox untuk CNN.....	19
<b>BAB 4.</b>	<b>HASIL DAN PEMBAHASAN</b> .....	20
4.1	<i>Image Preprocessing</i> .....	20
4.2	Hasil Pemrosesan CNN.....	22
4.3	Pemodelan Klasifikasi Menggunakan CNN .....	25
4.3.1	<i>Binary Classification of Imbalance Data</i> .....	25
4.3.2	<i>Binary Classification of Balance Data</i> .....	26
4.3.3	<i>Multiclass Classification of Balance Data</i> .....	30
4.3.4	<i>Multiclass Classification of Imbalance Data</i> .....	34
4.3.5	Analisis Hasil .....	37
<b>BAB 5.</b>	<b>KESIMPULAN DAN SARAN</b> .....	39
5.1	Kesimpulan .....	39
5.2	Saran.....	39
<b>DAFTAR PUSTAKA</b>	.....	<b>41</b>
<b>LAMPIRAN</b>	.....	<b>44</b>

**DAFTAR TABEL**

Tabel 2.1 Tabel <i>confusion matrix</i> .....	12
Tabel 3.1 Data penyakit daun teh.....	14
Tabel 4.1 Nilai-nilai piksel data gambar penyakit daun teh.....	20
Tabel 4.2 Skenario Data pada <i>Binary Classification</i> .....	21
Tabel 4.3 Skenario Data pada <i>Multiclass Classification</i> .....	21
Tabel 4.4 Nilai evaluasi model CNN <i>binary classification</i> pada proses <i>testing</i> ...	27
Tabel 4.5 <i>Confusion matrix</i> algoritma CNN pada <i>training data</i> .....	28
Tabel 4.6 <i>Confusion matrix</i> algoritma CNN pada <i>testing data</i> .....	29
Tabel 4.7 Nilai evaluasi model CNN <i>binary class</i> pada proses <i>training</i> .....	30
Tabel 4.8 Nilai evaluasi model CNN <i>binary class</i> pada proses <i>testing</i> .....	30
Tabel 4.9 Tabel <i>Confusion matrix multiclass classification</i> .....	32
Tabel 4.10 Nilai <i>accuracy, precision, recall, dan specificity</i> .....	32
Tabel 4.11 Tabel <i>Confusion matrix multiclass imbalance data</i> .....	35
Tabel 4.12 Nilai <i>accuracy, precision, recall dan specificity</i> .....	35

**DAFTAR GAMBAR**

Gambar 2.1 Penyakit Daun Teh <i>Algal Leaf</i> .....	4
Gambar 2.2 Penyakit Daun Teh <i>Antracnose</i> .....	5
Gambar 2.3 Penyakit Daun Teh <i>Bird Eye Spot</i> .....	5
Gambar 2.4 Daun Teh <i>Healthy</i> .....	5
Gambar 2.5 Contoh struktur pemodelan jaringan pada <i>Deep Learning</i> .....	6
Gambar 2.6 Lapisan Layer pada Jaringan <i>Deep Learning</i> .....	7
Gambar 2.7 Layer pada algoritma CNN .....	7
Gambar 2.8 Operasi <i>Convolution</i> .....	8
Gambar 2.9 Operasi <i>max pooling</i> .....	10
Gambar 2.10 Operasi <i>average pooling</i> .....	10
Gambar 3.1 Contoh gambar penyakit daun teh .....	14
Gambar 3.2 Diagram alur di dalam algoritma CNN .....	15
Gambar 3.3 Diagram alur <i>pre processing</i> .....	17
Gambar 3.4 Tahapan Penelitian .....	19
Gambar 4.1 Contoh Ekstraksi Piksel Citra .....	21
Gambar 4.2 Hasil Operasi <i>Zeropadding</i> .....	22
Gambar 4.3 Hasil Operasi <i>Convolution</i> .....	22
Gambar 4.4 Hasil Operasi <i>Convolution Rectified Linear Unit (ReLU)</i> .....	23
Gambar 4.5 Hasil Operasi <i>Pooling Layer</i> .....	23
Gambar 4.6 Hasil Operasi <i>Flatten</i> .....	23
Gambar 4.7 Hasil <i>Softmax</i> dengan <i>Output</i> yang Sesuai dengan Prediksi .....	24
Gambar 4.8 Hasil <i>Softmax</i> dengan <i>Output</i> yang Tidak Sesuai dengan Prediksi .....	24
Gambar 4.9 <i>Confusion matrix binary classification</i> (a) <i>training imbalance data</i> (b) <i>testing imbalance data</i> .....	26
Gambar 4.10 <i>Confusion matrix binary classification</i> (a) <i>training balance data</i> (b) <i>testing balance data</i> .....	27

Gambar 4.11 *Confusion matrix Multiclass Classification of Balance Data*  
(a) *training* (b) *testing*.....28

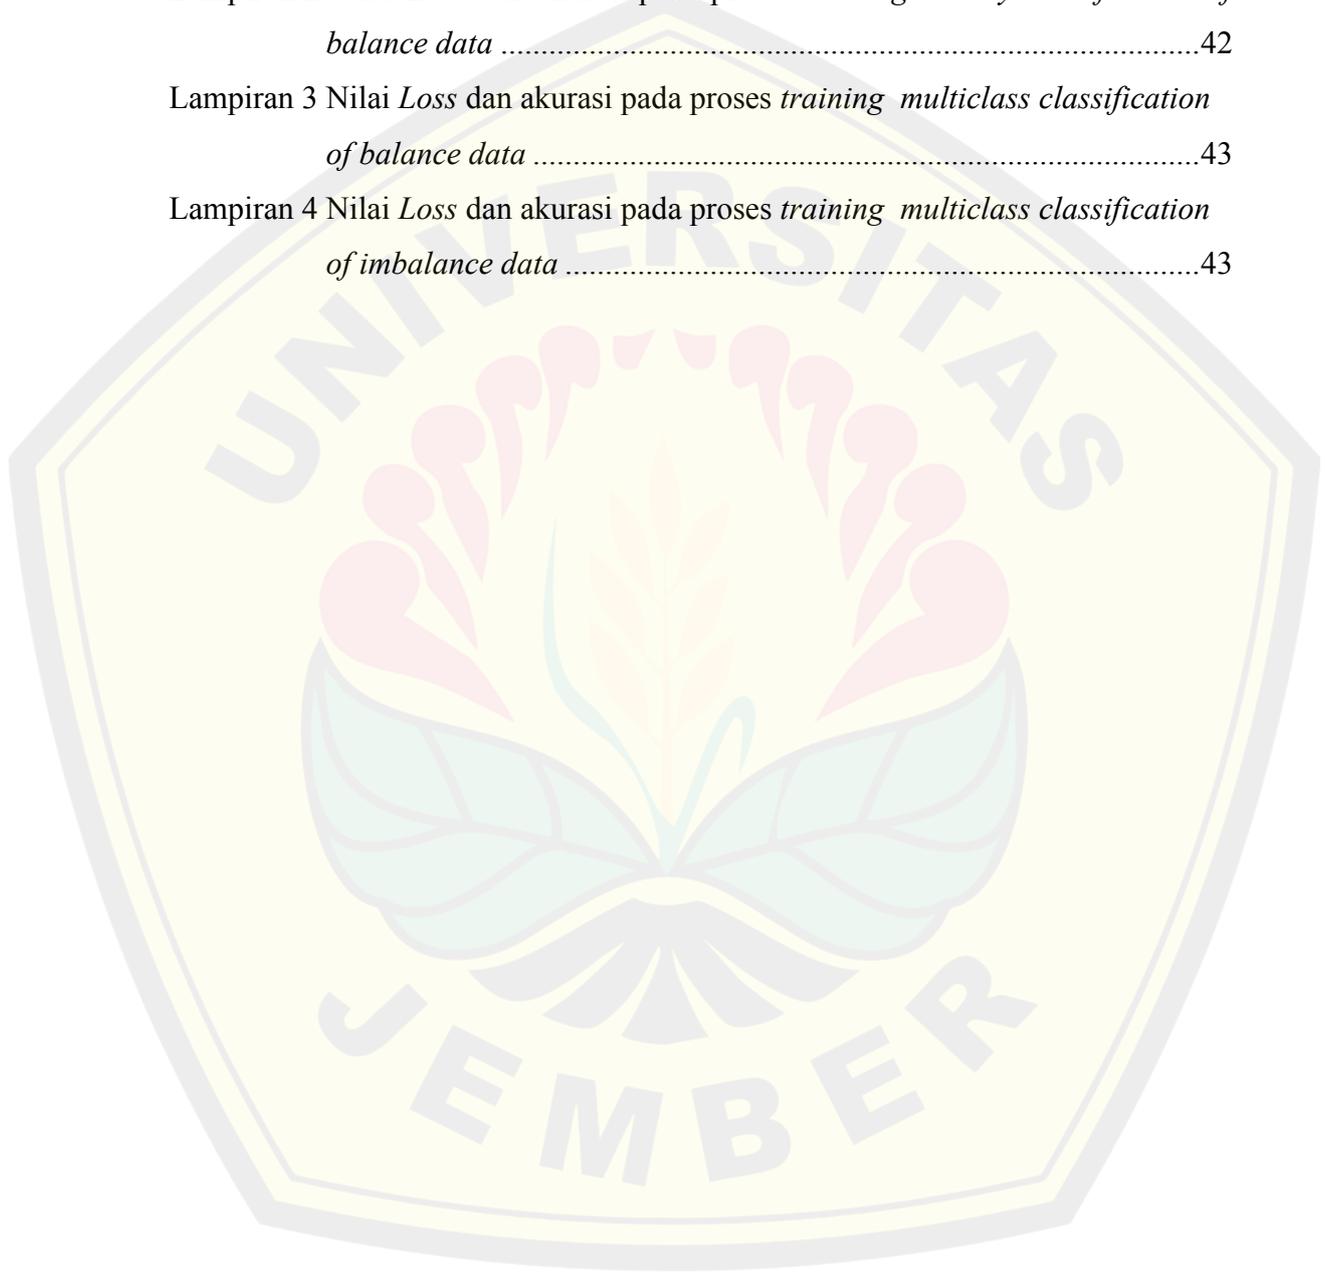
Gambar 4.12 *Confusion matrix multiclass classification untuk data tidak seimbang*  
(a) *training* (b) *testing*.....31

Gambar 4.13 Daun teh berpenyakit (a) *bird eye spot* (b) *antracnose*.....35



**DAFTAR LAMPIRAN**

Lampiran 1 Nilai <i>Loss</i> dan akurasi pada proses <i>training binary classification of imbalance data</i> .....	41
Lampiran 2 Nilai <i>Loss</i> dan akurasi pada proses <i>training binary classification of balance data</i> .....	42
Lampiran 3 Nilai <i>Loss</i> dan akurasi pada proses <i>training multiclass classification of balance data</i> .....	43
Lampiran 4 Nilai <i>Loss</i> dan akurasi pada proses <i>training multiclass classification of imbalance data</i> .....	43



## BAB 1. PENDAHULUAN

### 1.1 Latar Belakang

Seiring berjalannya waktu, perkembangan teknologi komputer mempermudah pekerjaan seseorang baik dalam bidang ekonomi, kesehatan, hingga pertanian. *Deep learning* menjadi fokus penting dalam prediksi ilmiah, salah satunya di bidang pertanian yang bertujuan untuk mengurangi resiko gagal panen. Indonesia merupakan negara dengan sumber daya alam yang melimpah salah satunya adalah daun teh. Teh merupakan salah satu komoditas pertanian yang cukup diminati. Tingginya minat terhadap teh dikarenakan kandungan di dalamnya yang memiliki banyak manfaat (Azurianti et al., 2022).

Menurut statistik tahun 2020, Indonesia merupakan negara penghasil teh terbesar ke-7 di dunia (BPS, 2020). Perkembangan produksi daun teh di Indonesia dari tahun 2018 hingga 2020 cenderung mengalami penurunan. Beberapa masalah yang sering dihadapi oleh para petani teh diantaranya adalah ekspor dan impor yang menurun, berkurangnya lahan pertanian dan penyakit tanaman. Penyakit daun teh ini dapat menyebabkan pertumbuhan tanaman teh tidak optimal, sehingga mengakibatkan penurunan hasil dan kualitas daun teh (Azurianti et al., 2022).

Penyakit daun teh biasanya disebabkan oleh jamur, bakteri, ganggang, dan virus. Selain itu, ada juga penyakit lain yang disebabkan oleh kondisi lingkungan yang tidak mendukung (Agarwal et al., 2020). Beberapa penyakit pada daun teh yang umum diketahui seperti *Algal Leaf*, *Antracnose*, *Bird Eye Spot*. Penyakit *Algal Leaf* adalah penyakit yang menyerang daun dewasa yang muncul sebagai area melingkar berwarna hijau keabu-abuan yang pada akhirnya membentuk karat merah karena alga menghasilkan banyak sekali spora mikroskopis berwarna karat (Y. Liu et al., 2021; Nurlaeni et al., 2021). *Antracnose* adalah penyakit yang disebabkan oleh *Colletotrium theae sinensis*. Penyakit ini menyebabkan penurunan warna hijau pada daun teh. Penyakit *Bird Eye Spot* disebabkan oleh patogen jamur, *Cercospora theae*. Penyakit *Bird Eye Spot* menyerang daun teh yang sudah matang sehingga mempengaruhi fotosintesis dan suplai makanan.

Pengendalian penyakit pada daun teh membutuhkan berbagai upaya untuk mengidentifikasi penyakit pada daun teh. Usaha terkini yang dapat dilakukan adalah membuat model klasifikasi penyakit pada daun teh. Berbagai metode digunakan untuk mendiagnosis penyakit daun teh, salah satunya dengan identifikasi mikroskopis. Namun, metode tersebut membutuhkan waktu yang lama dan bisa bersifat subyektif, sehingga diperlukan cara yang lebih cepat untuk menangani masalah tersebut. Pengenalan dan pengendalian penyakit daun teh yang akurat dapat menjaga kualitas dan kuantitas produk. Pesatnya perkembangan teknologi komputer mampu memecahkan berbagai permasalahan di bidang pertanian, salah satunya *deep learning*. *Deep learning* banyak digunakan dalam klasifikasi gambar, deteksi objek, pemrosesan bahasa alami, dan secara otomatis mengintegrasikan proses ekstraksi fitur ke dalam *training*. *Deep learning* telah berhasil mengumpulkan kumpulan data yang besar dan dapat digunakan untuk mendiagnosis penyakit tanaman dengan cepat dan akurat (Chandra Karmokar et al., 2015).

Penelitian ini melakukan pengklasifikasian pada penyakit daun teh menggunakan algoritma *Convolutional Neural Network* (CNN). Penyakit daun teh dibagi menjadi 4 kelas yaitu *Algal\_Leaf*, *Antracnose*, *Bird\_Eye\_Spot* dan *Healthy*. Dimensi gambar penyakit daun teh yang digunakan adalah 256 x 256 piksel dengan jumlah kanal sebanyak 3 yaitu *red*, *green*, *blue* (RGB). Gambar akan diklasifikasikan menggunakan *supervised learning* dengan melatih data sebelum diuji. Klasifikasi yang akan diuji adalah *binary classification*, *multiclass classification* menggunakan data seimbang dan data tidak seimbang.

## 1.2 Rumusan Masalah

Adapun rumusan masalah dalam penelitian ini meliputi :

1. Bagaimana penerapan algoritma *Convolution Neural Network* (CNN) menggunakan *binary classification of balance data* pada penyakit daun teh?
2. Bagaimana penerapan algoritma *Convolution Neural Network* (CNN) menggunakan *binary classification of balance data* pada penyakit daun teh?

3. Bagaimana penerapan algoritma *Convolution Neural Network* (CNN) menggunakan *multiclass classification of balance data* pada penyakit daun teh?
4. Bagaimana penerapan algoritma *Convolution Neural Network* (CNN) menggunakan *multiclass classification of imbalance data* pada penyakit daun teh?

### 1.3 Tujuan

Tujuan dari penelitian ini adalah :

1. Menjelaskan penerapan algoritma *Convolution Neural Network* (CNN) menggunakan *binary classification of imbalance data* pada penyakit daun teh.
2. Menjelaskan penerapan algoritma *Convolution Neural Network* (CNN) menggunakan *binary classification of balance data* pada penyakit daun teh.
3. Menjelaskan penerapan algoritma *Convolution Neural Network* (CNN) menggunakan *multiclass classification of balance data* pada penyakit daun teh.
4. Menjelaskan penerapan algoritma *Convolution Neural Network* (CNN) menggunakan *multiclass classification of imbalance data* pada penyakit daun teh.

### 1.4 Manfaat

Manfaat yang diperoleh dari penelitian ini sebagai berikut :

1. Bagi peneliti dapat menjadi sumber data referensi penelitian yang sejenis.
2. Bagi lembaga pemerintahan dapat dijadikan sebagai rekomendasi dalam pendeteksi penyakit pada daun teh.
3. Bagi masyarakat dapat dijadikan sebuah acuan dalam perhitungan pendeteksi penyakit pada daun teh untuk meningkatkan produktivitas.

## BAB 2. TINJAUAN PUSTAKA

### 2.1 Tanaman Teh

Teh adalah tanaman dengan nama latin *Camellia Sinensis* dalam keluarga *Theaceae* (Ponmurugan et al., 2010). Teh tersebut mengandung senyawa yang dapat mengobati beberapa penyakit ringan dan mencegah serangan berbagai penyakit serius (Nafi'ah, 2016). Namun, dalam beberapa tahun terakhir, produksi teh menurun akibat penyusutan lahan. Produktivitas teh sangat dipengaruhi oleh faktor internal (tanaman) dan faktor eksternal (lingkungan).

#### 2.1.1 Penyakit Daun Teh *Algal Leaf*

Penyakit alga paling umum yang menyerang tanaman teh disebut *Algal Leaf* disebabkan oleh alga *Cephaleuros*. *Algal Leaf* ditandai dengan adanya bercak berwarna hijau atau coklat kemerahan pada permukaan atas daun teh (Ponmurugan et al., 2010). Contoh penyakit daun teh *Algal Leaf* pada Gambar 2.1 :



Gambar 2.1 Penyakit Daun Teh *Algal Leaf*

Sumber : [www.kaggle.com](http://www.kaggle.com)

#### 2.1.2 Penyakit Daun Teh *Antracnose*

*Antracnose* adalah penyakit jamur yang dapat menyerang daun teh. Penyakit *Antracnose* disebabkan oleh jamur *Colletotrichum*. Penyakit *Antracnose* dapat menyerang bagian daun, batang, dan buah. Gejala penyakit ini berupa bintik-bintik kecil berbentuk lingkaran atau tidak beraturan. Awalnya, bintik-bintik tampak basah. Saat penyakit berkembang, bintik-bintik membesar dan berubah coklat tua atau hitam. Daerah yang terkena bisa cekung dan mengering. (Marsuni, 2020). Contoh penyakit daun teh *Antracnose* pada Gambar 2.2 :

Gambar 2.2 Penyakit Daun Teh *Antracnose*Sumber : [www.kaggle.com](http://www.kaggle.com)

### 2.1.3 Penyakit Daun Teh *Bird Eye Spot*

Penyakit mata burung atau biasa dikenal penyakit *bird eye spot* disebabkan oleh jamur *Cercospora Theae* dan menyerang daun tanaman teh. Akibat adanya penyakit ini, pertumbuhan tanaman menjadi lambat dan lemah sehingga menyebabkan okulasi lambat dan menurun. Gejala penyakit *bird eye spot* yaitu munculnya bintik-bintik kecil, melingkar atau berbentuk oval pada permukaan atas daun teh. Bintik-bintik ini awalnya berwarna coklat kekuningan tetapi kemudian berubah menjadi coklat tua atau hitam. Daun yang terkena dampak parah dapat menguning dan rontok sebelum waktunya (Selvi, 2016). Contoh penyakit daun teh *Bird Eye Spot* pada Gambar 2.3 :

Gambar 2.3 Penyakit Daun Teh *Bird Eye Spot*Sumber : [www.kaggle.com](http://www.kaggle.com)

### 2.1.4 Daun Teh Sehat

Daun teh yang sehat adalah daun yang menunjukkan karakteristik yang diinginkan dan bebas dari penyakit, hama, atau kerusakan fisik. Adapun ciri-ciri daun teh yang sehat adalah memiliki warna hijau cerah, memiliki tekstur halus, mengeluarkan aroma yang khas, bebas dari kerusakan fisik, dan tidak terinfeksi hama dan penyakit. Contoh daun teh *Healthy* pada Gambar 2.4 :

Gambar 2.4 Daun Teh *Healthy*Sumber : [www.kaggle.com](http://www.kaggle.com)

## 2.2 Citra Digital

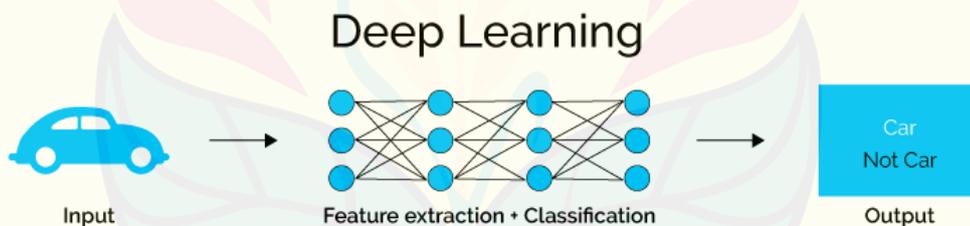
Citra digital adalah citra elektronik yang diambil dari beberapa jenis dokumen, yaitu berupa foto, buku, ataupun video dan suara (Putri, 2018).

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0, N-1) \\ f(1,0) & f(1,1) & \dots & f(1, N-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1, N-1) \end{bmatrix} \quad (2.1)$$

Indeks  $x$  dan  $y$  digunakan untuk menotasikan baris dan kolom. Indeks  $x$  bergerak ke bawah dan indeks  $y$  bergerak ke kanan. Titik asal adalah  $f(0,0)$  yang terletak di pojok kiri atas, dan berakhir di posisi  $f(M-1, N-1)$ .

## 2.3 Deep Learning

*Deep Learning* adalah bagian dari *Machine Learning* yang berfokus pada pelatihan jaringan syaraf tiruan dengan banyak lapisan (arsitektur) untuk melakukan tugas-tugas kompleks. *Deep Learning* terinspirasi oleh struktur otak manusia dimana informasi diproses melalui neuron yang saling berhubungan (Ningsih, 2021). Contoh struktur pemodelan jaringan pada *deep learning* dapat dilihat pada Gambar 2.5.



Gambar 2.5 Contoh struktur pemodelan jaringan pada *Deep Learning*

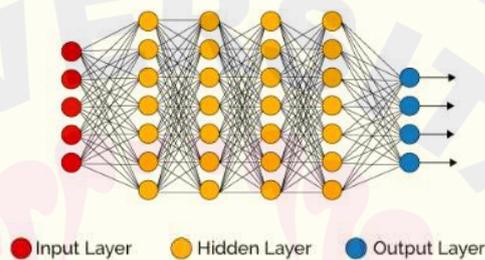
Sumber : (Dadang, 2018)

Arsitektur *deep learning* terdiri dari serangkaian *layer* atau lapisan yang saling berhubungan, dimana setiap bagian memiliki peran tertentu dalam mengolah dan mengekstraksi karakteristik data baik pada citra digital, teks, maupun suara. Proses *deep learning* menggunakan sejumlah data besar berlabel. *Deep learning* merupakan pengembangan dari *multilayer perceptron* (MLP) yang terdiri dari *input layer*, *hidden layer*, dan *output layer*. Salah satu keuntungan utama *deep learning* adalah kemampuannya secara otomatis mempelajari fitur yang relevan dari data mentah (Asri & Firmansyah, 2018). Selain itu, *deep learning* memiliki tingkat

akurasi yang lebih tinggi dibandingkan dengan metode lainnya (Hashemi, 2019; Hasma & Silfianti, 2018).

#### 2.4 Convolutional Neural Network (CNN)

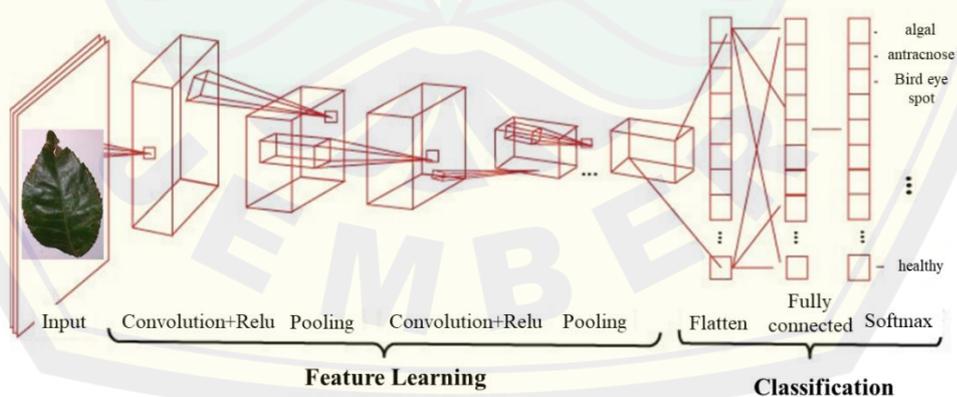
*Convolutional neural network* (CNN) adalah jenis khusus dari *deep learning* yang dirancang untuk memproses dan menganalisis data terstruktur seperti grid, gambar atau data spasial. CNN banyak diaplikasikan pada data citra (Suartika et al., 2016). *Convolutional neural network* terdiri dari *input layer*, *output layer*, dan beberapa *hidden layer*. Lapisan layer pada jaringan *deep learning* dapat dilihat pada Gambar 2.6.



Gambar 2.6 Lapisan Layer pada Jaringan *Deep Learning*

Sumber : (Ningsih, 2021)

*Hidden layer* biasanya berisi *convolutional layers*, *pooling layers*, dan *fully connected layer*. Berbeda dengan *Multi Layer Perceptron* (MLP) yang arsitekturnya disusun secara satu dimensi, CNN menggunakan arsitektur dua dimensi yaitu lebar (*width*) dan tinggi (*height*) (Bella, 2021). Layer pada algoritma CNN dapat dilihat pada Gambar 2.7.



Gambar 2.7 Layer pada algoritma CNN

Sumber : (Rosyidah et al., 2023)

*Input layer* berfungsi menerima data *input* mentah, yang biasanya berupa gambar atau struktur data spasial. *Hidden layer* berfungsi menghubungkan semua neuron dari lapisan sebelumnya ke lapisan berikutnya. Layer ini mempelajari pola dan hubungan yang rumit di peta fitur. *Output layer* adalah lapisan terakhir dari CNN. Misalnya dalam klasifikasi citra, lapisan keluaran mungkin memiliki neuron yang sesuai dengan kelas yang berbeda yang mewakili probabilitas atau prediksi untuk setiap kelas (Abduljabbar et al., 2019).

#### 2.4.1 Convolution Layer

*Convolution layer* ini dapat diterapkan untuk operasi *convolution* pada data citra secara berurutan guna mempelajari fitur tepi, warna, dan bentuk dari citra input (Latha et al., 2021). Operasi *convolution* diterapkan pada dua matriks yaitu matriks yang berisi piksel input dan matriks filter. Filter berisi nilai random antara -1 sampai 1 yang digunakan untuk mempelajari fitur pada gambar sesuai ukuran filternya (Ningsih, 2021). Ukuran filter bergantung pada arsitekturnya. Filter bergeser sebanyak *stride* pada nilai input dengan perkalian *dot product* yang diilustrasikan pada Gambar 2.8.

a	b	c	d
e	f	g	h
i	j	k	l
m	n	o	p

*Image 4 x 4*

$$\times$$

r	s	t
u	v	w
x	y	z

*Filter 3 x 3*

$$=$$

ar + bs + ct + eu + fv + gw + ix + jy + kz	br + cs + dt + fu + gv + hw + jx + ky + lz
er + fs + gt + iu + jv + kw + mx + ny + oz	fr + gs + ht + ju + kv + lw + nx + oy + pz

*Output 2 x 2*

Gambar 2.8 Operasi *Convolution*

*Convolution layer* memiliki *stride* dan *zero padding*. *Stride* merupakan jumlah pergeseran filter sedangkan *zero padding* merupakan jumlah penambahan intensitas nol di daerah sekeliling input gambar. CNN umumnya menggunakan lebar langkah atau *stride* = 1.

### 2.4.2 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi untuk mengaktifkan neuron dan meningkatkan sifat nonlinearitas di dalam jaringan secara keseluruhan. Beberapa fungsi aktivasi antara lain :

#### a. *Rectified Linear Unit (ReLU)*

*Rectified Linear Unit (ReLU)* adalah fungsi aktivasi yang biasa digunakan dalam jaringan syaraf termasuk CNN. Fungsi aktivasi ReLU didefinisikan sebagai berikut :

$$F(x) = \max(0, x) \quad (2.2)$$

$F(x)$  adalah nilai dari ReLU *activation* dan  $x$  adalah nilai matriks dari citra. Nilai 0 ditetapkan sebagai fungsi aktivasi pengganti nilai negatif pada *feature map* dan nilai input neuron *feature map* tetap jika bernilai lebih dari atau sama dengan nol (Ningsih, 2021). ReLU menjadi pilihan populer untuk fungsi aktivasi dalam *deep learning* karena kesederhanaan, efektivitas dan efisiensi komputasinya. ReLU memungkinkan jaringan mempelajari hubungan yang lebih kompleks antar fitur (Balde et al., 2022).

#### b. *Aktivasi Sigmoid*

Fungsi aktivasi sigmoid adalah fungsi aktivasi non linier yang biasa digunakan untuk masalah klasifikasi dengan persamaan berikut (Rosyidah et al., 2023):

$$f(x) = \frac{1}{(1+e^{-x})} \quad (2.3)$$

$x$  adalah input fungsi dan  $e$  menunjukkan fungsi eksponensial. *Output* dari fungsi ini selalu berada dalam interval 0 dan 1.

#### c. *Aktivasi Softmax*

Aktivasi *Softmax* atau disebut *Softmax Classifier* merupakan bentuk lain dari algoritma *logistic regression* yaitu mampu mengklasifikasi lebih dari dua kelas. Bentuk persamaan yang muncul pada *Softmax* sebagai berikut :

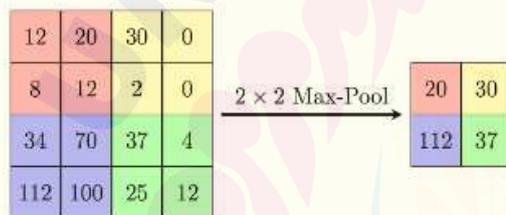
$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (2.4)$$

$\vec{z}$  merupakan vektor input ke fungsi *softmax*.  $z_i$  adalah elemen dari vektor input ke fungsi *softmax* dan nilai tersebut merupakan bilangan riil apapun.  $e^{z_i}$  adalah fungsi

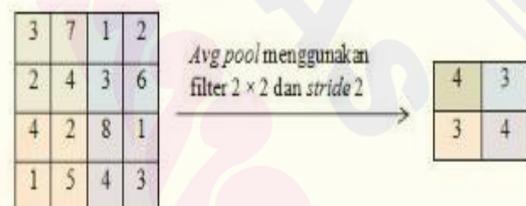
eksponensial yang diterapkan pada setiap elemen vektor input. Istilah  $\sum_{j=1}^K e^{z_j}$  adalah normalisasi, sedangkan  $K$  adalah jumlah kelas dalam pengklasifikasi *multiclass* (Ningsih, 2021).

### 2.4.3 Pooling Layer

*Pooling layer* adalah penggabungan yang membantu mereduksi data. Proses *pooling layer* dapat mengurangi ukuran *array* dengan menggunakan fungsi *pooling layer*. Lapisan gabungan biasanya muncul setelah lapisan *convolution*. Ada dua jenis *pooling layer* yang biasa digunakan, yaitu *average pooling* dan *maximum pooling*. *Average pooling* nilai yang diambil adalah rata-rata, sedangkan *maximum pooling* nilai yang diambil adalah nilai maksimal. Berikut adalah ilustrasi *max pooling* dengan matriks  $4 \times 4$  dapat dilihat pada Gambar 2.9 dan *average pooling* dapat dilihat pada Gambar 2.10.



Gambar 2.9 Operasi *Max Pooling*



Gambar 2.10 Operasi *Average Pooling*

Sumber : (Ilahiyah & Nilogiri, 2018; Rizal, 2022)

Gambar 2.9 memperlihatkan fungsi *max-pooling* untuk citra  $4 \times 4$  dengan ukuran *max-pooling*  $2 \times 2$  (Albawi et al., 2017). Hasil dari proses *pooling* adalah matriks dengan dimensi yang lebih kecil dari matriks aslinya. Bentuk seperti ini akan mengurangi *feature map* hingga 75% dari ukuran aslinya. *Max pooling* berguna mempertahankan informasi yang paling menonjol sehingga secara efektif dapat mengurangi *feature map* dan mempertahankan fitur paling penting. Proses *convolution* dan *pooling* dilakukan beberapa kali sehingga untuk mendapatkan *feature map* yang diinginkan. *Feature map* tersebut akan menjadi input bagi *fully connected neural network* (Gayathri et al., 2020).

#### 2.4.4 Flatten

*Flatten* ini berguna untuk membentuk ulang fitur menjadi sebuah vektor agar bisa digunakan sebagai input dari *fully connected layer*. Saat bekerja dengan data gambar di CNN, lapisan *convolution* memproses input sebagai multidimensi, menangkap pola dan fitur lokal. Namun, lapisan yang terhubung sepenuhnya memerlukan *input* satu dimensi (Putri, 2018).

#### 2.4.5 Fully Connected Layer

*Fully connected layer* adalah *layer* yang biasa digunakan dalam *Multi Layer Perceptron* (MLP). Tiap neuron pada *convolution layer* perlu ditransformasi menjadi data satu dimensi terlebih dahulu agar dapat diklasifikasi secara linear. *Fully connected layer* didefinisikan sebagai berikut:

$$y_j = b_j + \sum w_{ij} x_i \quad (2.5)$$

Dimana  $x$  merupakan input pada *fully connected layer* yang merupakan hasil dari pembelajaran fitur,  $w$  merupakan bobot jaringan berukuran  $i \times j$  dengan  $i$  menunjukkan jumlah fitur dan  $j$  menunjukkan jumlah target kelas,  $b$  merupakan bias dan  $y$  merupakan output dari *fully connected layer* (B. Liu et al., 2018).

#### 2.4.6 Darknet 19

*Darknet-19* adalah arsitektur *deep learning* yang dikembangkan oleh Joseph Redmon. *Darknet-19* dirancang untuk berbagai tugas penglihatan komputer termasuk deteksi dan klasifikasi objek. Input *darknet-19* berupa gambar atau peta fitur. *Darknet-19* dimulai dengan 19 lapisan *convolution*, 5 lapisan *maxpooling* yang diakhiri dengan *softmax*. Lapisan ini menggunakan filter berukuran  $3 \times 3$  untuk menangkap pola. *Darknet-19* dikenal dengan efisiensi dan ukurannya yang relative kecil dibandingkan dengan arsitektur *neural network* lainnya. *Darknet-19* menyediakan arsitektur yang ringkas dan efektif (Swastika et al., 2019).

*Deep learning* memiliki metode optimasi yang biasa digunakan salah satunya yaitu *adam optimizer*. ADAM merupakan algoritma optimasi yang dapat digunakan untuk memperbarui bobot secara iteratif berdasarkan data pelatihan. ADAM merupakan sebuah metode untuk optimasi yang efisien dan hanya membutuhkan gradien orde pertama dengan kebutuhan memori yang kecil (Kingma & Ba, 2015). Arsitektur suatu model bukanlah faktor utama untuk mendapatkan akurasi terbaik.

Lebih tepatnya kualitas data pelatihan serta *preprocessing* dan augmentasinya yang dapat memberikan peningkatan akurasi yang paling signifikan (Boulent et al., 2019).

#### 2.4.7 Confusion Matrix

*Confusion matrix* adalah penilaian model klasifikasi yang digunakan untuk memprediksi elemen mana yang benar dan mana yang salah. Matriks prediksi yang dibandingkan dengan kelas *input* asli (Mustakim & Oktaviani, 2016). Menurut (Suartika et al., 2016) kinerja model yang diuji diukur dengan empat bacaan dengan penjelasan.

- a. TP (*True Positive*) adalah jumlah data positif yang terklasifikasi benar.
- b. TN (*True Negative*) adalah jumlah data negatif yang terklasifikasi benar.
- c. FP (*False Positive*) adalah jumlah data negative yang terklasifikasi salah.
- d. FN (*False Negative*) adalah jumlah data positif yang terklasifikasi salah.

Hasil yang didapat dari nilai TP, TN, FP, dan FN tersebut merupakan hasil nilai yang diperoleh setelah menghitung selisih antara perhitungan jumlah objek secara manual (aktual) dan secara otomatis (prediksi). Berikut merupakan tabel dari confusion matrix yang disajikan dalam Tabel 2.1.

Tabel 2.1 Tabel *confusion matrix*

		<i>Predicted Class</i>	
		Positif (P)	Negatif (N)
<i>Actual Class</i>	Positif (P)	TP	FP
	Negatif (N)	FN	TN

Setelah dilakukan perhitungan dengan uji *Confusion Matrix*, selanjutnya dilakukan perhitungan terhadap nilai yang diperoleh untuk mendapatkan hasil analisis. Indikator tersebut dihitung dengan persamaan berikut (Almazroi, 2022) :

##### a. Accuracy

*Accuracy* merupakan perbandingan antara prediksi nilai benar dengan data keseluruhan. Berikut persamaan untuk menggambarkan seberapa tepat model dapat memprediksi dengan benar.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (2.6)$$

b. *Precision*

*Precision* merupakan presentase *true positive* pada masing-masing kelas dengan seluruh data yang diprediksi. Nilai *precision* dapat dilihat dari persamaan 2.7.

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (2.7)$$

c. *Recall*

*Recall* merupakan presentase prediksi *true positive* pada masing-masing kelas dengan seluruh data sebenarnya. Nilai *recall* dapat diperoleh dari persamaan 2.8

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (2.8)$$

d. *Specificity*

*Specificity* merupakan presentase prediksi data yang tidak sakit dengan seluruh data sesungguhnya yang tidak sakit. *Specificity* diperoleh dengan persamaan 2.9.

$$Specificity = \frac{TN}{TN+FP} \times 100\% \quad (2.9)$$

### BAB 3. METODOLOGI PENELITIAN

#### 3.1 Data Penelitian

Data penelitian yang digunakan dalam penelitian ini adalah data sekunder gambar daun teh yang diperoleh dari laman dataset kaggle yaitu penyakit daun teh <https://www.kaggle.com/datasets/shashwatwork/identifying-disease-in-tea-leafs>.

Contoh daun teh yang digunakan sebagai berikut:



Gambar 3.1 Contoh gambar penyakit daun teh

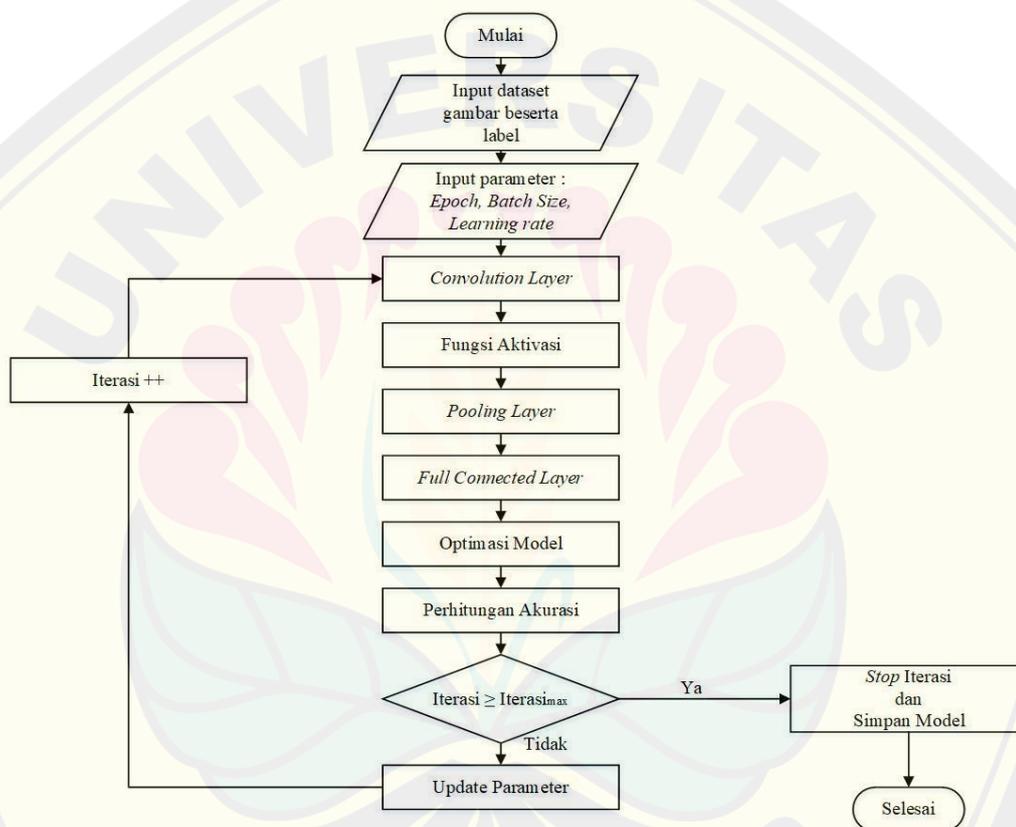
Data yang digunakan dalam penelitian ini adalah data gambar daun teh yang sehat maupun yang berpenyakit. Pengambilan data dilakukan pada tanggal 8 Januari 2023. Jumlah data yang terkumpul sebanyak 400 data. Proporsi data pada masing-masing kelas sebanyak 100 data. Sejumlah data penyakit daun teh dapat dilihat pada Tabel 3.1

Tabel 3.1 Data penyakit daun teh

No	Kode	Ukuran Asli	Kelas
1	23-01-08-H-01	768 x 1024	<i>Healthy</i>
2	23-01-08-An-01	3120 x 4160	<i>Antracnose</i>
3	23-01-08-H-02	768 x 1024	<i>Healthy</i>
4	23-01-08-AL-01	768 x 1024	<i>Algal_Leaf</i>
...	...	...	...
395	23-01-08-BES-96	3120 x 4160	<i>Bird_Eye_Spot</i>
396	23-01-08-An-97	4160 x 3120	<i>Antracnose</i>
397	23-01-08-AL-93	768 x 1024	<i>Algal_Leaf</i>
398	23-01-08-H-96	1024 x 1024	<i>Healthy</i>
399	23-01-08-BES-98	3120 x 4160	<i>Bird_Eye_Spot</i>
400	23-01-08-AL-100	768 x 1024	<i>Algal_Leaf</i>

### 3.2 Algoritma *Convolutional Neural Network*

Data penelitian kemudian diproses dengan menggunakan algoritma *Convolutional Neural Network* (CNN). Desain arsitektur pada algoritma CNN dibuat dengan tujuan untuk memperoleh model prediksi terbaik berdasarkan dataset yang dimasukkan. Susunan *layer* dan pemilihan jenis layer yang akan digunakan sangat berpengaruh dalam pembuatan arsitektur CNN. Diagram algoritma CNN yang digunakan untuk mendapatkan model prediksi terbaik ditunjukkan dalam Gambar 3.2 berikut



Gambar 3.2 Diagram alur di dalam algoritma CNN

Data gambar penyakit daun teh (*Camellia Sinensis*) diperoleh secara online pada laman dataset Kaggle. Setiap gambar yang diperoleh memiliki label tersendiri (kelas penyakit). Gambar berlabel akan dimasukkan untuk dijadikan sebagai dataset. Pertama yang harus dilakukan adalah mendefinisikan *layers* terlebih dahulu dan menentukan bagaimana data akan melewati jaringan dalam *forward function*. *Layer* yang dimaksud adalah *convolution layer*, fungsi aktivasi, dan *pooling layer*.

Setelah itu, seluruh neuron dari lapisan sebelumnya akan terhubung penuh pada *fully connected layer*.

Optimasi merupakan suatu proses penyesuaian parameter model untuk mengurangi kesalahan prediksi model dalam setiap langkah proses *training*. Upaya yang dilakukan untuk optimalisasi model adalah dengan *loss function* dan *optimizer*. *Loss function* digunakan untuk mengukur ketidaksamaan data hasil prediksi dengan data target. *Loss function* dihitung dengan membuat prediksi input data sampel yang diberikan dan membandingkannya dengan nilai label (kelas) sesungguhnya.

Selain itu, hyperparameter merupakan parameter yang dapat disesuaikan dan bertujuan untuk mengontrol pengoptimalan model. Nilai *hyperparameter* yang berbeda dapat mempengaruhi pelatihan model. Berikut adalah *hyperparameter* yang digunakan dalam proses *training*.

- a. *Epoch* merupakan jumlah iterasi dalam proses suatu model mengenali dataset.
- b. *Batch size* merupakan jumlah data sampel yang dapat dilihat oleh model dalam setiap *epoch*nya.
- c. *Learning rate*, berguna untuk mengatur berapa banyak parameter model yang dapat diperbarui untuk setiap *batch / epoch*. *Learning rate* yang kecil membuat proses *training* semakin berjalan lambat.

### 3.3 Tahapan Penelitian

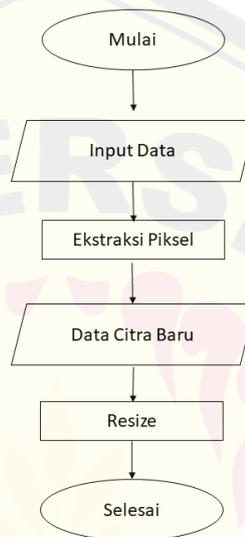
Tahapan penelitian ini dilakukan secara sistematis sebagai berikut

- a. Pengumpulan Data

Data gambar penyakit daun teh (*Camellia Sinensis*) diperoleh secara *online* pada laman dataset Kaggle. Data gambar ditangkap menggunakan kamera <https://www.kaggle.com/datasets/shashwatwork/identifying-disease-in-tea-leafs>. Banyak data yang diperoleh sebanyak 400 gambar dengan 300 daun teh yang terkena penyakit dan 100 daun teh yang sehat. Data dibagi menjadi 2 bagian yaitu data pelatihan masing-masing sebanyak 30 % dan data pengujian masing-masing sebanyak 70%.

b. *Image Pre-processing*

*Pre-processing* merupakan langkah awal pengolahan data yang dilakukan dengan tujuan mendapatkan data yang optimal. Data yang telah melalui tahapan *pre-processing* tersebut yang nantinya akan digunakan sebagai data *input* pada proses klasifikasi. Langkah-langkah *pre-processing* data *image* dilakukan sesuai dengan diagram alur pada Gambar 3.3:



Gambar 3.3 Diagram alur *pre-processing*

c. Perancangan CNN

Model CNN dilatih dengan menggunakan data pelatihan yang sudah disediakan. Setelah itu, proses pelatihan (*training*) dapat dilakukan. Penentuan model algoritma terbaik pada tahap *training* ditentukan oleh parameter. Parameter yang akan digunakan adalah 150 *epoch*, 10 *batchsize*, dan 0,0001 *learningrate*. Setiap satu *epoch*, model akan mempelajari parameter untuk membuat prediksi dengan baik. Hasil akurasi dan *loss* model akan ditampilkan pada masing-masing *epoch*. Fungsi *loss* digunakan untuk melihat ukuran kebaikan model. Proses *training* bertujuan untuk melatih algoritma CNN yang telah dibuat dalam mengenali dataset gambar dan membentuk model terbaik berdasarkan pelatihan tersebut.

## d. Pengujian Model

Tahapan selanjutnya adalah melakukan pengujian model (*testing*). Data yang digunakan adalah data uji yang belum pernah dilatih sebelumnya. Proses ini bertujuan menguji suatu model yang telah dibuat pada saat proses *training* menggunakan data baru. Tahap pengujian model ini berguna untuk mengetahui seberapa baik model memprediksi suatu kelas dengan benar.

## e. Skenario Data

Data yang digunakan dibagi ke dalam dua skenario. Skenario pertama adalah *balance data*. *Balance data* merupakan data yang memiliki proporsi sama di setiap kelas pada tahap *training*. *Balance data* mampu memberikan representasi yang tidak bias pada setiap kelas sehingga algoritma mampu belajar secara efektif untuk klasifikasi data. Skenario kedua menggunakan data yang tidak seimbang (*imbalance data*). *Imbalance data* merupakan kumpulan data dimana perbedaan dalam setiap kelas berbeda sehingga terdapat kelas mayoritas dan minoritas.

## f. Analisis hasil

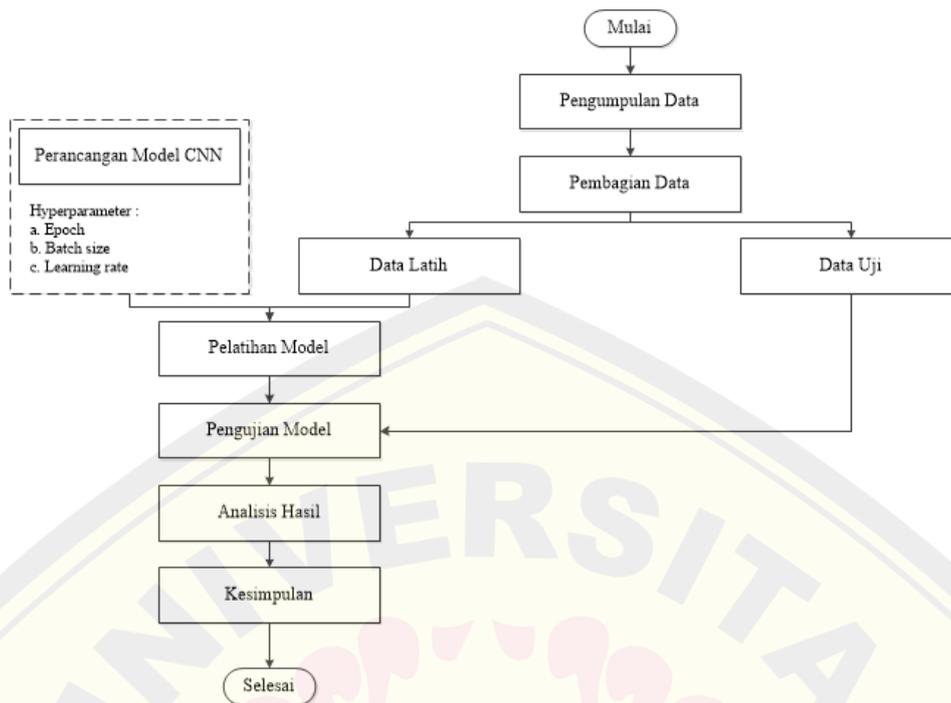
Model yang telah dibuat akan diuji menggunakan dataset yang tersedia, apakah proses telah berjalan dengan baik. Penelitian ini menganalisis ketepatan model dalam memprediksi suatu data dengan memperhatikan tingkat akurasi, presisi, *recall*, dan *specificity*. Tingkat nilai akurasi dalam prediksi sebagai berikut (Rizal, 2022) :

90% < Akurasi ≤ 100%	artinya <i>excellent classification</i>
80% < Akurasi ≤ 90%	artinya <i>good classification</i>
70% < Akurasi ≤ 80%	artinya <i>fair classification</i>
60% < Akurasi ≤ 70%	artinya <i>poor classification</i>
Akurasi ≤ 60%	artinya <i>failure</i>

## g. Kesimpulan

Membuat kesimpulan dari penelitian yang telah dilakukan, yaitu dengan menganalisis akurasi dari algoritma *Convolutional Neural Network* dalam memprediksi kelas penyakit daun teh.

Tahapan penelitian dengan *flowchart* ditunjukkan pada Gambar 3.4.



Gambar 3.4 Tahapan Penelitian

### 3.4 MATLAB *Toolbox* untuk CNN

Penelitian ini mengembangkan program dengan menggunakan platform pemrograman MATLAB. MATLAB adalah merk *software* yang dikembangkan oleh Mathworks.Inc. (lihat <http://www.mathworks.com>). Program yang dikembangkan mengimplementasikan algoritma CNN menggunakan arsitektur *Darknet 19*. *Toolbox* MATLAB yang digunakan pada penelitian ini adalah *deep learning toolbox*, *optimization toolbox* dan *bioinformatics toolbox*. *Deep learning toolbox* menyediakan seperangkat alat untuk merancang, melatih dan menerapkan *deep learning*. *Optimization toolbox* menyediakan kumpulan algoritma dan fungsi untuk memecahkan masalah pengoptimalan. *Bioinformatics toolbox* menyediakan alat dan fungsi khusus untuk menganalisis dan mengevaluasi data (Paluszek et al., 2022).

## BAB 4 HASIL DAN PEMBAHASAN

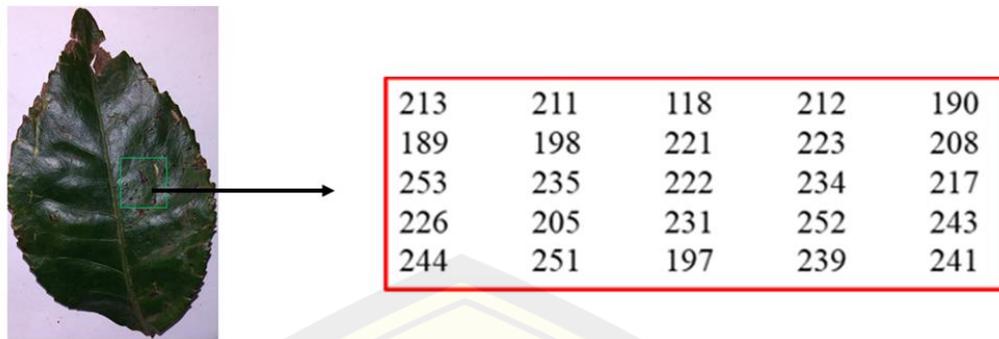
Bab ini akan dipaparkan metode CNN dalam mengklasifikasikan penyakit tanaman pada daun teh. Kelas yang diberikan berupa *Healthy* untuk daun teh yang sehat, *Algal\_Leaf* untuk daun berpenyakit *algal leaf*, *Antracnose* untuk daun teh berpenyakit *antracnose*, dan *Bird\_Eye\_Spot* untuk daun teh berpenyakit *bird eye spot*.

### 4.1 Image Preprocessing

*Image Preprocessing* dilakukan agar proses pelatihan pada mesin berjalan dengan baik. Tahap awal, data yang berupa gambar akan diambil nilai pikselnya. Setelah itu, piksel-piksel yang telah diperoleh akan dijadikan variabel  $X$  dan kelas sebagai variabel  $Y$ . Dataset akan di *resize* agar memiliki dimensi piksel yang sama. Data yang telah seragam kemudian diambil nilai-nilai pikselnya sehingga data tersebut berubah menjadi kumpulan *array* atau matriks. Piksel atau derajat keabuan dari gambar diperoleh dengan menggunakan perintah `impxel` yang dijalankan di *software* Matlab. Nilai-nilai piksel dari gambar penyakit daun teh ditunjukkan pada Tabel 4.1 dan contoh ekstraksi piksel pada citra ditunjukkan pada Gambar 4.1.

Tabel 4.1 Nilai-nilai piksel data gambar penyakit daun teh

No	Kode	Piksel	Resize	Kelas
1	23-01-08-H-01	[161., 218., 247., ...]	256 x 256	<i>Healthy</i>
2	23-01-08-An-01	[64., 29., 23., ...]	256 x 256	<i>Antracnose</i>
3	23-01-08-H-02	[182., 220., 255., ...]	256 x 256	<i>Healthy</i>
4	23-01-08-AL-01	[200., 187., 194., ...]	256 x 256	<i>Algal_Leaf</i>
...	...	...	...	...
395	23-01-08-BES-96	[72., 47., 66., ...]	256 x 256	<i>Bird_Eye_Spot</i>
396	23-01-08-An-97	[87., 62., 83., ...]	256 x 256	<i>Antracnose</i>
397	23-01-08-AL-93	[253., 242., 246., ...]	256 x 256	<i>Algal_Leaf</i>
398	23-01-08-H-96	[175., 215., 225., ...]	256 x 256	<i>Healthy</i>
399	23-01-08-BES-98	[46., 26., 37., ...]	256 x 256	<i>Bird_Eye_Spot</i>
400	23-01-08-AL-100	[236., 224., 226., ...]	256 x 256	<i>Algal_Leaf</i>



Gambar 4.1 Contoh Ekstraksi Piksel Citra

Data dibagi menjadi dua bagian. Bagian pertama adalah data pelatihan dan bagian kedua adalah data pengujian. Proporsi pada data pelatihan lebih besar dari pada data pengujian, hal ini dikarenakan konsep pembelajaran mesin didasarkan pada konsep belajar dari data sehingga mampu mempelajari pola dan hubungan dari data yang tersedia. Perbandingan data pelatihan dan data pengujian pada penelitian ini yaitu 70% : 30%. Skenario pada penelitian ini menggunakan *balance data* dan *imbalance data*. Skenario ini dibuat untuk menguji apakah model mampu menghasilkan klasifikasi yang akurat. Klasifikasi yang diuji yaitu *Binary Classification* dan *Multiclass Classification*. Skenario data pada penelitian ini ditunjukkan pada Tabel 4.2 dan Tabel 4.3.

Tabel 4.2 Skenario Data pada *Binary Classification*

Subjek	Data Tidak Seimbang		Total Observasi	Data Seimbang	
	Latih	Uji		Latih	Uji
<i>Healthy</i>	70	30	100	70	30
<i>Tea Disease</i>	210	90	300	70	30

Tabel 4.3 Skenario Data pada *Multiclass Classification*

Subjek	Data Seimbang		Data tidak seimbang		Total Observasi
	Latih	Uji	Latih	Uji	
<i>Healthy</i>	40	15	56	24	80
<i>Antracnose</i>	40	15	39	16	55
<i>Algal_Leaf</i>	40	15	42	18	60
<i>Bird_Eye_Spot</i>	40	15	49	21	70

**4.2 Hasil Pemrosesan CNN**

**a. Hasil Operasi *Zeropadding***

*Zeropadding* berguna untuk mempertahankan dimensi citra dan menjaga informasi. Gambar yang telah diekstrak dan menghasilkan piksel dalam bentuk matriks selanjutnya akan ditambahkan angka nol di sekitar *input* matriks untuk mengontrol ukuran *output* setelah operasi *convolution*. Hasil Operasi *zeropadding* ditunjukkan pada Gambar 4.2.

0	0	0	0	0	0	0
0	213	211	118	212	190	0
0	189	198	221	223	208	0
0	253	235	222	234	217	0
0	226	205	231	252	243	0
0	244	251	197	239	241	0
0	0	0	0	0	0	0

Gambar 4.2 Hasil Operasi *Zeropadding*

**b. Hasil Operasi *Convolution***

Operasi *convolution* berguna untuk mengidentifikasi pola. Matriks *input* dan filter 3x3 akan bergeser ke arah kanan dengan *stride* 1 menggunakan aturan *dot product* sesuai dengan operasi *convolution* yang sudah dijelaskan pada Gambar 2.8. *Output* yang dihasilkan disebut *feature map*. Contoh Hasil Operasi *convolution* dapat dilihat pada Gambar 4.3.

0	0	0	0	0	0	0
0	213	211	118	212	190	0
0	189	198	221	223	208	0
0	253	235	222	234	217	0
0	226	205	231	252	243	0
0	244	251	197	239	241	0
0	0	0	0	0	0	0

 $\times$ 

1	0	1
1	-1	1
-1	0	-1

 $=$ 

-200	-290	-116	-333	-201
-15	68	154	75	-7
-25	193	211	160	-12
-37	286	205	223	4
212	647	750	673	250

Gambar 4.3 Hasil Operasi *Convolution*

**c. Hasil Operasi *Rectified Linear Unit (ReLU)***

*Feature map* negatif pada *Rectified Linear Unit (ReLU)* akan diubah menjadi nol dan bernilai tetap jika *feature map* lebih besar dari nol atau samadengan nol. Hasil Operasi *Rectified Linear Unit (ReLU)* dapat dilihat pada Gambar 4.4.

-200	-290	-116	-333	-201
-15	68	154	75	-7
-25	193	211	160	-12
-37	286	205	223	4
212	647	750	673	250

 $=$ 

0	0	0	0	0
0	68	154	75	0
0	193	211	160	0
0	286	205	223	4
212	647	750	673	250

Gambar 4.4 Hasil Operasi *Convolution Rectified Linear Unit (ReLU)*

**d. Hasil Operasi *Pooling Layer***

*Max pooling* mempertahankan nilai maksimum pada *input*. Filter 3x3 akan bergerak dari pojok kiri atas ke kanan bawah sesuai dengan Gambar 4.5 berikut :

0	0	0	0	0
0	68	154	75	0
0	193	211	160	0
0	286	205	223	4
212	647	750	673	250

 $=$ 

193	211	211
286	286	223
750	750	750

Gambar 4.5 Hasil Operasi *Pooling Layer*

**e. Hasil Operasi *Flatten***

*Flatten* bertujuan untuk mengubah data menjadi satu dimensi. *Output* dari *flatten* adalah vektor seperti Gambar 4.6 :

193	211	211
286	286	223
750	750	750

 $=$  [193,211,211,286,286,223,750,750,750]

Gambar 4.6 Hasil Operasi *Flatten*

**f. Hasil Operasi *Normalization***

*Normalization* digunakan untuk menyeragamkan nilai piksel gambar. Dataset harus diurutkan (*data training*, *data testing*) terlebih dahulu sebelum dilakukan *normalization*. Vektor dinormalisasi menggunakan persamaan berikut :

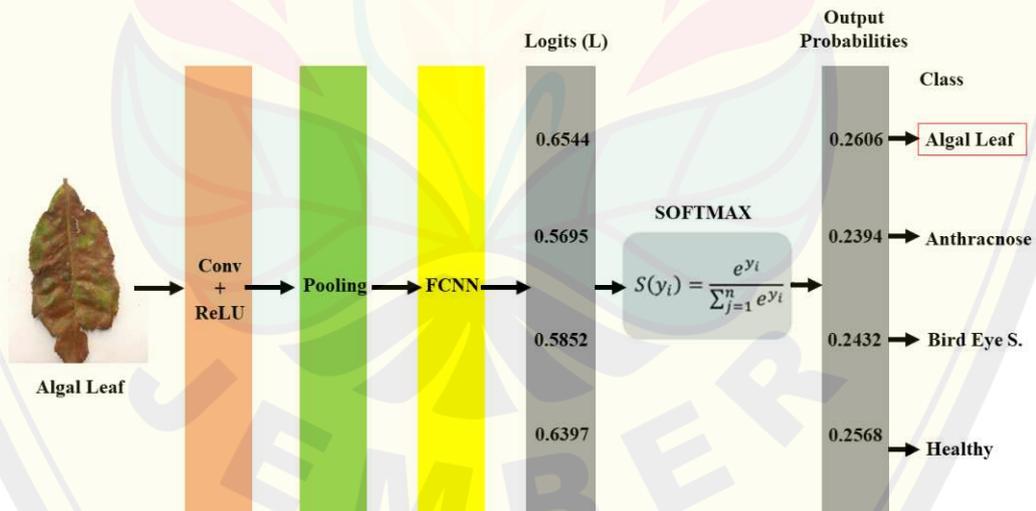
$$x_i = \frac{a+(c_i-\max(c))x(b-a)}{\max(c)-\min(c)}, \text{ dimana } a = 0.1; b = 0.9; c = \text{input vektor} \quad (4.1)$$

Berdasarkan perhitungan normalisasi menggunakan rumus di atas didapatkan vektor input untuk *Fully Connected Neural Network* (FCNN) sebagai berikut :

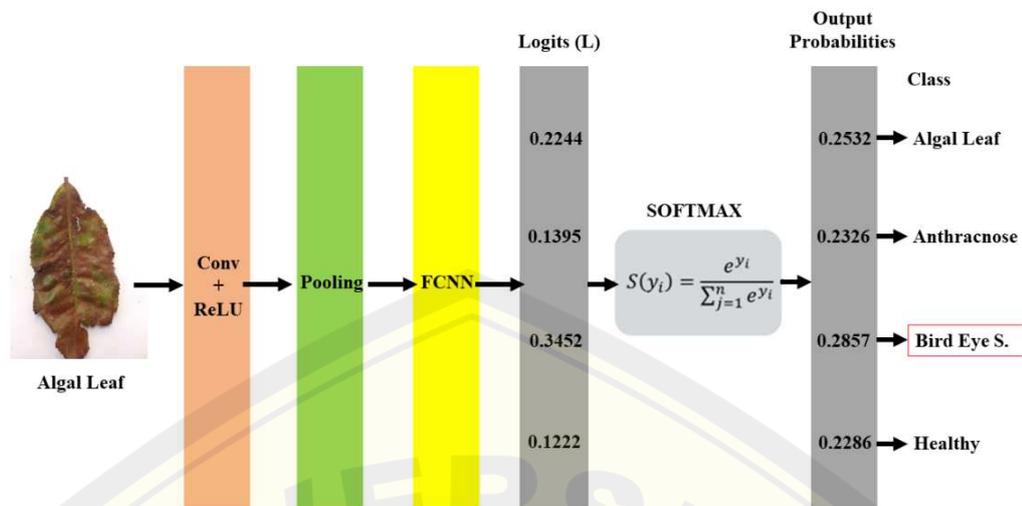
$$x = [0.1; 0.13; 0.13; 0.23; 0.23; 0.14; 0.9; 0.9; 0.9]$$

#### g. Hasil Operasi FCNN

Vektor  $x$  yang sudah didapatkan menjadi input *Fully Connected Neural Network* (FCNN). *Output* FCNN didapatkan dengan menghitung bias ditambah jumlah bobot dikali input. Langkah selanjutnya mengaktifkan setiap *output* neuron. Fungsi aktivasi yang digunakan untuk mengaktifkan *output* neuron adalah *log sigmoid* dengan menggunakan rumus pada persamaan 2.3. Proses FCNN terakhir menggunakan *softmax* untuk menghasilkan distribusi probabilitas. Ilustrasi proses *softmax* dengan *output* yang sesuai dengan prediksi ditunjukkan pada Gambar 4.7 sedangkan ilustrasi proses *softmax* dengan *output* yang tidak sesuai prediksi ditunjukkan pada Gambar 4.8. Nilai *output* diproses menggunakan fungsi *softmax* dengan persamaan 2.4. Berdasarkan nilai probabilitas yang dihasilkan, probabilitas terbesar menentukan prediksi *output*.



Gambar 4.7 Hasil *Softmax* dengan *Output* yang Sesuai dengan Prediksi



Gambar 4.8 Hasil *Softmax* dengan *Output* yang Tidak Sesuai dengan Prediksi

### 4.3 Pemodelan Klasifikasi Menggunakan CNN

Data yang telah diproses dengan *image preprocessing* siap untuk digunakan dengan menjalankan *image classifier* pada *toolbox* matlab menggunakan fungsi *trainNetwork*. Arsitektur yang digunakan pada klasifikasi penyakit daun teh ini menggunakan *darknet19* dengan *optimizer* “adam”. Pengujian keberhasilan algoritma CNN dalam klasifikasi penyakit daun the dilakukan dengan beberapa percobaan terhadap implementasi data. Parameter yang digunakan telah diatur terlebih dahulu yaitu menggunakan 150 *epoch*, 10 *batch size*, dan 0,0001 *learning rate*.

#### 4.3.1 *Binary Classification of Imbalance Data*

*Binary Classification* adalah proses pengklasifikasian yang diberikan algoritma tertentu berdasarkan dua kelas yang berbeda (Kumari & Kr., 2017). *Binary classification* menggunakan perbandingan data pada proses *training* dan *testing* adalah 70% : 30%. Hasil *confusion matrix* dengan skenario *imbalance data* ditunjukkan pada Gambar 4.9.



Gambar 4.9 *Confusion matrix binary classification*

(a) *training imbalance data* (b) *testing imbalance data*

Berdasarkan Gambar 4.9 (a) pada proses pelatihan, hasil klasifikasi seluruhnya terbaca dengan sangat baik oleh model. *True Positive* sejumlah 210 daun teh yang terinfeksi penyakit (*Tea Disease*). *True Negative* sejumlah 70 daun teh berkelas sehat (*Healthy*) diklasifikasikan dengan benar sebagai daun teh sehat. Pemodelan data pelatihan tidak terdapat *False Positive* dan *False Negative*. Gambar 4.9 (b) pada proses pengujian, hasil klasifikasi seluruhnya terbaca dengan sangat baik oleh model. *True Positive* sejumlah 90 daun teh yang terinfeksi penyakit dan *True Negative* sejumlah 30 daun teh berkelas sehat diklasifikasikan dengan benar sebagai daun teh sehat. Pemodelan data pengujian tidak terdapat *False Positive* dan *False Negative*. Hasil loss dan akurasi selama proses *training* dapat dilihat pada Lampiran 1.

#### 4.3.2 *Binary Classification of Balance Data*

##### a. Deteksi Daun Teh Sehat dan Seluruh Daun Teh Berpenyakit

*Binary classification of balance data* diperoleh dari skenario *imbalance data* dengan teknik *undersampling*. Teknik *undersampling* adalah menyeimbangkan dataset dengan mengurangi ukuran kelas mayoritas agar memiliki jumlah yang sama dengan kelas minoritas. Klasifikasi penyakit daun teh menggunakan algoritma CNN dengan arsitektur *darknet19* menghasilkan *confusion matrix* yang sangat baik pada data pelatihan maupun data pengujian. Hasil *confusion matrix binary classification of balance data* disajikan pada Gambar 4.10.



Gambar 4.10 *Confusion matrix binary classification*  
 (a) *training balance data* (b) *testing balance data*

Berdasarkan Gambar 4.10 (a) pada proses pelatihan, *True Positive* sejumlah 70 daun teh yang terinfeksi penyakit pada *balance data* diklasifikasikan dengan benar sebagai daun teh yang terinfeksi penyakit. *True Negative* sejumlah 70 daun teh berkelas sehat (*Healthy*) pada *balance data* diklasifikasikan dengan benar sebagai daun teh sehat. Pemodelan data pelatihan tidak terdapat *False Positive* dan *False Negative*. Gambar 4.10 (b) pada proses pengujian, *True Positive* sejumlah 30 daun teh yang terinfeksi penyakit diklasifikasikan dengan benar sebagai sebagai daun teh yang terinfeksi penyakit. *True Negative* sejumlah 30 daun teh berkelas sehat pada *balance data* diklasifikasikan dengan benar sebagai daun teh sehat. Pemodelan data pelatihan tidak terdapat *False Positive* dan *False Negative*. Nilai evaluasi model pada masing-masing percobaan dapat dilihat pada Tabel 4.4. Hasil loss dan akurasi selama proses *training* dapat dilihat pada Lampiran 2.

Tabel 4.4 Nilai evaluasi model CNN *binary classification* pada proses *testing*

<i>Skenario</i>	<i>Binary Class</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>Specificity</i>
<i>Imbalance data</i>	<i>Healthy vs Tea Disease</i>	100%	100%	100%	100%
<i>Balance data</i>	<i>Healthy vs Tea Disease</i>	100%	100%	100%	100%

- b. Deteksi Daun Teh Sehat dan Masing-masing Daun Teh Berpenyakit  
 Model diuji dengan mendeteksi setiap penyakit dengan daun teh sehat. *Healthy* diuji dengan *Algal Leaf*, *Healthy* diuji dengan *Antracnose*, *Healthy* diuji dengan *Bird Eye Spot*. Hasil *confusion matrix* disajikan pada Tabel 4.5 dan Tabel 4.6.

Tabel 4.5 *Confusion matrix* algoritma CNN pada *training data*

Data	Binary Class	Confusion matrix									
Training data	<i>Healthy vs Algal Leaf</i>	<table border="1"> <tr> <td>Algal_Leaf</td> <td>70</td> <td>0</td> </tr> <tr> <td>Healthy</td> <td>0</td> <td>70</td> </tr> <tr> <td></td> <td>Algal_Leaf</td> <td>Healthy</td> </tr> </table>	Algal_Leaf	70	0	Healthy	0	70		Algal_Leaf	Healthy
	Algal_Leaf	70	0								
	Healthy	0	70								
	Algal_Leaf	Healthy									
<i>Healthy vs Antracnose</i>	<table border="1"> <tr> <td>Antracnose</td> <td>70</td> <td>0</td> </tr> <tr> <td>Healthy</td> <td>0</td> <td>70</td> </tr> <tr> <td></td> <td>Antracnose</td> <td>Healthy</td> </tr> </table>	Antracnose	70	0	Healthy	0	70		Antracnose	Healthy	
Antracnose	70	0									
Healthy	0	70									
	Antracnose	Healthy									
<i>Healthy vs Bird Eye Spot</i>	<table border="1"> <tr> <td>Bird_Eye_Spot</td> <td>70</td> <td>0</td> </tr> <tr> <td>Healthy</td> <td>0</td> <td>70</td> </tr> <tr> <td></td> <td>Bird_Eye_Spot</td> <td>Healthy</td> </tr> </table>	Bird_Eye_Spot	70	0	Healthy	0	70		Bird_Eye_Spot	Healthy	
Bird_Eye_Spot	70	0									
Healthy	0	70									
	Bird_Eye_Spot	Healthy									

Tabel 4.6 *Confusion matrix* algoritma CNN pada *testing data*

Data	Binary Class	Confusion matrix											
Testing data	<i>Healthy vs Algal Leaf</i>	<table border="1" style="margin-left: auto; margin-right: auto;"> <tr> <td rowspan="2" style="vertical-align: middle;">True Class</td> <td>Alga_Leaf</td> <td style="background-color: #0070C0; color: white; text-align: center;">30</td> <td></td> </tr> <tr> <td>Healthy</td> <td></td> <td style="background-color: #0070C0; color: white; text-align: center;">30</td> </tr> <tr> <td></td> <td></td> <td style="text-align: center;">Alga_Leaf</td> <td style="text-align: center;">Healthy</td> </tr> </table>	True Class	Alga_Leaf	30		Healthy		30			Alga_Leaf	Healthy
	True Class	Alga_Leaf		30									
		Healthy		30									
		Alga_Leaf	Healthy										
<i>Healthy vs Antracnose</i>	<table border="1" style="margin-left: auto; margin-right: auto;"> <tr> <td rowspan="2" style="vertical-align: middle;">True Class</td> <td>Antracnose</td> <td style="background-color: #0070C0; color: white; text-align: center;">30</td> <td></td> </tr> <tr> <td>Healthy</td> <td></td> <td style="background-color: #0070C0; color: white; text-align: center;">30</td> </tr> <tr> <td></td> <td></td> <td style="text-align: center;">Antracnose</td> <td style="text-align: center;">Healthy</td> </tr> </table>	True Class	Antracnose	30		Healthy		30			Antracnose	Healthy	
True Class	Antracnose		30										
	Healthy		30										
		Antracnose	Healthy										
<i>Healthy vs Bird Eye Spot</i>	<table border="1" style="margin-left: auto; margin-right: auto;"> <tr> <td rowspan="2" style="vertical-align: middle;">True Class</td> <td>Bird_Eye_Spot</td> <td style="background-color: #0070C0; color: white; text-align: center;">30</td> <td></td> </tr> <tr> <td>Healthy</td> <td></td> <td style="background-color: #0070C0; color: white; text-align: center;">30</td> </tr> <tr> <td></td> <td></td> <td style="text-align: center;">Bird_Eye_Spot</td> <td style="text-align: center;">Healthy</td> </tr> </table>	True Class	Bird_Eye_Spot	30		Healthy		30			Bird_Eye_Spot	Healthy	
True Class	Bird_Eye_Spot		30										
	Healthy		30										
		Bird_Eye_Spot	Healthy										

Berdasarkan Tabel 4.5 pada data pelatihan, hasil klasifikasi seluruhnya terbaca dengan sangat baik oleh model. *True Positif* sejumlah 70 daun teh berkelas *algall leaf*, *antracnose*, dan *bird eye spot* diklasifikasikan dengan benar sebagai *algall leaf*, *antracnose*, dan *bird eye spot*. *True Negative* sejumlah 70 daun teh

berkelas *healthy* pada masing-masing percobaan diklasifikasikan dengan benar sebagai *healthy*. Pemodelan data pelatihan tidak terdapat *False Positive* dan *False Negative*. Nilai evaluasi model dapat diperoleh dari tabel *confusion matrix* diatas. Nilai evaluasi model pada masing-masing percobaan dapat dilihat pada Tabel 4.7

Tabel 4.7 Nilai evaluasi model CNN *binary class* pada proses *training*

<b><i>Binary Class</i></b>	<b><i>Accuracy</i></b>	<b><i>Precision</i></b>	<b><i>Recall</i></b>	<b><i>Specificity</i></b>
<i>Healthy vs Algal Leaf</i>	100%	100%	100%	100%
<i>Healthy vs Antracnose</i>	100%	100%	100%	100%
<i>Healthy vs Bird Eye Spot</i>	100%	100%	100%	100%

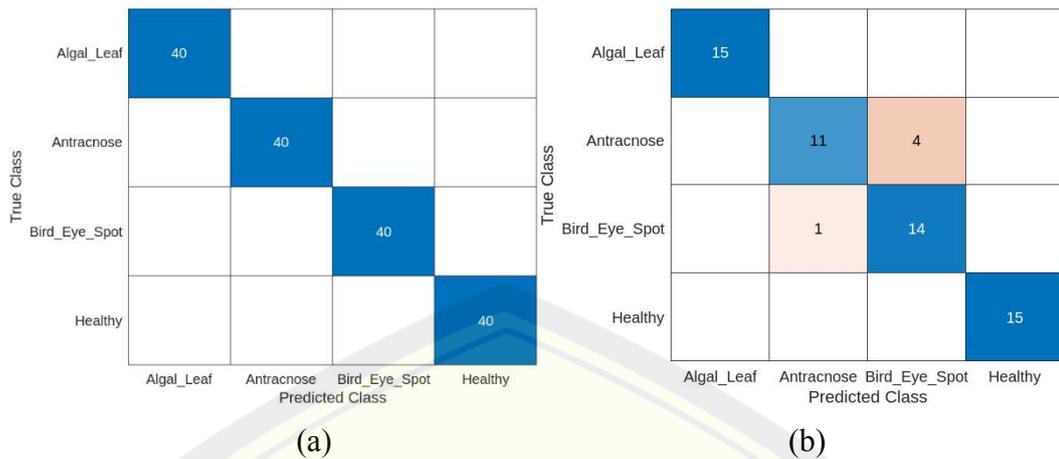
Hasil klasifikasi data pengujian terbaca dengan sangat baik oleh model. *True Positif* sejumlah 30 daun teh berkelas *algal leaf*, *antracnose*, dan *bird eye spot* diklasifikasikan dengan benar sebagai *algal leaf*, *antracnose*, dan *bird eye spot*. *True Negative* sejumlah 30 daun teh berkelas *healthy* pada masing-masing percobaan diklasifikasikan dengan benar sebagai *healthy*. Pada pemodelan data pelatihan tidak terdapat *False Positive* dan *False Negative*. Nilai evaluasi model dapat diperoleh dari tabel *confusion matrix* diatas. Nilai evaluasi model pada masing-masing percobaan dapat dilihat pada Tabel 4.8. Sedangkan hasil loss dan akurasi selama proses *training* dapat dilihat pada Lampiran A.

Tabel 4.8 Nilai evaluasi model CNN *binary class* pada proses *testing*

<b><i>Binary Class</i></b>	<b><i>Accuracy</i></b>	<b><i>Precision</i></b>	<b><i>Recall</i></b>	<b><i>Specificity</i></b>
<i>Healthy vs Algal Leaf</i>	100%	100%	100%	100%
<i>Healthy vs Antracnose</i>	100%	100%	100%	100%
<i>Healthy vs Bird Eye Spot</i>	100%	100%	100%	100%

#### 4.3.3 ***Multiclass Classification of Balance Data***

*Multiclass Classification* adalah proses klasifikasi dengan algoritma tertentu ke dalam tiga kelas atau lebih. *Multiclass Classification* memiliki tantangan tersendiri dalam pengklasifikasian baik berupa data tabular maupun data gambar. *Multiclass classification* menggunakan perbandingan data pada proses *training* dan *testing* adalah 70% : 30%. *Multiclass classification of balance data* diperoleh dari skenario *imbalance data* yang diberikan teknik *undersampling*. Hasil *confusion matrix* disajikan pada Gambar 4.11.



Gambar 4.11 *Confusion matrix Multiclass Classification of Balance Data*

(a) *training* (b) *testing*

Gambar 4.11 (a) menunjukkan hasil klasifikasi pada proses *training* terbaca dengan sangat baik oleh model. *Confusion Matrix* pada klasifikasi biner dan klasifikasi multikelas memiliki perbedaan perhitungan. *True Positive* pada klasifikasi multikelas merupakan nilai aktual dan nilai prediksi sama sedangkan *False Positive* merupakan jumlah kolom yang bersesuaian kecuali nilai *True Positive*. *False Negative* merupakan jumlah baris yang bersesuaian kecuali nilai *True Positive* dan *True Negative* merupakan jumlah semua kolom dan baris kecuali nilai kelas yang dihitung. *True Positive* masing-masing kelas sejumlah 40 daun teh yang diklasifikasikan dengan benar sebagai *algal leaf*, *antracnose*, dan *bird eye spot* dan *healthy*. *True Negative* pada masing-masing kelas sejumlah 120. Proses *training* tidak terdapat *False Positive* dan *False Negative* artinya semua data mampu diklasifikasikan dengan akurat.

Gambar 4.11 (b) menunjukkan hasil klasifikasi pada proses *testing* terbaca dengan baik. Kelas *algal leaf* dan kelas *healthy* memiliki jumlah *True Positive* dan *True Negative* yang sama yaitu masing-masing 15 dan 45, artinya kelas aktual *algal leaf* dan *healthy* nilai prediksinya sama. *False Positive* dan *False Negative* pada kelas ini berjumlah 0, artinya model mampu mengklasifikasikan dengan sangat baik sehingga tidak terdapat kesalahan dalam klasifikasi. Kelas *antracnose* terdapat *False Positive* sebanyak 1 daun teh yang diklasifikasikan ke dalam penyakit *antracnose* padahal kenyataannya daun teh tersebut berpenyakit *bird eye spot*.

*False Negative* sebanyak 4 daun teh diprediksi ke dalam penyakit *bird eye spot* padahal kenyataannya ke empat daun teh tersebut berpenyakit *antracnose*. Kelas *bird eye spot* terdapat *False Positive* sebanyak 4 daun teh yang diklasifikasikan ke dalam penyakit *bird eye spot* padahal kenyataannya daun teh tersebut berpenyakit *antracnose*, terdapat juga *False Negative* sebanyak 1 daun teh yang diprediksi ke dalam penyakit *antracnose* padahal kenyataannya daun teh tersebut berpenyakit *bird eye spot*. Tabel dari *confusion matrix multiclass classification* disajikan dalam Tabel 4.9.

Tabel 4.9 Tabel *confusion matrix multiclass classification*

<b>Multiclass</b>	<b>TP</b>	<b>TN</b>	<b>FP</b>	<b>FN</b>
<i>Algal Leaf</i>	15	45	0	0
<i>Antracnose</i>	11	44	1	4
<i>Bird Eye Spot</i>	14	41	4	1
<i>Healthy</i>	15	45	0	0

Perhitungan *accuracy*, *precision*, *recall*, dan *specificity* dari hasil *confusion matrix* dapat dilihat pada Tabel 4.10. Hasil *loss* dan akurasi selama proses *training* dapat dilihat pada Lampiran 3.

Tabel 4.10 Nilai *accuracy*, *precision*, *recall*, dan *specificity*

<b>Multiclass</b>	<b>Accuracy</b>	<b>Precision</b>	<b>Recall</b>	<b>Specificity</b>
<i>Algal Leaf</i>		100%	100%	100%
<i>Antracnose</i>	95,83%	91,67%	73,34%	97,78%
<i>Bird Eye Spot</i>		77,78%	93,34%	91,12%
<i>Healthy</i>		100%	100%	100%

Berdasarkan informasi pada Tabel 4.10 model klasifikasi dapat memprediksi dengan benar sebesar 95,83% dan sisanya 4,17% model tidak dapat memprediksi dengan tepat. Nilai *accuracy* memberikan informasi berapa persen daun teh yang benar diprediksi terkena penyakit maupun sehat dari keseluruhan gambar daun teh. Nilai *precision* pada kelas *algal leaf* sebesar 100% artinya presentase daun teh yang terkena penyakit *algal leaf* dari keseluruhan data yang diprediksi terkena penyakit *algal leaf*. Model memprediksi tepat 15 daun teh yang terkena penyakit *algal leaf* dari 15 daun teh yang diprediksi terkena penyakit *algal*

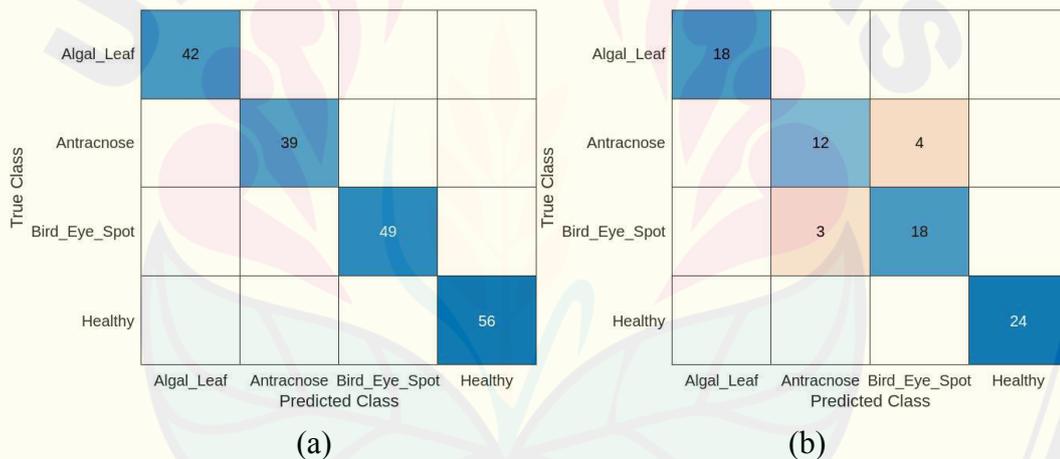
*leaf*. Nilai *precision* pada kelas *antracnose* sebesar 91,67% artinya presentase daun teh yang benar-benar terkena penyakit *antracnose* dan terdapat gambar daun teh tidak berpenyakit *antracnose* yang diprediksi sebagai daun teh berpenyakit *antracnose* sebesar 8,33%. Model dapat menebak dengan tepat 11 gambar teh yang terkena penyakit *antracnose* dari 12 gambar daun teh yang diprediksi terkena penyakit *antracnose*. Nilai *precision* pada kelas *bird eye spot* diperoleh 77,78% artinya presentase daun teh yang benar-benar terkena penyakit *bird eye spot* dan terdapat gambar daun teh tidak berpenyakit *bird eye spot* yang diprediksi sebagai daun teh berpenyakit *bird eye spot* sebesar 22,22%. Model dapat menebak dengan tepat 14 gambar teh yang terkena penyakit *bird eye spot* dari 18 gambar daun teh yang diprediksi terkena penyakit *bird eye spot*. Nilai *precision* ini dapat menjawab pertanyaan rasio daun teh yang benar terkena penyakit dari keseluruhan prediksi daun teh yang terkena penyakit.

*Recall* untuk kelas *algal leaf* memperoleh nilai sebesar 100%, ini mengindikasikan bahwa model sangat bisa memprediksi dengan benar daun teh yang terkena penyakit *algal leaf* dari keseluruhan data aktual status *algal leaf* sebesar 100%. Model sangat akurat dalam memprediksi daun teh yang terkena penyakit *algal leaf*. Model mampu memprediksi 15 daun teh *algal leaf* dari keseluruhan data aktual daun berpenyakit *algal leaf*. *Recall* pada kelas *antracnose* sebesar 73,34%, artinya model hanya bisa memprediksi dengan tepat 11 daun teh yang terkena penyakit *antracnose* dari 15 daun teh yang sesungguhnya terkena penyakit *antracnose*. *Recall* untuk kelas *bird eye spot* sebesar 93,34%, artinya model hanya bisa memprediksi dengan tepat 14 daun teh yang terkena penyakit *bird eye spot* dari 15 daun teh yang sesungguhnya terkena penyakit *bird eye spot*. perhitungan nilai *recall* bertujuan untuk melihat berapa persen daun teh yang diprediksi terkena penyakit dari keseluruhan daun teh yang sesungguhnya terkena penyakit. Nilai *specificity* diperoleh sebesar 100% untuk *algal leaf*, ini mengindikasikan bahwa model bisa memprediksi dengan 45 daun teh yang tidak terkena penyakit *algal leaf* dari 45 daun teh yang sesungguhnya tidak terkena penyakit *algal leaf*. Kelas *antracnose* memperoleh nilai 97,78%, itu artinya model memprediksi dengan benar 44 daun teh yang tidak terkena penyakit *antracnose* dari

45 daun teh yang sesungguhnya tidak terkena penyakit *antracnose*. Nilai *specificity* diperoleh sebesar 91,12% untuk kelas *bird eye spot*, ini mengindikasikan bahwa model bisa memprediksi dengan benar 41 daun teh yang tidak terkena penyakit *bird eye spot* dari 45 daun teh yang sesungguhnya tidak terkena penyakit *bird eye spot*.

#### 4.3.4 Multiclass Classification of Imbalance Data

Kelas tidak seimbang (*imbalance*) dapat menyebabkan hasil klasifikasi tidak akurat karena kelas minoritas diidentifikasi sebagai kelas mayoritas oleh mesin. *Imbalance* data tentu sangat berpengaruh ketika dievaluasi dengan akurasi hasil prediksi. Hasil klasifikasi data minor tidak tepat dan prediksi lebih dominan untuk data mayor. Skenario data tidak seimbang pada klasifikasi penyakit daun teh menggunakan algoritma CNN dengan arsitektur *darknet19* menghasilkan *confusion matrix* yang sangat baik pada data pelatihan tetapi cukup baik pada data pengujian. Hasil *confusion matrix* disajikan pada Gambar 4.11



Gambar 4.12 *Confusion matrix Multiclass Classification* untuk data tidak seimbang (a) *training* (b) *testing*

Gambar 4.12 (a) menunjukkan hasil klasifikasi pada proses *training* terbaca dengan sangat baik oleh model. *Confusion Matrix* pada klasifikasi multikelas menghasilkan klasifikasi yang sangat akurat atau dapat disebut sempurna karena tidak ada kesalahan klasifikasi. Gambar 4.12 (b) menunjukkan hasil klasifikasi pada proses *testing* terbaca cukup baik. Kelas *healthy* memiliki jumlah *True Positive* dan *True Negative* masing-masing 24 dan 55. *False Positive* dan *False Negative* pada kelas ini berjumlah 0, artinya model mampu mengklasifikasikan dengan sangat baik

sehingga tidak terdapat kesalahan dalam klasifikasi. Kelas *algal leaf* memiliki jumlah *True Positive* dan *True Negative* masing-masing 18 dan 61. Kemudian, untuk *False Positive* dan *False Negative* pada kelas ini berjumlah 0, artinya model mampu mengklasifikasikan dengan sangat baik sehingga tidak terdapat kesalahan dalam klasifikasi. Kelas *antracnose* terdapat *False Positive* sebanyak 3 daun teh yang diklasifikasikan ke dalam penyakit *antracnose* padahal kenyataannya daun teh tersebut berpenyakit *bird eye spot*, terdapat juga *False Negative* sebanyak 4 daun teh yang diprediksi ke dalam penyakit *bird eye spot* padahal kenyataannya 4 daun teh tersebut berpenyakit *antracnose*. *False Positive* pada kelas *bird eye spot* sebanyak 4 daun teh yang diklasifikasikan ke dalam penyakit *bird eye spot* padahal kenyataannya daun teh tersebut berpenyakit *antracnose*, terdapat juga *False Negative* sebanyak 3 daun teh yang diprediksi ke dalam penyakit *antracnose* padahal kenyataannya daun teh tersebut berpenyakit *bird eye spot*. Di bawah ini merupakan tabel dari *confusion matrix* klasifikasi multikelas disajikan dalam Tabel 4.11.

Tabel 4.11 Tabel *confusion matrix multiclass imbalance data*

<b>Multiclass</b>	<b>TP</b>	<b>TN</b>	<b>FP</b>	<b>FN</b>
<i>Algal Leaf</i>	18	61	0	0
<i>Antracnose</i>	12	60	3	4
<i>Bird Eye Spot</i>	18	54	4	3
<i>Healthy</i>	24	55	0	0

Perhitungan *accuracy*, *precision*, *recall*, dan *specificity* dari hasil *confusion matrix* dapat dilihat pada Tabel 4.12. Hasil *loss* dan akurasi selama proses *training* dapat dilihat pada Lampiran 4.

Tabel 4.12 Nilai *accuracy*, *precision*, *recall*, dan *specificity*

<b>Multiclass</b>	<b>Accuracy</b>	<b>Precision</b>	<b>Recall</b>	<b>Specificity</b>
<i>Algal Leaf</i>		100%	100%	100%
<i>Antracnose</i>	95,56%	80%	75%	95,23%
<i>Bird Eye Spot</i>		81,81%	85,71%	93,10%
<i>Healthy</i>		100%	100%	

Berdasarkan informasi pada Tabel 4.12, klasifikasi untuk data tidak seimbang model hanya dapat memprediksi dengan benar sebesar 95,56% dan

sisanya 4,44% model tidak dapat memprediksi dengan tepat. Nilai *accuracy* memberikan informasi berapa persen daun teh yang benar diprediksi terkena penyakit maupun sehat dari keseluruhan gambar daun teh. Nilai *precision* pada kelas *algal leaf* sebesar 100% artinya presentase daun teh yang benar terjangkit penyakit *algal leaf* dari keseluruhan data yang diprediksi terkena penyakit *algal leaf*. Model memprediksi tepat 18 daun teh yang terkena penyakit *algal leaf* dari 18 daun teh yang diprediksi terkena penyakit *algal leaf*. Nilai *precision* pada kelas *antracnose* sebesar 80% artinya presentase daun teh yang benar terjangkit penyakit *antracnose* dari keseluruhan data yang diprediksi terkena penyakit *antracnose*. Model dapat menebak dengan tepat 12 gambar teh yang terkena panyakit *antracnose* dari 15 gambar daun teh yang diprediksi terkena penyakit *antracnose*. Kelas *bird eye spot* memiliki nilai *precision* sebesar 81,81% artinya presentase daun teh yang benar-benar terkena penyakit *bird eye spot* dan terdapat gambar daun teh tidak berpenyakit *bird eye spot* yang diprediksi sebagai daun teh berpenyakit *bird eye spot* sebesar 18,19%. Model dapat menebak dengan tepat 18 gambar teh yang terkena panyakit *bird eye spot* dari 22 gambar daun teh yang diprediksi terkena penyakit *bird eye spot*. Nilai *precision* ini dapat menjawab pertanyaan rasio daun teh yang benar terkena penyakit dari keseluruhan daun teh yang diprediksi terkena penyakit.

*Recall* untuk kelas *algal leaf* memperoleh nilai sebesar 100%, ini mengindikasikan bahwa model sangat baik memprediksi dengan benar daun teh yang terkena penyakit *algal leaf* dari keseluruhan data aktual status *algal leaf*. Model sangat tepat memprediksi 18 daun teh yang terkena penyakit *algal leaf* dari 18 daun teh yang sesungguhnya terkena penyakit *algal leaf*. *Recall* pada kelas *antracnose* sebesar 75%, artinya model hanya bisa memprediksi dengan tepat 12 daun teh yang terkena penyakit *antracnose* dari 16 daun teh yang sesungguhnya terkena penyakit *antracnose*. *Recall* untuk kelas *bird eye spot* sebesar 85,71%, artinya model hanya bisa memprediksi dengan tepat 18 daun teh yang terkena penyakit *bird eye spot* dari 21 daun teh yang sesungguhnya terkena penyakit *bird eye spot*. Perhitungan nilai *recall* bertujuan untuk melihat berapa persen daun teh

yang diprediksi benar terkena penyakit dari keseluruhan daun teh yang sesungguhnya terkena penyakit.

Nilai *specificity* diperoleh sebesar 100% untuk *algal leaf*, ini mengindikasikan bahwa model bisa memprediksi dengan 61 daun teh yang tidak terkena penyakit *algal leaf* dari 61 daun teh yang sesungguhnya tidak terkena penyakit *algal leaf*. Kelas *antracnose* memperoleh nilai 95,23%, itu artinya model memprediksi dengan benar 60 daun teh yang tidak terkena penyakit *antracnose* dari 63 daun teh yang sesungguhnya tidak terkena penyakit *antracnose*. Nilai *specificity* diperoleh sebesar 93,10% untuk kelas *bird eye spot*, ini mengindikasikan bahwa model bisa memprediksi dengan benar 54 daun teh yang tidak terkena penyakit *bird eye spot* dari 58 daun teh yang sesungguhnya tidak terkena penyakit *bird eye spot*. Nilai *specificity* berfungsi untuk mengetahui berapa persen daun teh yang diprediksi tidak terkena penyakit dari keseluruhan daun teh yang pada kenyataannya tidak terkena penyakit.

#### 4.3.5 Analisis Hasil

Hasil klasifikasi biner *imbalance data* dan *imbalance data* terbaca sangat baik oleh model. Hal ini menunjukkan bahwa model dapat memprediksi dengan benar penyakit *Antracnose* dengan daun teh *Healthy*, penyakit *Algal Leaf* dengan daun teh *Healthy*, dan penyakit *Bird Eye Spot* dengan daun teh *Healthy*. Hasil tersebut dikarenakan gambar mudah dibedakan antara daun sehat dan daun berpenyakit. Selain itu, tidak terdapat penyakit lain yang terdapat pada klasifikasi tersebut.

Klasifikasi multikelas pada data seimbang maupun data tidak seimbang memberikan informasi tentang kesalahan klasifikasi pada kelas *antracnose* dan *bird eye spot*. Analisis penyebab kesalahan klasifikasi pada data penelitian ini dikarenakan objek memiliki tingkat kecerahan yang hampir sama antara kelas *antracnose* dan *bird eye spot*. Tingkat kecerahan pada klasifikasi gambar sangat penting, hal ini berkaitan dengan fitur-fitur penting pada gambar yang ditangkap oleh model. Berikut merupakan perbandingan gambar daun teh yang terkena penyakit *antracnose* dan *bird eye spot* dapat dilihat pada Gambar 4.13.



(a)

(b)

Gambar 4.13 Daun teh berpenyakit (a) *bird eye spot* (b) *antracnose*

Berdasarkan Tabel 4.10, kelas *antracnose* memperoleh nilai *precision* yang lebih rendah dibandingkan nilai *recall*, hal ini sangat penting karena model tidak salah mendiagnosa dan meminimalkan kesalahan prediksi. Kelas *bird eye spot* memiliki nilai *recall* lebih kecil daripada *precision*, hal ini terjadi saat model mampu memprediksi lebih banyak daun berpenyakit *bird eye spot*, sehingga kesalahan prediksinya kecil. *Precision* yang tinggi menunjukkan bahwa model dapat diandalkan dalam mengidentifikasi kasus yang benar-benar memiliki penyakit.

Berdasarkan Tabel 4.12, kelas *antracnose* memperoleh nilai *precision* dan *recall* paling kecil dibandingkan dengan kelas lainnya, artinya model tidak bekerja dengan baik dalam mengidentifikasi data aktual dengan benar dan melakukan banyak kesalahan prediksi. Secara keseluruhan, pada kelas *multiclass imbalance data*, nilai *precision* dan *recall* semakin turun dikarenakan pada proses *training* terdapat kelas mayoritas sehingga selama pelatihan model lebih cenderung untuk mempelajari pola dan fitur kelas mayoritas sedangkan informasi yang berkaitan dengan kelas minoritas terabaikan. Hasil prediksi saat *testing* akan lebih mengikuti kelas mayoritas. Kelas mayoritas yang besar pada skenario data tidak seimbang adalah *bird eye spot*, sehingga kesalahan klasifikasi lebih banyak terjadi pada kelas *bird eye*

## BAB 5 KESIMPULAN DAN SARAN

### 5.1 Kesimpulan

Berdasarkan penelitian dan hasil pengujian yang telah dilakukan diperoleh kesimpulan sebagai berikut :

- a. Hasil *binary classification of imbalance data* dan *balance data* yang menunjukkan bahwa model dapat memprediksi dengan sangat baik daun teh sehat dan daun teh berpenyakit.
- b. Hasil *multiclass classification of balance data* memberikan informasi kesalahan klasifikasi pada kelas *antracnose* dan *bird eye spot*. Kelas *antracnose* memperoleh *recall* paling kecil sebesar 73,34% dan kelas *bird eye spot* memperoleh *precision* paling kecil sebesar 77,78%. Analisis penyebab dari kesalahan klasifikasi ini dikarenakan objek memiliki tingkat kecerahan yang hampir sama antara kelas *antracnose* dan *bird eye spot*.
- c. *Multiclass classification* memperoleh nilai *precision* dan *recall* pada kelas *antracnose* rendah sebesar 80% dan 75%, hal ini dikarenakan pada proses *training* terdapat kelas mayoritas sehingga pada proses *testing* kelas yang diprediksi akan lebih mengikuti kelas mayoritas. Kelas mayoritas pada skenario data tidak seimbang adalah *bird eye spot*, sehingga prediksi klasifikasi lebih mengikuti kelas *bird eye spot*.

### 5.2 Saran

Saran yang dapat diberikan untuk penelitian selanjutnya, khususnya bagi yang menggunakan *Convolutional Neural Network* adalah :

- a. Berdasarkan hasil penelitian di atas, data penelitian yang tidak seimbang dapat mengakibatkan nilai akurasi, *precision* maupun *recall* kecil. Hal ini bisa diatasi dengan cara mengumpulkan lebih banyak data, semakin banyak data yang dimiliki dalam melatih model maka akan semakin baik kinerja model. Selain itu, dapat dilakukan penyeimbangan data. Strategi yang umum dilakukan adalah *undersampling* dan *oversampling*. *Undersampling* merupakan menurunkan jumlah data pada kelas mayoritas sehingga sejajar dengan jumlah sampel pada kelas minoritas. dan *oversampling* untuk

meningkatkan jumlah data pada kelas minoritas sehingga susunannya sama dengan kelas mayoritas.

- b. Mencoba beberapa arsitektur, variasi parameter, dan memperbaiki kualitas gambar atau citra digital yang menjadi dataset.



## DAFTAR PUSTAKA

- Abduljabbar, R., Dia, H., Liyanage, S., & Bagloee, S. A. (2019). Applications of artificial intelligence in transport: An overview. *Sustainability (Switzerland)*, *11*(1). <https://doi.org/10.3390/su11010189>
- Agarwal, M., Singh, A., Arjaria, S., Sinha, A., & Gupta, S. (2020). ToLeD: Tomato Leaf Disease Detection using Convolution Neural Network. *Procedia Computer Science*, *167*, 293–301. <https://doi.org/10.1016/j.procs.2020.03.225>
- Albawi, S., Mohammed, T. A. M., & Alzawi, S. (2017). Understanding of a Convolutional Neural Network. *Icet*, 1–6.
- Almazroi, A. A. (2022). Survival prediction among heart patients using machine learning techniques. *Mathematical Biosciences and Engineering*, *19*(1), 134–145. <https://doi.org/10.3934/mbe.2022007>
- Asri, J. S., & Firmansyah, G. (2018). *Konferensi Nasional Sistem Informasi 2018 STMIK Atma Luhur Pangkalpinang*.
- Azurianti, A., Wulansari, R., Athallah, F. N. F., & Prijono, S. (2022). The Relation Study of Soil Nutrient to Productivity of productive Tea Plants in Pagar Alam Tea Plantation, South Sumatra. *Jurnal Tanah Dan Sumberdaya Lahan*, *9*(1), 153–161. <https://doi.org/10.21776/ub.jtisl.2022.009.1.17>
- Balde, A. M., Chhabra, M., Ravulakollu, K., Goyal, M., Agarwal, R., & Dewan, R. (2022). Iris Disease Detection using Convolutional Neural Network. *Proceedings of the 2022 9th International Conference on Computing for Sustainable Global Development, INDIACom 2022*, 644–647. <https://doi.org/10.23919/INDIACom54597.2022.9763164>
- Bella, M. A. (2021). *Implementasi Algoritma Deep Learning Untuk Sistem Deteksi Kantuk Pada Pengemudi Menggunakan YOLO*. Universitas Islam Indonesia Yogyakarta.
- Boulent, J., Foucher, S., Théau, J., & St-Charles, P. L. (2019). Convolutional Neural Networks for the Automatic Identification of Plant Diseases. *Frontiers in Plant Science*, *10*(July). <https://doi.org/10.3389/fpls.2019.00941>
- BPS. (2020). *Statistik Teh Indonesia 2020*. BPS RI.
- Chandra Karmokar, B., Samawat Ullah, M., Siddiquee, K., & Alam, K. M. R. (2015). Tea Leaf Diseases Recognition using Neural Network Ensemble. In *International Journal of Computer Applications* (Vol. 114, Issue 17).
- Gayathri, S., Wise, D. C. J. W., Shamini, P. B., & Muthukumaran, N. (2020). Image Analysis and Detection of Tea Leaf Disease using Deep Learning.

*Proceedings of the International Conference on Electronics and Sustainable Communication Systems, ICESC 2020, Icesc*, 398–403. <https://doi.org/10.1109/ICESC48915.2020.9155850>

Hashemi, M. (2019). Enlarging Smaller Images Before Inputting Into Convolutional Neural Network: Zero-padding vs. Interpolation. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0263-7>

Hasma, Y. A., & Silfianti, W. (2018). Implementasi Deep Learning Menggunakan Framework Tensorflow dengan Metode Faster Regional Convolutional Neural Network untuk Pendeteksian Jerawat. *Jurnal Ilmiah Teknologi Dan Rekayasa*, 23(2), 89–102. <https://doi.org/10.35760/tr.2018.v23i2.2459>

Ilahiyah, S., & Nilogiri, A. (2018). Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network. *JUSTINDO (Jurnal Sistem Dan Teknologi Informasi Indonesia)*, 3(2), 49–56.

Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–15.

Kumari, R., & Kr., S. (2017). Machine Learning: A Review on Binary Classification. *International Journal of Computer Applications*, 160(7), 11–15. <https://doi.org/10.5120/ijca2017913083>

Latha, R. S., Sreekanth, G. R., Suganthe, R. C., Rajadevi, R., Karthikeyan, S., Kanivel, S., & Inbaraj, B. (2021). Automatic Detection of Tea Leaf Diseases using Deep Convolution Neural Network. *2021 International Conference on Computer Communication and Informatics, ICCCI 2021*. <https://doi.org/10.1109/ICCCI50826.2021.9402225>

Liu, B., Zhang, Y., He, D. J., & Li, Y. (2018). Identification of Apple Leaf Diseases Based on Deep Convolutional Neural Networks. *Symmetry*, 10(1). <https://doi.org/10.3390/sym10010011>

Liu, Y., Pu, H., & Sun, D. W. (2021). Efficient Extraction of Deep Image Features Using Convolutional Neural Network (CNN) for Applications in Detecting and Analysing Complex Food Matrices. *Trends in Food Science and Technology*, 113(April), 193–204. <https://doi.org/10.1016/j.tifs.2021.04.042>

Marsuni, Y. (2020). Pencegahan Penyakit Antraknosa pada Cabai Besar (Lokal: Lombok Ganal) dengan Perlakuan Bibit Kombinasi Fungisida Nabati. In *Prosiding Seminar Nasional Lingkungan Lahan Basah* (Vol. 5).

Mustakim, & Oktaviani, G. (2016). Algoritma K-Nearest Neighbor Classification Sebagai Sistem Prediksi Prestasi Mahasiswa. *Jurnal Sains, Teknologi Dan Industri*, 13(2), 195–202. <http://ejournal.uin-suska.ac.id/index.php/sitekin>

- Nafi'ah, T. C. (2016). *Klafisikasi Tingkat Ketuaan Daun Teh (Camellia Sinensis) dengan Analisis Citra Digital Menggunakan Pendekatan Analisis Warna dan Tekstur*. Universitas Brawijaya Malang.
- Ningsih, D. F. (2021). *Klasifikasi Jenis Penyakit Daun Kentang Menggunakan Convolutional Neural Network (CNN) Model Arsitektur Googlenet*. Universitas Yudharta Pasuruan.
- Nurlaeni, Y., Tita Nursinta, N., Raya, K., Riset, C.-P., Tumbuhan, K., Riset, B., Nasional, I., Program, M., Agroteknologi, S., Pertanian, F., Islam, U., Bandung, N., Kebun, J., Cibodas, R., Cimacan, D., Cipanas, K., Cianjur, K., & Barat, J. (2021). HAMA DAN PENYAKIT PADA TANAMAN HIAS CAMELIA (*Camellia* spp.) DI KEBUN RAYA CIBODAS PESTS AND DISEASES IN ORNAMENTAL PLANTS OF CAMELIA (*Camellia* spp.) AT CIBODAS BOTANIC GARDENS. In *Seminar Nasional Pertanian*.
- Paluszek, M., Thomas, S., & Ham, E. (2022). Practical MATLAB Deep Learning. In *Practical MATLAB Deep Learning*. <https://doi.org/10.1007/978-1-4842-7912-0>
- Ponmurugan, P., Saravanan, D., & Ramya, M. (2010). Culture and Biochemical Analysis of a Tea Algal Pathogen, *Cephaleuros Parasiticus*. *Journal of Phycology*, 46(5), 1017–1023. <https://doi.org/10.1111/j.1529-8817.2010.00879.x>
- Putri, R. K. S. C. (2018). *Implementasi Deep Learning Menggunakan Metode Convolutional Neural Network untuk Klasifikasi Gambar*. Universitas Islam Indonesia Yogyakarta.
- Rizal, A. S. (2022). *Convolutional Neural Network (CNN) untuk Memprediksi Kadar Hemoglobin pada Gambar Telapak Tangan*. Universitas Jember.
- Rosyidah, E. A., Hadi, A. F., & Dewi, Y. S. (2023). The Classification of Tea Leaf Disease Using CNN Image Classifier. *ICONSMAL*, 89–112. <https://doi.org/10.2991/978-94-6463-174-6>
- Selvi. (2016). *Inventarisasi Penyakit pada Tanaman Karet (Hevea brasiliensis Muell Arg.) di PT PP London Sumatra Indonesia, TBK Palangisang Estate Kabupaten Bulukumba*. Politeknik Pertanian Negeri Pangkep.
- Suartika, I. W., Wijaya, A. Y., & Soelaiman, R. (2016). Klafisikasi Citra Menggunakan Convolutional Neural Network (CNN) Pada Caltech 101. *Jurnal Teknik ITS*, 5(1), 65–69.
- Swastika, W., Nur, A. W., & Kelana, O. H. (2019). Monitoring Ruang Untuk Deteksi Manusia Berbasis CNN Dengan Fitur Push Notification. *Teknika*, 8(2), 92–96. <https://doi.org/10.34148/teknika.v8i2.166>