


**LAPORAN AKHIR PENELITIAN SAINTEKS  
FAKULTAS TEKNIK UNIVERSITAS SRIWIJAYA**



**IDENTIFIKASI PENYAKIT PADA TANAMAN PADI DENGAN  
METODE DEEP LEARNING**

**OLEH :**

**IRMAWAN., SSi, MT (KETUA)  
GUSTINI., ST, MT (ANGGOTA)  
HERA HIKMARIKA., ST, Meng (ANGGOTA)**

**Dana PNPB Fakultas Teknik Universitas Sriwijaya Tahun Anggaran 2023  
SP DIPA-023.17.2.677515/2023 tanggal 30 Nopember 2022  
Sesuai dengan Surat Keputusan Rektor  
SK 0601/UN9.FT/TU.SK/2023  
Tanggal 07 Juli 2023**

**JURUSAN TEKNIK ELEKTRO  
FAKULTAS TEKNIK  
UNIVERSITAS SRIWIJAYA  
2023**

## HALAMAN PENGESAHAN LAPORAN AKHIR

### PENELITIAN/PENGABDIAN SKEMA SAINTEKS FT TAHUN 2023

1. Judul Penelitian/Pengabdian : Identifikasi Penyakit Pada Tanaman Padi Dengan Metode Deep Learning
2. Bidang Penelitian/Pengabdian : Penelitian SAINTEKS FT TAHUN 2023
3. Ketua Peneliti
  - a. Nama Lengkap : IRMAWAN, S.Si., MT
  - b. NIDN/NIDK : 0017097405
  - c. Pangkat dan Golongan : Penata Tk I / III d
  - d. Fakultas/Jurusan/Prodi : Teknik/Teknik Elektro
  - e. Telepon/HP/E-mail : 081373331366/irmawan@unsri.ac.id
- 4 Jumlah Anggota Peneliti :
  - a. Nama Anggota I : Gustini, S.T, MT  
NIDN/NIDK : 0004087801
  - b. Nama Anggota II : Hera Hikmarika, ST, M.Eng  
NIDN/NIDK : 0007127801
  - c. Nama Anggota III :  
NIDN/NIDK :
5. Tempat/Lokasi Penelitian : Laboratorium Dasar Elektronika dan Rangkaian Listrik
- 6 Jangka Waktu Penelitian : Satu Tahun
7. Jumlah Dana yang Disetujui : 24.250.000,-
8. Target Luaran TKT : TKT 3
9. Nama, NIM dan Jurusan/  
Program Studi/BKU  
Mahasiswa yang Terlibat
  1. Salman Al Farizi Harahap  
(NIM : 03041282025085)
  2. Ahmad Setyanto  
(NIM : 03041382025099)

Mengetahui  
Ketua UPPM FT,

Dr. Rosidawani, ST, M.T.  
NIP. 197605092000122001

Indaralaya, Nopember 2023  
Ketua Peneliti,



Irmawan, S.Si., M.T  
NIP. 197409172000121002

Indaralaya, November 2023  
Dekan Fakultas Teknik UNSRI

Prof. Dr. Eng. Ir. H. Joni Arliansyah, M.T.  
NIP. 196706151995121002

## RINGKASAN DAN SUMMARY

Kesalahan dalam mengidentifikasi penyakit pada tumbuhan padi bisa menyebabkan potensi kegagalan panen meningkat hingga 18%-80% menurut data kementerian pertanian Indonesia. Hal ini bisa disebabkan karena masih kurangnya ekspert di bidang pertanian. Oleh sebab itu teknologi bisa menjadi solusi dari masalah kekurangan ekspert, terutama dengan memanfaatkan deep learning. Penelitian terbaru dalam bidang deep learning menggunakan neural network telah mencapai peningkatan yang luar biasa, terutama pada bidang pertanian.

Penelitian dengan memanfaatkan deep learning yaitu faster rcnn pernah dilakukan untuk mendeteksi apakah padi mengidap penyakit false smut atau bukan. Namun pemanfaatan object detection pada penelitian sebelumnya belum optimal karena hanya untuk binary classification. Pada penelitian ini dengan menggunakan faster rcnn untuk identifikasi penyakit pada tanaman padi menggunakan 13.876 data. Dengan 10 kelas data. Selanjutnya data di anotasi dan di resize dengan ukuran 512x512, baru kemudian dilakukan training. Dengan menggunakan backbone, dan pretrained model resnet50\_fpn, dan Fast rcnn sebagai predictor pada layer terakhirnya. Model mampu mendeteksi penyakit spesifik di area yang diidap. Disamping itu juga model mampu mendeteksi penyakit lebih dari satu pada tanaman padi. Dengan hasil akhir dari pengujian akurasi sebesar 91.35% dan loss 0.22%.

Kata kunci :deep learning, neural network, faster rcnn, pretrained, resnet50.

## PRAKATA

Puji dan syukur penulis panjatkan kehadiran Allah SWT atas hidayah dan kekuatan yang diberikan sehingga penelitian dosen muda dengan judul Identifikasi Penyakit Pada Tanaman Padi Dengan Metode Deep Learning dapat diselesaikan.

Pada kesempatan ini juga penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Bapak Prof. Dr. Eng. Ir. H. Joni Arliansyah, M.T. sebagai Dekan Fakultas Teknik Unsri
2. Ibu Dr. Rosidawani, ST, M.T. sebagai Ketua UPPM FT Unsri
3. Bapak Dr. M. Abu Bakar Sidiq, ST, M.Eng sebagai ketua jurusan Teknik Elektro Unsri
4. Ibu Dr. Eng, Suci Dwijayanti, ST, MT sebagai sekretaris jurusan Teknik Elektro Unsri
5. Seluruh rekan Staf Pengajar di Jurusan Teknik Elektro Unsri
6. Seluruh Karyawan dan Laboran di Jurusan Teknik Elektro Unsri

Sekalipun masih banyak kekurangan yang ada dalam penelitian Sainteks ini, penulis tetap berharap penelitian ini dapat bermanfaat bagi yang memerlukan.

Inderalaya, 21 Nopember 2023

Penulis

## DAFTAR ISI

<b>COVER</b>	i
<b>LEMBAR PENGESAHAN</b>	ii
<b>RINGKASAN DAN SUMMARY</b>	iii
<b>PRAKATA</b>	iv
<b>DAFTAR ISI</b>	v
<b>DAFTAR GAMBAR</b>	vii
<b>DAFTAR TABEL</b>	viii
<b>DAFTAR LAMPIRAN</b>	ix
<b>BAB I. PENDAHULUAN</b>	1
1.1. Latar Belakang	1
1.2. Perumusan Masalah	3
1.3. Tujuan dan Manfaat Penelitian	3
<b>BAB II. TINJAUAN PUSTAKA</b>	4
2.1. Deep Learning	8
2.2. Object Detection	5
2.3. Convolutional Neural Network	9
2.4. R-CNN	11
2.1. Fast R-CNN	11
2.5. Faster RCNN	12
2.6. Propeller	13
2.7. Resnet	13
2.8. Web Service	14
2.9. Jenis Penyakit Padi	15
<b>BAB III. METODE PENELITIAN</b>	20
3.1. Pengumpulan Data	20
3.2. Pelabelan Data	21

3.3. Resize Gambar	22
3.4. Training Data	22
3.5. Model dan Testing	22
3.6. Evaluasi Model	23
3.7. Aplikasi Mobile	23
<b>BAB IV. HASIL DAN PEMBAHASAN</b>	<b>24</b>
4.1. Pengumpulan Data	25
4.2. Pelabelan Data	26
4.3. Resize Gambar	26
4.4. Training Data	26
4.5. Model dan Testing	27
4.6. Evaluasi Model	27
4.7. Hasil Training dan Evaluasi	27
<b>BAB V. KESIMPULAN DAN SARAN</b>	<b>29</b>
5.1. Kesimpulan	29
5.2. Saran	30
<b>DAFTAR PUSTAKA</b>	<b>31</b>
<b>LAMPIRAN</b>	<b>34</b>

## DAFTAR GAMBAR

<b>Gambar 2.1</b>	Arsitektur jaringan syaraf tiruan	8
<b>Gambar 2.2.</b>	Perbedaan object detection kiri dan image classification kanan	9
<b>Gambar 2.3.</b>	Arsitektur CNN	10
<b>Gambar 2.4.</b>	R-CNN	11
<b>Gambar 2.5.</b>	Residual Block	14
<b>Gambar 2.6.</b>	Arsitektur Web Service	15
<b>Gambar 3.1.</b>	Metodologi penelitian	20
<b>Gambar 4.1.</b>	Diagram Alir penelitian	25
<b>Gambar 4.2.</b>	Arsitektur MobileNetV3	28
<b>Gambar 4.3.</b>	Grafik Peningkatan Akurasi dan Penurunan Loss	28

## DAFTAR TABEL

<b>Tabel 2.1</b> Penelitian-penelitian terkait penyakit tanaman	5
<b>Tabel 2.2.</b> Perbandingan kecepatan fast r-cnn vs rcnn	12
<b>Tabel 3.1.</b> Dataset Paddy Disease Classification	21



## DAFTAR LAMPIRAN

<b>Lampiran 1.</b> Makalah Avoer 15	34
<b>Lampiran 2.</b> Sertifikat Avoer 15 sebagai penulis	34

# **BAB I**

## **PENDAHULUAN**

### **1.1. Latar Belakang**

Pertanian merupakan salah satu sektor terpenting bagi bangsa Indonesia. Pertanian menjadi sektor penyedia ketahanan pangan masyarakat, membuka lapangan pekerjaan, menjadi instrumen pengentasan kemiskinan, serta sumber pendapatan masyarakat. Hal tersebut didukung dengan kontribusi pertanian yang sangat signifikan terhadap pencapaian tujuan program Sustainable Development Goals (SDG's) kedua, yaitu tidak ada kelaparan, mencapai ketahanan pangan, perbaikan nutrisi, serta mendorong budidaya pertanian yang berkelanjutan. Selain itu sektor pertanian memberikan kontribusi terhadap perekonomian Indonesia, dimana kehutanan, dan perikanan menyumbang sebesar 13,28 persen. Namun pada tahun 2021, hasil Survei KSA menyatakan bahwa luas lahan panen dan produksi padi di Indonesia mengalami penurunan sebanyak 245,47 ribu hektar (2,30 %) serta 140,73 ribu ton (0,45 %) dibandingkan dengan produksi beras tahun 2020 (Khasanah & Astuti, 2022). Adanya penurunan lahan panen serta hasil produksi tersebut tentu akan memberikan dampak bagi ketahanan pangan serta perekonomian Indonesia kedepannya.

Produksi pertanian, perencanaan suksesi, penerus, dan penggunaan lahan pertanian secara signifikan dipengaruhi oleh populasi pertanian yang menua (Zou et al., 2018). Data yang dikutip dari katadata.co.id menyatakan bahwa populasi petani di Indonesia hanya sekitar 28,5% pada 2019, padahal tiga dekade sebelumnya populasinya mencapai 55,5% dari total angkatan kerja. Ditinjau dari usia para petani, dominasi usia adalah pada 35-55 tahun (Yudhistira, 2022). Oleh sebab itu lambat laun jumlah para petani akan semakin berkurang seiring waktu apabila regenerasi petani tidak dilanjutkan. Regenerasi petani menjadi syarat penting untuk memastikan keberlanjutan pertanian di Indonesia (Sidharta et al., 2020). Hasil sebuah peneliti menyatakan bahwa krisis petani muda di Indonesia adalah akibat dari kecenderungan keinginan pemuda untuk bekerja di sektor industri dengan penggunaan teknologi masa kini dibanding bekerja di sektor pertanian yang dianggap masih menggunakan teknologi tradisional (Arvianti et al., 2019). Dengan demikian adanya modernisasi pada sistem pertanian merupakan salah satu hal yang dapat menarik minat para pemuda ke sektor pertanian.

Di era modernisasi saat ini segala hal telah terintegrasi dengan menggunakan mesin dan tidak bekerja dengan hanya mengandalkan kekuatan manusia saja, tentu sektor pertanian juga diarahkan untuk disesuaikan dengan era saat ini. Modernisasi pertanian juga sejalan dengan salah satu isu pertanian yang dibahas pada presidensi G20 2022 dimana indonesia menjadi tuan rumah. Kepala Biro Kerja Sama Luar Negeri Kementerian Pertanian, Ade Candradijaya yang dikutip oleh Republica.co.id menyatakan bahwa tiga isu prioritas yang diangkat dalam deklarasi para menteri pertanian yaitu membangun sistem pangan dan pertanian yang tangguh dan berkelanjutan, mempromosikan perdagangan pangan yang terbuka, adil, dan dapat diprediksi serta transparan, Serta mendorong bisnis pertanian yang inovatif melalui pertanian digital untuk memperbaiki kehidupan petani di wilayah pedesaan (Zuraya, 2022). Pada kenyataannya beberapa kegiatan di sektor pertanian saat ini perlahan sudah mengarah ke modernisasi pertanian seperti proses pembajakan sawah, penanaman, padi, pemupukan, hingga panen yang sudah menggunakan alat bantu mesin yang memadai. Namun mesin hanya membantu, petani tetap menjadi orang yang mengetahui kondisi lahannya serta kualitas sawahnya sehingga kegiatan pengecekan kualitas padi masih dilakukan secara manual hingga saat ini. Pengecekan tersebut tentu sangat penting mengingat 25% gagal panen padi terjadi akibat penyakit daun padi (Nuryanto, 2018). Pengecekan secara manual akan menghabiskan waktu yang cukup lama sesuai luas lahan, selain itu diagnosa penyakit padi yang dilakukan oleh petani sendiri tentu tidak akurat sehingga sampai saat ini gagal panen akibat penyakit padi masih terus terjadi. Oleh sebab itu diperlukan sistem modernisasi pertanian untuk mendeteksi penyakit pada tanaman padi untuk memperoleh hasil panen yang berkualitas dan mengefisienkan sistem pertanian saat ini.

Teknologi saat ini sudah memunculkan berbagai kemudahan salah satunya sistem yang disebut dengan artificial intelligence. Artificial Intelligence atau kecerdasan buatan adalah sistem komputer yang mampu melakukan tugas-tugas yang biasanya membutuhkan kecerdasan manusia. Teknologi ini dapat membuat keputusan dengan cara menganalisis dan menggunakan data yang tersedia di dalam sistem (Sobron & Lubis, 2021), dengan sistem ini dapat direncanakan sebuah alat untuk mendeteksi penyakit pada pertanian dengan memprogramnya untuk mengenali berbagai penyakit pada pertanian. Oleh sebab itu penulis memiliki gagasan untuk menciptakan Handy Paddy Doctor yang merupakan aplikasi android berbasis artificial intelligence untuk

mendeteksi penyakit pada tanaman padi. Alat ini dirancang untuk dapat mendeteksi kondisi normal padi dan 9 penyakit tanaman padi yang paling umum dan menyebabkan dampak besar bagi kegagalan panen hingga saat ini, 9 penyakit tanaman padi tersebut yaitu *Bacterial Leaf Blight*, *Bacterial leaf Streak*, *Bacterial Panicle Blight*, *Blast*, *Brown Spot*, *Dead Heart*, *Downy Mildew*, *Hispa*, dan *Tungro*. Sistem artificial intelligence ini nantinya akan diintegrasikan dengan aplikasi android yang cukup umum dan mudah untuk diakses oleh para petani mengingat penggunaan android sudah merambah ke seluruh kalangan termasuk para petani saat ini. Inovasi ini diharapkan dapat memberikan kemudahan bagi para petani muda dalam kegiatan pengecekan tanaman padi sehingga jumlah gagal panen dapat diminimalisir serta akan terjadi peningkatan hasil pertanian padi di Indonesia.

## **1.2. Perumusan Masalah**

Adapun perumusan masalah yang akan dikerjakan dalam penelitian ini adalah :

1. Bagaimana merancang dan memprogram sistem untuk identifikasi penyakit pada tanaman padi.
2. Bagaimana menerapkan sistem operasi android sebagai platform untuk mengaplikasikan algoritma Deep Learning untuk aplikasi identifikasi penyakit pada tanaman padi.
3. Bagaimana penerapan algoritma Deep Learning untuk aplikasi identifikasi penyakit pada tanaman padi.

## **1.3. Tujuan Penelitian**

2. Merancang sistem berbasis Android yang dapat secara otomatis mengidentifikasi dengan cepat penyakit pada tanaman padi
3. Merancang algoritma cerdas berbasis deep learning yang dapat mengidentifikasi dengan cepat penyakit pada tanaman padi.

## BAB II TINJAUAN PUSTAKA

Penelitian terkait penyakit tanaman terdahulu mengacu pada Table 2. 1, terdapat sub tema penelitian, algoritma yang digunakan, jenis penyakit, serta jenis tanaman yang di infeksi. Penelitian tentang deteksi penyakit dan pengenalan jenis hama pada tumbuhan tomat dengan memanfaatkan deep learning pernah dilakukan untuk 9 kelas yang terdiri dari penyakit dan hama (Fuentes, Alvaro, 2017) dengan jumlah dataset sebanyak 5000 data yang merupakan dataset public (Plant Village dataset).

Dengan hasil model mampu mendeteksi 9 kelas yang berbeda walaupun resolusi gambar tidak sama. Penelitian lain menggunakan Faster R-CNN dengan kombinasi Firefly Chaos teory Maximum dan Kmeans (FCM-KM) untuk mendeteksi penyakit pada tanaman padi dengan 3 kelas data dilakukan oleh Guoxiong dkk, dengan penambahan proses masking gambar pada layer terpisah untuk mengurangi noise, kemudian baru dimasukan ke Faster R-CNN (Zhou et al., 2019). Namun disayangkan pada penelitian ini ada kegagalan deteksi terjadi ketika terdapat multi area penyakit dalam satu gambar.

Pada tahun 2020 penelitian untuk mendeteksi apakah tumbuhan padi mengidap penyakit false smut atau bukan, dengan menggunakan algoritma faster r-cnn (Sethy et al., 2020) juga pernah dilakukan, sayangnya secara teori ini masih bisa disimpulkan sebagai binary classification + localization, dengan kata lain fungsi dari *object detection* belum bisa di maksimalkan. Selanjutnya penelitian yang hampir mirip dengan penelitian sethy dkk, juga pernah dilakukan oleh Liang dkk yaitu mengenali apakah tumbuhan padi terinfeksi penyakit blast atau bukan (Liang et al., 2019). Penelitian lain ditahun yang sama pada tahun 2019 M.al-amin dkk, menggunakan CNN untuk memprediksi apakah tumbuhan padi tergolong kedalam 4 kelas penyakit Bacterial Leaf, Blight, Blast Leaf Smut, atau Brown Spot dengan akurasi mencapai 97.40% (Al-Amin et al., 2019).

Table 2. 1 Penelitian-penelitian terkait penyakit tanaman

No.	Subtema	Algoritma	Jenis penyakit	Jenis Tanaman	Author
1.	A Robust Deep-Learning-Based Detector for Real-Time Tomato Plant Diseases and Pests Recognition	Faster RCNN VGG-16, Single Shoot Detector, R-FCN	- Bacterial spot - Early Blight - Late Blight - Leaf Mold - Septoria Leaf spot - Spider Mite - Target spot - Yellow Leaf - Mosaic Virus	Tomat	Fuentes, Alvaro, 2017
2.	Rapid Detection of rice disease based on FCM-KM and Faster R-CNN fusion	FCM-KM and Faster R-CNN Fusion	- Rice Blast - Bacterial Blight - Blight	Padi	Guoxiong et all
3.	Rice False smut Detection based on Faster-RCNN	Faster RCNN, False Smut	False Smut	Padi	Sethy et al
4.	Rice blast disease recognition using a deep convolutional neural network	Local Binary Pattern Histogram	Blast Disease	Padi	Liang et al
5.	Prediction of rice disease	CNN	- Bacterial Leaf Blight	Padi	Al-Amin et al

from leaves using deep convolution neural network towards a digital agricultural system			- Blast - Leaf Smut - Brown Spot		
--------------------------------------------------------------------------------------------------------------	--	--	----------------------------------------	--	--

Banyak faktor yang dapat menyebabkan gagal panen dalam produktivitas tanaman padi, salah satunya yaitu hama dan penyakit daun padi (Soleh, 2020). Sebanyak 25% gagal panen padi disebabkan oleh penyakit daun padi (Nuryanto, 2018), untuk itu perlu upaya mengurangi resiko gagal panen dengan cara mendeteksi citra daun padi secara dini (Saputra et al., 2020).

Sebagian besar penyakit daun padi disebabkan oleh patogen/parasit, penyakit daun busuk, bakteri hawar daun dan bercak coklat merupakan penyakit yang paling banyak menyerang daun padi (Pothen & Pai, 2020) Penyakit padi yang paling umum adalah blas daun, bercak coklat, hawar daun (Chawathe, 2020). Proses klasifikasi dalam mendeteksi citra penyakit daun padi perlu dibangun dalam sebuah aplikasi yang menerapkan metode *deep learning*, agar dengan mudah para petani pemula dapat dengan cepat mengetahui jenis penyakit daun padi tersebut. Banyak metode *deep learning* mampu menyeleksi fitur yang kompleks dan cepat namun algoritma *convolutional neural network (CNN)* merupakan algoritma yang paling efisien dalam mengekstraksi fitur (Rahman et al., 2020).

Penelitian terkait mengenai penyakit daun padi sudah banyak dilakukan sebelumnya, seperti penelitian (Saputra et al., 2020) klasifikasi penyakit daun padi menggunakan KNN dan ekstraksi fitur GLCM didapat akurasi 65.83% dan kappa 0.485, Penelitian (Jani & Noor, 2018) melakukan klasifikasi penyakit daun padi dengan ekstraksi fitur GLCM dan algoritma backpropagation didapat akurasi 80%. Penelitian (Phadikar & Sil, 2008) melakukan identifikasi penyakit daun padi menggunakan algoritma zooming dalam ekstrak gambar dan algoritma neural network menghasilkan klasifikasi penyakit daun padi dengan baik. Penelitian (Phadikar, Sil, & Das, 2013)

klasifikasi penyakit daun padi dengan membandingkan dua algoritma yaitu Naive Bayes dan Support Vector Machine didapat akurasi sebesar 79,5% dan 68.1%, Penelitian (Minarni & Warman, 2017) membuat aplikasi sistem pakar identifikasi penyakit daun padi menggunakan algoritma CBR menghasilkan akurasi 82,69%. Penelitian (Yang et al., 2008) melakukan ekstrak fitur penyakit daun padi dengan algoritma Neural Network, penelitian ini menunjukkan bahwa algoritma Neural Network dapat digunakan dalam klasifikasi penyakit daun padi.

Kebaharuan dalam penelitian ini akan membahas sebuah pengembangan dengan algoritma CNN dan arsitektur *MobileNet* dengan *feature extraction* dan *feature map* untuk klasifikasi sembilan penyakit daun padi yaitu *Bacterial Leaf Blight*, *Bacterial leaf Streak*, *Bacterial Panicle Blight*, *Blast*, *Brown Spot*, *Dead Heart*, *Downy Mildew*, *Hispa*, dan *Tungro*, *feature map* akan dapat mengindikasikan klasifikasi beberapa penyakit daun padi yang dapat menyebabkan penurunan nilai makanan.

## 2.2. Deep Learning

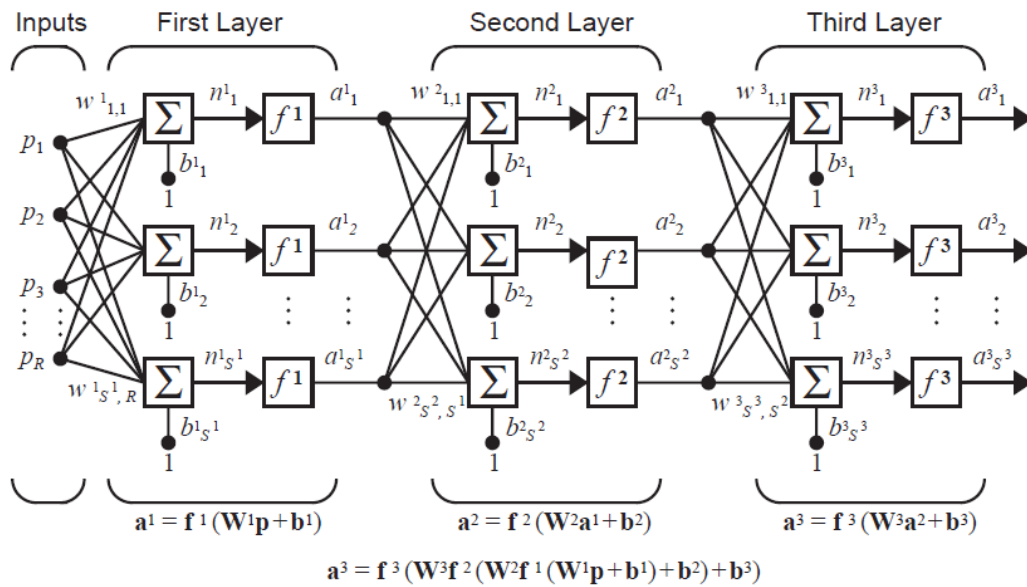
Deep Learning sebenarnya subbidang dari *machine learning* (Purwins et al., 2019) yang pada awal mulanya terinspirasi oleh struktur otak manusia. Struktur otak tersebut dinamakan Artificial Neural Networks atau disingkat ANN. Pada dasarnya, merupakan jaringan saraf yang memiliki tiga atau lebih ANN. *Deep learning* mampu belajar dan beradaptasi untuk sejumlah data yang tak terstruktur seperti gambar dan audio, serta mampu menyelesaikan permasalahan yang sulit bisa dibandingkan algoritma *machine learning* lainnya. Sementara itu deep learning pertama kali diteorikan pada 1980-an, namun baru sekarang mulai populer, karena ada dua alasan utama mengapa hal itu bisa terjadi:

1. Deep learning membutuhkan sejumlah besar data berlabel. Misalnya, pengembangan mobil tanpa pengemudi membutuhkan jutaan gambar dan ribuan jam video.
2. Deep learning membutuhkan daya komputasi yang besar. GPU performa tinggi memiliki arsitektur paralel yang efisien untuk deep learning. Ketika dikombinasikan dengan cluster atau komputasi awan, ini memungkinkan tim pengembangan untuk mengurangi waktu pelatihan untuk jaringan deep learning dari minggu ke jam atau kurang.

Sebagian besar metode deep learning menggunakan arsitektur jaringan saraf. Karena itu model deep learning sering disebut sebagai deep neural network. Seperti



yang ditunjukkan pada Gambar 3. 1 node/cell terlihat dibedakan menjadi 3 bagian. Pertama input layer, hidden layer, dan output layer. Hidden layer pada gambar mempunyai kedalaman yang lebih dalam dibanding 2 layer lainnya. Istilah "dalam" biasanya mengacu pada jumlah lapisan tersembunyi di jaringan saraf. Jaringan saraf tradisional hanya berisi 2-3 lapisan tersembunyi, sedangkan deep neural network dapat memiliki sebanyak 150 lapisan. Dikatakan deep learning apabila suatu neural network ini memiliki lebih dari satu hidden layer.



Gambar 2. 1 Arsitektur jaringan syaraf tiruan

Deep learning berbeda dengan machine learning tradisional. Dalam machine learning tradisional, pemrogram harus sangat spesifik memberi tahu komputer jenis hal apa yang harus dicari untuk mengambil suatu keputusan dalam output-nya (Jordan & Mitchell, 2015; J. Yu et al., 2018). Sedangkan deep learning membangun set fitur (extraction feature) secara otomatis tanpa perlu dilakukan secara manual oleh manusia untuk digunakan dalam mengambil suatu keputusan atau prediksi dalam output-nya (LeCun et al., 2015).

### 2.3. Object Detection

Object detection adalah sebuah teknik dari computer vision yang bekerja untuk mengidentifikasi dan melokalisasi objek dalam sebuah gambar ataupun video (Pathak et al., 2018). Object detection secara umum juga akan memberikan output berupa

bounding box. Kemudian bounding box tersebut juga akan menyesuaikan dengan lokasi objek yang diprediksi oleh model. Object detection berbeda dengan image classification. Dimana image classification akan mengklasifikasi sebuah gambar berdasarkan kelas yang paling dominan. Baru kemudian akan memberikan label terhadap gambar dengan score yang paling tinggi. Sedangkan object detection memberikan lokasi objek berada berupa koordinat yang hasil akhirnya bisa lebih dari satu kelas/objek. Kemudian akan diberikan koordinat atau bounding box pada masing-masing kelas sesuai hasil prediksinya. Pada Gambar 2. 3 terdapat perbedaan antara image classification dan object detection.




Gambar 2.2. Perbedaan object detection kiri dan image classification kanan

Dimana dengan penyakit yang sama object detection memberikan persis area lokasi penyakit dengan bounding box. Sedangkan image classification hanya memberikan prediksi kelas dengan skor paling tinggi.

#### 2.4. Convolutional Neural Network

Convolutional Neural Network (CNN) adalah salah satu bagian dari neural network yang biasa digunakan pada data gambar (O'Shea & Nash, 2015). CNN selain untuk klasifikasi juga bisa digunakan untuk mendeteksi dan mengenali object pada sebuah gambar. Convolutional Neural Network telah digunakan sebagai *framework deep learning* yang terinspirasi oleh *visual cortex hewan*. Awalnya telah banyak digunakan untuk tugas klasifikasi pada sebuah gambar. Tetapi sekarang penelitiannya

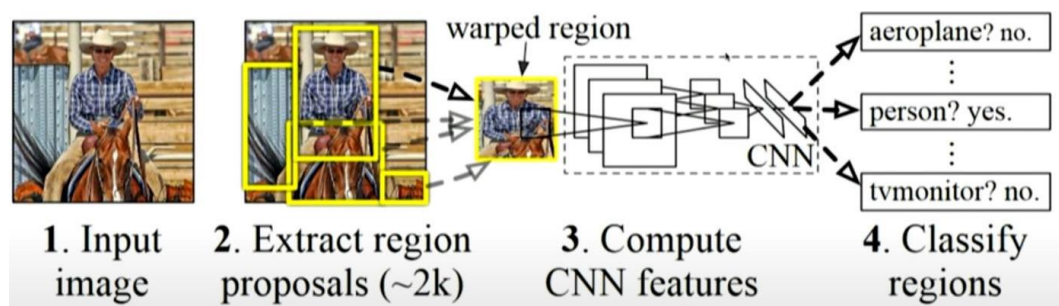
telah mulai digunakan di domain yang berbeda seperti, *object detection*, *object tracking*, *pose estimation*, *text detection and recognition*, *action recognition*, dan banyak lagi bidang-bidang lainnya (Oberweger et al., 2015). Pada Gambar 2. 4 dijelaskan bagaimana cara kerja dari Convolutional Neural Network. Convolutional Neural Network (CNN) yang pada dasarnya terdiri dari 3 lapisan yaitu *convolutional layer*, *pooling layer*, dan *fully connected layer*. Dimana setiap layer mempunyai fungsi yang berbeda dalam memproses data. Secara garis besar bisa dikelompokkan menjadi 2 bagian yaitu *feature extraction* dan *classification*. Pada bagian *feature extraction*, *convolution layer* yang merupakan *layer* bertanggung jawab untuk melakukan ekstraksi fitur yang kemudian hasil *output*-nya dikontrol oleh fungsi aktivasi. Dimana hasil dari outputnya disebut dengan *feature map*. Kemudian *pooling layer* yang bertugas untuk mereduksi ukuran *fitur map* yang telah dihasilkan oleh *convolution layer*. Tujuannya untuk mengambil fitur yang signifikan biasanya dengan menggunakan *max pooling*, atau *average pooling*. Sedangkan pada *classification* yang bertanggung jawab adalah *fully connected layer*. Agar data bisa diproses pada bagian ini data terlebih dahulu harus diubah menjadi data satu dimensi (*flatten*). Kemudian baru akan di masukan ke *output activation* untuk menentukan probabilitas yang paling tinggi .



Gambar 2.3. Arsitektur CNN

## 2.5. R-CNN

Pada tahun 2014 grup peneliti dari UC Berkeley mengembangkan sebuah *Deep Convolutional network* yang dinamakan R-CNN yang mampu mendeteksi 80 object yang berbeda (Zhang et al., 2014). Ketika Girshik dkk menggabungkan *region proposal* dan CNNs, yang kemudian dinamakan dengan R-CNN. Jika dibandingkan dengan teknik *object detection* biasa perbedaannya hanya pada ekstraksi feature yang menggunakan CNN. Mengacu pada Gambar 2. 10 ketika proses gambar dimasukan sebagai input, *selective search algorithm* men-generate area sebanyak 2000, kemudian gambar akan di *crop* untuk dimasukan kedalam CNN dan SVM (*support vector machine*) pada Gambar 2. 11. Dalam prosesnya akan dilakukan *feature extraction* sampai dengan classification dan pada bagian akhir penentuan klasifikasi setiap objek yang telah melewati *features extraction*.



Gambar 2.4. R-CNN<sup>7</sup>

## 2.6. Fast R-CNN

Fast R-CNN adalah object detector yang di kembangkan oleh **Ross Girshick**, seorang facebook ai Researcher dan *former* Microsoft Researcher. Fast R-CNN datang untuk memperbaiki beberapa issue pada RCNN. Dengan nama Fast R-CNN karena lebih cepat bila dibandingkan dengan R-CNN (Girshick, 2015). Beberapa perbaikan dengan yang di hadirkan Fast R-CNN sebagai berikut.

1. Menghadirkan layer baru dengan nama **ROI Pooling** dengan panjang fitur ekstraksi yang sama pada setiap vektor proposal digambar yang sama.
2. Dibandingkan dengan R-CNN, yang mempunyai *multiple stages* (*region proposal generation*, *feature extraction*, dan *classification* dengan menggunakan SVM). Fast R-CNN membuat model yang hanya mempunyai satu stage.

3. Fast R-CNN berbagi komputasi (*convolutional layer calculation*) dengan semua proposal (ROIs) dibanding dengan melakukan kalkulasi di setiap proposal secara independen. Hal ini bisa diselesaikan dengan menggunakan **ROI POOLING layer**, yang membuat **Fast R-CNN** bisa lebih cepat bila dibandingkan dengan **R-CNN**.
3. Fast R-CNN lebih cepat dibandingkan R-CNN, pada Table 2. 2 menjelaskan perbandingan yang dilakukan meliputi *training time*, *test time per image*, serta peningkatan kecepatan dari Fast R-CNN dibandingkan dengan R-CNN.

Table 2.2. Perbandingan kecepatan fast r-cnn vs rcnn<sup>9</sup>

	R-CNN	Fast R-CNN
Training Time	84 hours	9.5 hours
Speed-up	1x	8.8 x
Test time per image	47 seconds	0.32 seconds
Speed-up	1x	146x

## 2.6. Faster RCNN

Berawal dari masih kurangnya kecepatan dalam deteksi objek yang dilakukan oleh algoritma yang berbasiskan region proposal, menjadi motivasi awal Shaoqing ren dkk, untuk mengusulkan metode baru. Dimana pada algoritma fast R-CNN waktu yang dibutuhkan masih sekitar ~2 detik per gambar. Hal ini belum memungkinkan untuk mendeteksi objek secara realtime. Karenanya dibutuhkan algoritma yang bisa melakukan deteksi yang kurang dari 1 detik sehingga bisa diterapkan untuk frame persecond-nya. Sehingga pada saat itulah dikenalkan Region Proposal Network (RPN). Dimana tidak memerlukan selective search lagi dalam proses training (Ren et al., 2015). Hal ini bisa dilakukan dengan cara mengganti selective search menggunakan RPN. RPN bekerja dengan *sharing layer* secara parallel dengan *feature extractor* yang ada. sehingga bisa di klaim *cost free*. Kemudian sebagai detector tetap menggunakan seperti Fast R-CNN detector.

Arsitektur dari Faster R-CNN terdiri dari 3 bagian berikut:

1. Feature extractor, berupa VGG-16, bisa diganti dengan arsitektur cnn lainnya. Pada penelitian ini menggunakan Resnet\_50\_fpn
2. RPN untuk melakukan generate proposal
3. Fast R-CNN untuk mendeteksi object yang berada di *proposed region*.


## 2.7. Resnet

Dalam beberapa tahun terakhir terobosan dalam bidang computer vision terutama dalam pemanfaatan Convolutional Neural Network telah mendapatkan hasil yang baik terutama dalam bidang image classification dan image recognition (He et al., 2015). Untuk mendapatkan hasil yang baik para peneliti cenderung membuat deep neural network lebih dalam dengan cara menambahkan lebih banyak layer untuk menyelesaikan masalah yang lebih kompleks dan meningkatkan kinerja di bidang image recognition/classification (Zhong et al., 2017) . akan tetapi dengan semakin banyaknya layer pada deep neural network menyebabkan semakin sulit untuk di training dan mulai mengalami saturasi dan penurunan pada akurasi.

Resnet merupakan singkatan dari *Residual Network* yang mengacu kepada *neural network* yang dikenalkan oleh Kaiming he pada tahun 2015 pada *paper* yang berjudul “Deep Residual Learning for Image Recognition” (He et al., 2015). Dalam beberapa kasus penambahan layer pada *deep neural network* meningkatkan akurasi dan performa. Anggapan dengan mempunyai layer dengan kedalaman yang lebih banyak juga akan secara *progresif* akan mampu mempelajari fitur yang lebih kompleks. sebagai contoh dalam bidang *image recognition* dengan layer pertama digunakan untuk mendeteksi sudut dan layer kedua mengidentifikasi tekstur, sedangkan pada layer ketiga digunakan untuk mendeteksi object dan lainnya. Akan tetapi ditemukan *threshold maximum* pada kedalaman *layer*. Khususnya model *Convolutional Neural Network* tradisional. Masalah akibat kedalaman *layer* pada *neural network* biasanya dikenal dengan *Vanishing Gradient / Exploding gradient* (Zhong et al., 2017).

Permasalahan *Vanishing Gradient dan Exploding Gradient* yang menghambat konvergen dari awal bisa diatasi dengan proses normalisasi dan inisialisasi. Sedangkan penambahan normalisasi pada bagian tengah mampu membuat convergence layer dengan puluhan layer untuk Stochastic Gradient Descent ( SGD ) dengan back propagation. Masalah degradasi inilah yang coba diselesaikan oleh framework *Deep*

*Residual Network*. Dengan cara menggunakan *residual block* dengan menambahkan koneksi secara langsung dan melewati beberapa layer dalam sebuah model seperti pada Gambar 2. 18. Dibanding dengan menumpuk setiap layer secara langsung dan diproses secara berurutan. Dimana jika layer yang dimiliki terlalu dalam akan mengakibatkan terjadi *vanishing gradient* ataupun *exploding gradient*. Oleh sebab itu dibuatlah sebuah block yang mampu melakukan shortcut koneksi yang disebut *skip connection*. Metode inilah yang menjadi jantung dari *Residual Network*.




Gambar 2.5. Residual Block<sup>12</sup>

Dengan menggunakan teknik *skip connection* Resnet mampu menyelesaikan masalah *Vanishing Gradient* dan *Exploding Gradient* pada CNN. Untuk mengetahui bagaimana cara kerja dari Resnet perlu mengetahui arsitektur yang digunakannya. Pada Gambar 2. 19 arsitektur Resnet sendiri terdiri dari 34 *layer plain network*. Terinspirasi dari VGG-19 dengan penambahan *skip connection*. Dimana VGG-19 adalah salah satu arsitektur CNN yang lebih awal dari Resnet mampu mengidentifikasi 1000 gambar dengan 1000 kategori yang berbeda (He et al., 2015). VGG-19 merupakan salah satu algoritma untuk image classification yang populer dan mudah digunakan untuk transfer learning. Dengan demikian arsitektur yang dimiliki oleh Resnet juga mirip dengan VGG-19 yang berbeda hanya penambahan *skip connection*-nya saja.

## 2.8 Web Service

Web service merupakan aplikasi yang berisi sekumpulan basis data (database) dan perangkat lunak (software) atau bagian dari program perangkat lunak yang diakses secara remote oleh piranti dengan perantara tertentu (Al-Masri & Mahmoud, 2007). Biasanya akan menerima *request* berupa *web document* (HTML, JSON, XML, Images) dan dibuat spesifik untuk menyelesaikan masalah tertentu. Pada Gambar 2. 20 terlihat ada 2 client (*mobile, desktop*) yang mencoba melakukan request data ke computer

server dengan metode get, post, put, delete maupun yang lainnya. Jika client yang melakukan request dianggap berhak menerima informasi atas data yang ada pada server, maka server akan mengirimkan response sesuai dengan permintaan masing-masing dari client yang ada.



Gambar 2.6. Arsitektur Web Service<sup>14</sup>

Evolusi layanan web terjadi karena semua platform utama dapat mengakses internet, tetapi platform yang berbeda tidak dapat berinteraksi satu sama lain. Oleh sebab itu salah satu cara untuk bisa berkomunikasi antar aplikasi, web service menjadi salah satu pilihan yang bisa digunakan.

## 2.9 Jenis Penyakit Padi

Pada penelitian ini penulis hanya mengambil 3 contoh dari penyakit tumbuhan padi, yang merupakan 7 penyakit yang banyak di temui di Indonesia (Nisa, 2021). Berikut penyakit yang akan dibahas pada penelitian ini.

### 1. Bacterial leaf streak (Penyakit daun bergaris)

Penyakit tanaman padi yang pertama adalah penyakit bakteri daun bergaris (*bacterial leaf streak*), terjadi hanya pada helaian daun saja. Gejala yang timbul berupa bercak sempit berwarna hijau gelap yang lama-kelamaan membesar berwarna kuning dan tembus cahaya di antara pembuluh daun. Sejalan dengan berkembangnya penyakit, bercak membesar, berubah menjadi berwarna coklat, dan berkembang menyamping melampaui pembuluh daun yang besar. Seluruh daun varietas yang rentan bisa berubah warna menjadi coklat dan mati. Pada keadaan ideal untuk infeksi, seluruh pertanaman menjadi berwarna oranye kekuning-kuningan.





2. Bacterial panicle blight (Penyakit hawar daun)

Penyakit tanaman padi berikutnya adalah penyakit hawar daun bakteri (HDB). Penyakit ini akan menimbulkan bercak pada daun berwarna kuning hingga putih, berbentuk garis lebam pada bagian tepi.



3. Penyakit blast

Gejala yang ditimbulkan jika tanaman padi terserang penyakit ini adalah daun akan memiliki bercak kuning pada bagian ujung, hingga berwarna kecoklatan dan juga kering pada tanaman.



#### 4. Penyakit hawar pelepah daun

Hawar pelepah merupakan salah satu penyakit utama pada tanaman padi yang disebabkan oleh jamur *Rhizoctonia solani*. Gejala penyakit umumnya timbul saat tanaman memasuki fase anakan maksimum, terlihat pada bagian pelepah daun berupa bercak-bercak besar, berbentuk oval dengan bagian tepi tidak teratur. Bercak pada awalnya timbul pada pelepah daun bagian bawah, dan selanjutnya menjalar ke pelepah daun bagian atasnya. Pusat bercak berwarna coklat kemerahan.



#### 5. Dead heart (Penyakit busuk batang)

Gejala yang ditimbulkan apabila tanaman padi terserang penyakit ini adalah terjadinya pembusukan pada batang menjadi kuning, kecoklatan dan kehitaman sehingga mengakibatkan kematian pada tanaman padi. Pengendalian penyakit ini dapat dilakukan dengan cara melakukan pemupukan secara teratur atau juga bisa dengan melakukan penyemprotan dengan fungisida berbahan aktif.



6. Downy mildey (Penyakit Kerdil)

Penyakit tanaman padi selanjutnya adalah penyakit kerdil. Tanaman padi yang terserang penyakit ini akan sulit tumbuh dan berkembang, sehingga tanaman akan pendek dan kerdil. Pengendalian penyebab penyakit ini adalah dengan cara mencari musuhnya yaitu wereng coklat.



7. Brown spot



#### 8. Penyakit Tungro

Tanaman padi yang terserang penyakit ini akan mengalami pembusukan pada bunga tanaman padi dan juga membuat tanaman tidak berbunga.

Pengendalian penyakit ini dapat dilakukan dengan melakukan penyemprotan fungisida dengan baik dan teratur dan juga melakukan penjarangan sebelum penanaman dilakukan.



#### 9. Hispa

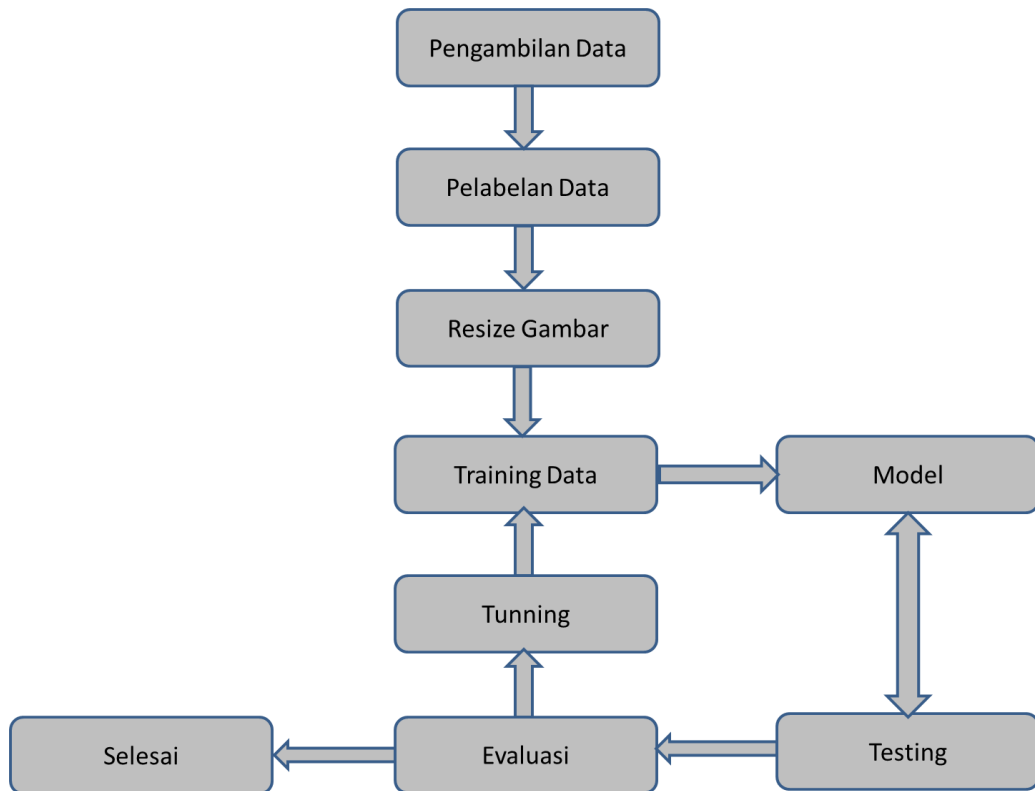


#### 10. Normal



## BAB III METODE PENELITIAN

Pada penelitian ini proses perencanaan sampai dengan penelitian ini selesai memiliki beberapa tahapan sesuai dengan Gambar 3. 1.



Gambar 3. 1 Metodologi penelitian

### 3.1. Pengumpulan Data

Penelitian ini pertama menggunakan data sekunder dari *Paddy Disease Classification Dataset* sebagai data training untuk pengujian dari algoritma deep learning yang dirancang. Dataset ini memiliki total 13,876 gambar 10.407 (75%) diantaranya digunakan untuk melatih model. Semua gambar terbagi menjadi 10 kelas yaitu 9 jenis penyakit dan 1 tumbuhan normal seperti pada tabel 5.1. Sisanya sebanyak 3.469 (25%) gambar akan digunakan untuk melakukan test model terhadap data yang sudah dilatih.

**Tabel 3.1 Dataset Paddy Disease Classification**

No	Nama Kelas	Jumlah Gambar
1	Bacterial Leaf Blight	479
2	Bacterial Leaf Streak	380
3	Bacterial Panicle Blight	337
4	Blast	1.738
5	Brown Spot	965
6	Dead Heart	1.442
7	Downy Mildew	620
8	Hispa	1.594
9	Tungro	1.088
10	Normal	1.764
Total		10.407

Selanjutnya data yang diambil secara langsung menggunakan kamera hp dan kamera digital. Jumlah data yang diambil sebanyak 500 gambar untuk setiap kelasnya, akan digunakan untuk melakukan test model terhadap data yang sudah dilatih. Data diambil dari lapangan menggunakan kamera digital sonny WX800, dan kamera hp.

### **3.2. Pelabelan Data**

Dalam proses pelabelan data jika menggunakan deep learning untuk image classification, dan deep learning untuk object detection adalah dua hal yang berbeda. Pada image classification cukup dengan mengelompokkan gambar berdasarkan kelasnya, Misal dengan folder yang dipisah atau cukup dengan penamaan yang menggunakan prefix. Biasanya 1 gambar hanya dianggap satu kelas yang paling dominan. Sedangkan untuk deep learning dengan tujuan object detection data harus dilabeli dengan cara anotasi pada gambar. Proses anotasi diperlukan khususnya pada dataset dengan tujuan objek detection dan juga object segmentation. Akibatnya jumlah data gambar yang didapat belum tentu sama dengan hasil pelabelan dari anotasi. Pada penelitian ini untuk memudahkan proses anotasi menggunakan aplikasi khusus anotasi yang bernama labelImg16. Berdasarkan keterangan resmi dari website penyedia labelImg, aplikasi ini

merupakan *graphical image annotation tools*, yang dibuat dengan menggunakan Bahasa pemrograman python dan Qt untuk sebagai interface (antarmuka) yang memudahkan dalam proses anotasi. Aplikasi ini support beberapa format anotasi seperti Pascal VOC yang digunakan oleh ImageNet, dan juga support format Yolo serta CreateML. Selain itu aplikasi ini juga *multiplatform* dengan kata lain bisa digunakan di sistem operasi *mainstream* seperti linux, windows, dan juga Mac OS.

### **3.3. Resize Gambar**

Proses training data adalah salah satu tahapan yang memerlukan komputasi yang tidak murah, terlebih data yang digunakan berupa data gambar, audio, dan video dengan kualitas tinggi. Untuk mengurangi beban pada saat training data, maka pada penelitian ini akan dilakukan proses resize gambar. Dengan melakukan proses resize gambar, diharapkan proses training data bisa lebih efisien dan lebih cepat.

### **3.4. Training Data**

Model pada *machine learning* bergantung pada data (Brodley & Friedl, 1999). Tanpa dasar data pelatihan berkualitas tinggi, bahkan algoritma yang paling berkinerja pun dapat dianggap tidak berguna. Pada penelitian kali ini, penulis melakukan proses pelabelan data dengan bantuan ahli dibidang pertanian yang yang bekerja di perusahaan berskala nasional, dengan catatan penulis tetap melakukan verifikasi ulang terhadap data, untuk mencegah human error.

### **3.5. Model dan Testing**

Untuk menghasilkan model pada penelitian ini menggunakan backbone *resnet50\_fpn*, dimana dengan menggunakan pretrained models yang sudah disediakan oleh pytorch akan membantu proses training mencapai convergen walau dengan data yang tergolong sedikit. Setelah melakukan training pada dataset maka akan dihasilkan beberapa model sesuai dengan konfigurasi yang disimpan, pada tahapan ini lah sebenarnya yang menjadi inti dari tahapan yang dilalui dalam penelitian. Ketika model terbaik sudah dihasilkan, berikutnya yang perlu dilakukan adalah menguji models. Beberapa model deep learning yang akan diujikan dengan data yang ada adalah, EfficientNet V2, Inception V3 dan MobileNet V3.

### 3.6. Evaluasi Model

Dalam evaluasi object detection standar yang biasa digunakan adalah mAP (mean average precision) baik itu untuk Yolo, SSD, dan juga Faster R-CNN. pada penelitian ini Faster R-CNN adalah algoritma yang digunakan untuk mendeteksi penyakit pada tanaman padi. sebelum mengetahui bagaimana mAP dihasilkan, perlu mengetahui tentang precision dan recall terlebih dahulu. *Precision* mengacu kepada ketepatan model dalam melakukan prediksi yang dibuat terhadap semua objek. Sedangkan *recall* mengacu kepada kemampuan model untuk mendeteksi semua *ground truth* yang ada. untuk lebih jelasnya perhatikan formula berikut.

$$Precision = TP / (TP+FP)$$

$$recall = TP / (TP+FN)$$

- TP = *True positif* mengacu kepada jumlah angka yang berhasil dideteksi secara benar oleh model ketika melakukan prediksi terhadap ground truth.
- FP = *False positif* mengacu kepada prediksi model yang salah bukan bagian dari ground truth
- FN = *False negative* model tidak memprediksi ground truth yang ada.

### 3.7. Aplikasi Mobile

Aplikasi mobile atau sering juga disingkat dengan istilah Mobile Apps adalah aplikasi dari sebuah perangkat lunak yang dalam pengoperasiannya dapat berjalan diperangkat mobile (Smartphone, Tablet, iPod, dll), dan memiliki system operasi yang mendukung perangkat lunak secara standalone (Wardana, 2016). Mobile apps mengaplikasikan deep learning model yang sudah dilatih dan ditest untuk digunakan secara langsung pada data real.



## BAB IV HASIL DAN PEMBAHASAN

### 4.1. Pengumpulan Data

Penelitian ini pertama menggunakan data sekunder dari *Paddy Disease Classification Dataset* sebagai data training untuk pengujian dari algoritma deep learning yang dirancang. Dataset ini memiliki total 13,876 gambar 10.407 (75%) diantaranya digunakan untuk melatih model. Semua gambar terbagi menjadi 10 kelas yaitu 9 jenis penyakit dan 1 tumbuhan normal seperti pada tabel 5.1. Sisanya sebanyak 3.469 (25%) gambar akan digunakan untuk melakukan test model terhadap data yang sudah dilatih.

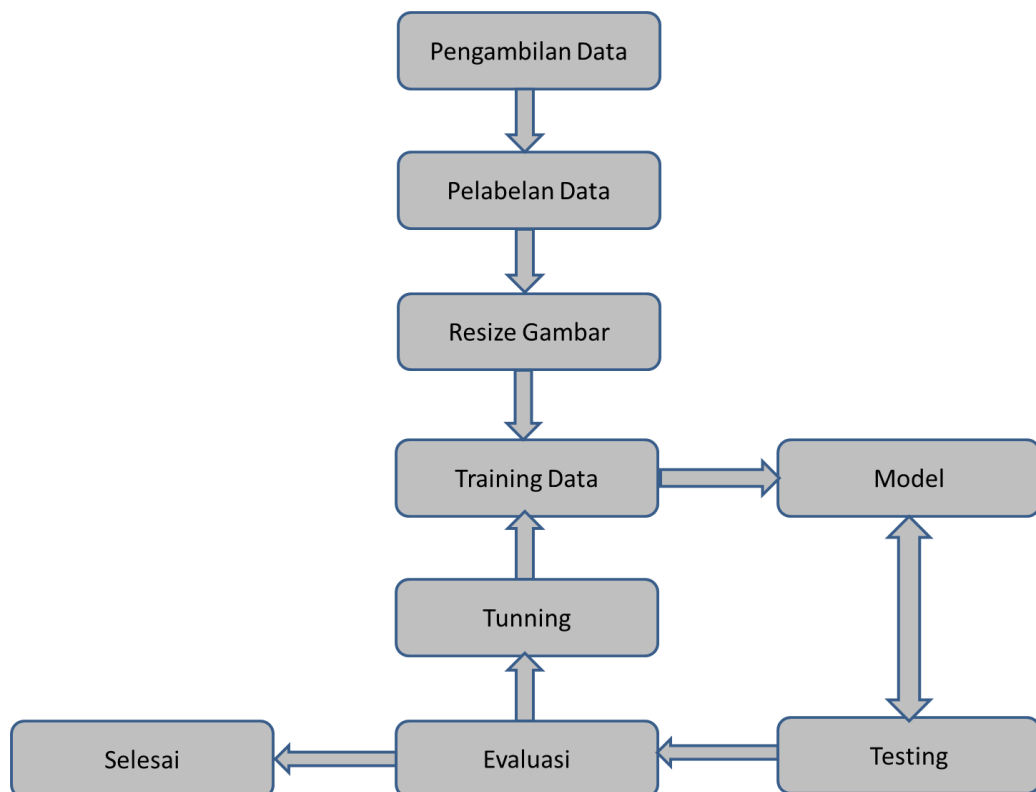
**Tabel 4.1. Dataset Paddy Disease Classification**

No	Nama Kelas	Jumlah Gambar
1	Bacterial Leaf Blight	479
2	Bacterial Leaf Streak	380
3	Bacterial Panicle Blight	337
4	Blast	1.738
5	Brown Spot	965
6	Dead Heart	1.442
7	Downy Mildew	620
8	Hispa	1.594
9	Tungro	1.088
10	Normal	1.764
Total		10.407

Selanjutnya data yang diambil secara langsung menggunakan kamera hp dan kamera digital. Jumlah data yang diambil sebanyak 347 gambar untuk setiap kelasnya, akan digunakan untuk melakukan test model terhadap data yang sudah dilatih. Data diambil dari lapangan menggunakan kamera digital dan kamera hp.

## 4.2. Pelabelan Data

Dalam proses pelabelan data jika menggunakan deep learning untuk image classification, dan deep learning untuk object detection adalah dua hal yang berbeda. Pada image classification cukup dengan mengelompokkan gambar berdasarkan kelasnya, Misal dengan folder yang dipisah atau cukup dengan penamaan yang menggunakan prefix. Biasanya 1 gambar hanya dianggap satu kelas yang paling dominan. Sedangkan untuk deep learning dengan tujuan object detection data harus dilabeli dengan cara anotasi pada gambar. Proses anotasi diperlukan khususnya pada dataset dengan tujuan objek detection dan juga object segmentation. Akibatnya jumlah data gambar yang didapat belum tentu sama dengan hasil pelabelan dari anotasi. Pada penelitian ini untuk memudahkan proses anotasi menggunakan aplikasi khusus anotasi yang bernama labelImg16.



Gambar 4.1. Diagram Alir penelitian

Berdasarkan keterangan resmi dari website penyedia labelImg, aplikasi ini merupakan *graphical image annotation tools*, yang dibuat dengan menggunakan Bahasa pemrograman python dan Qt untuk sebagai interface (antarmuka) yang memudahkan dalam proses anotasi. Aplikasi ini support beberapa format anotasi seperti Pascal VOC yang digunakan oleh ImageNet, dan juga support format Yolo serta CreateML. Selain itu aplikasi ini juga *multiplatform* dengan kata lain bisa digunakan di sistem operasi *mainstream* seperti linux, windows, dan juga Mac OS.

### **4.3. Resize Gambar**

Proses training data adalah salah satu tahapan yang memerlukan komputasi yang tidak murah, terlebih data yang digunakan berupa data gambar, audio, dan video dengan kualitas tinggi. Untuk mengurangi beban pada saat training data, maka pada penelitian ini akan dilakukan proses *resize* gambar. Dengan melakukan proses *resize* gambar, diharapkan proses training data bisa lebih efisien dan lebih cepat.

### **4.4. Training Data**

Model pada *machine learning* bergantung pada data (Brodley & Friedl, 1999). Tanpa dasar data pelatihan berkualitas tinggi, bahkan algoritma yang paling berkinerja pun dapat dianggap tidak berguna. Pada penelitian kali ini, penulis melakukan proses pelabelan data dengan bantuan ahli dibidang pertanian yang bekerja di perusahaan berskala nasional, dengan catatan penulis tetap melakukan verifikasi ulang terhadap data, untuk mencegah human error.

### **4.5. Model dan Testing**

Untuk menghasilkan model pada penelitian ini menggunakan backbone *resnet50\_fpn*, dimana dengan menggunakan *pretrained models* yang sudah disediakan oleh *pytorch* akan membantu proses training mencapai *convergen* walau dengan data yang tergolong sedikit. Setelah melakukan training pada dataset maka akan dihasilkan beberapa model sesuai dengan konfigurasi yang disimpan, pada tahapan ini lah sebenarnya yang menjadi inti dari tahapan yang dilalui dalam penelitian. Ketika model terbaik sudah dihasilkan, berikutnya yang perlu dilakukan adalah menguji models. Beberapa model *deep learning*

yang akan diujikan dengan data yang ada adalah, EfficientNet V2, Inception V3 dan MobileNet V3.

#### 4.6. Evaluasi Model

Dalam evaluasi object detection standar yang biasa digunakan adalah mAP (mean average precision) baik itu untuk Yolo, SSD, dan juga Faster R-CNN. pada penelitian ini Faster R-CNN adalah algoritma yang digunakan untuk mendeteksi penyakit pada tanaman padi. sebelum mengetahui bagaimana mAP dihasilkan, perlu mengetahui tentang precision dan recall terlebih dahulu. *Precision* mengacu kepada ketepatan model dalam melakukan prediksi yang dibuat terhadap semua objek. Sedangkan *recall* mengacu kepada kemampuan model untuk mendeteksi semua *ground truth* yang ada. untuk lebih jelasnya perhatikan formula berikut.

$$Precision = TP / (TP+FP)$$


$$recall = TP / (TP+FN)$$

- TP = *True positif* mengacu kepada jumlah angka yang berhasil dideteksi secara benar oleh model ketika melakukan prediksi terhadap ground truth.
- FP = *False positif* mengacu kepada prediksi model yang salah bukan bagian dari ground truth
- FN = *False negative* model tidak memprediksi ground truth yang ada

#### 4.7. Hasil Training dan Evaluasi

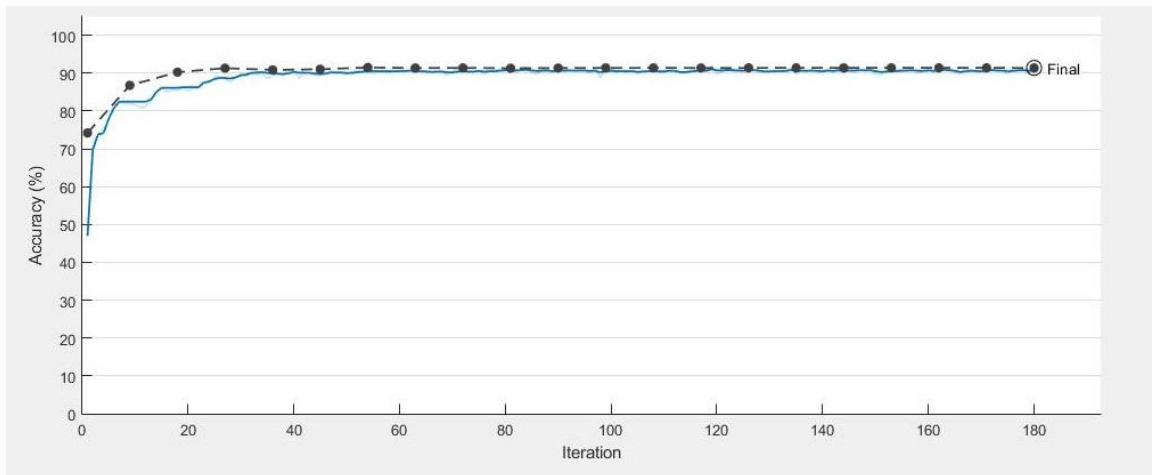
Algoritma yang digunakan pada penelitian pendeteksi penyakit tanaman pangan ini berupa *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV3. Arsitektur algoritma MobileNetV3 dapat dilihat pada gambar 1. Keunggulan dari algoritma CNN ialah pada kemampuannya yang baik dan cepat dalam mendeteksi pola pada suatu gambar. Selain itu, ukuran dari algoritma CNN yang kecil berkisar 3,901 MB membuat algoritma CNN sangat layak untuk ditempatkan pada aplikasi *mobile*.

Proses *training* dilakukan dengan melibatkan dua *callbacks* yaitu *early stopping callback* dan *reduce learning rate on plateau callback*. Kedua algoritma CNN ini berperan penting untuk meningkatkan kinerja algoritma pada saat proses training.




Gambar 4.2. Arsitektur MobileNetV3

*Reduce learning rate on plateau callback* akan menurunkan *learning rate* sampai ke angka  $10^{-5}$  sehingga algoritma dapat meningkatkan akurasi dan mengurangi loss. *Early stopping callback* berfungsi menghentikan proses *training* jika tidak terjadi peningkatan yang signifikan agar tidak menimbulkan *overfitting*. Grafik peningkatan akurasi dan penurunan loss seiring dengan penambahan epoch/iterasi dapat dilihat pada gambar 4.3.



(a)



(b)

Gambar 4.3. Grafik Peningkatan Akurasi dan Penurunan Loss

Model MobileNetV3 memiliki tingkat akurasi cukup tinggi dalam mengenali penyakit pada tanaman dengan rata-rata akurasi mencapai 91,35 % dan loss tidak lebih dari 0.22 %.

## BAB V

### KESIMPULAN DAN SARAN

#### 5.1. Kesimpulan

Penelitian ini menunjukkan bahwa penggunaan MobileNetV3 sebagai pendeteksi penyakit pada tanaman pangan dapat menjadi langkah penting dalam membangun pertanian *modern*. Penerapan teknologi AI seperti MobileNetV3, petani dapat mengidentifikasi penyakit pada tanaman secara akurat dan efisien, sehingga mereka dapat mengambil tindakan yang cepat dan tepat waktu dalam menjaga kesehatan tanaman.

Hasil penelitian menunjukkan bahwa MobileNetV3 memiliki tingkat akurasi yang tinggi dalam mengenali penyakit pada tanaman pangan, dengan rata-rata akurasi mencapai 94%. Hal ini menunjukkan bahwa penggunaan teknologi AI dalam pertanian dapat membantu petani untuk mengoptimalkan hasil panen dan meminimalisir kerugian akibat penyakit tanaman.

Penggunaan MobileNetV3 sebagai pendeteksi penyakit tanaman pangan merupakan langkah sesuai dengan perkembangan zaman dan kebutuhan generasi milenial. Teknologi yang mudah diakses seperti aplikasi *mobile* yang mendukung MobileNetV3 dapat membantu petani dalam mengelola pertanian dengan lebih efisien dan responsif terhadap perubahan kondisi tanaman.

Tahap implementasi dengan teknologi AI dalam pertanian dapat membawa dampak positif dalam meningkatkan efisiensi, produktivitas, dan keberlanjutan pertanian. Penggunaan MobileNetV3 sebagai pendeteksi penyakit pada tanaman pangan adalah salah satu contoh nyata bagaimana teknologi AI dapat menjadi langkah milenial dalam membangun pertanian modern.

Melalui adopsi teknologi seperti MobileNetV3, diharapkan pertanian dapat menjadi lebih adaptif terhadap perubahan iklim, lebih produktif, dan lebih ramah lingkungan. Penelitian ini diharapkan dapat mendorong para petani dan pelaku pertanian lainnya untuk terus membuka diri terhadap kemajuan teknologi dan memanfaatkannya untuk mengatasi tantangan yang dihadapi oleh sektor pertanian di era *modern* ini.

## **5.2. Saran**

Penelitian ini dapat dikembangkan untuk berbagai jenis penyakit pada berbagai tanaman pangan lainnya dan dapat dibandingkan dengan metode deep learning lain.

## Daftar Pustaka

- Agarwal, S., Farid, H., El-Gaaly, T., & Lim, S.-N. (2020). Detecting deep-fake videos from appearance and behavior. *2020 IEEE International Workshop on Information Forensics and Security (WIFS)*, 1–6.
- Ajitha, P. V., & Nagra, A. (2021). An Overview of Artificial Intelligence in Automobile Industry—A Case Study on Tesla Cars. *Solid State Technology*, *64*(2), 503–512.
- Al-Amin, M., Karim, D. Z., & Bushra, T. A. (2019). Prediction of rice disease from leaves using deep convolution neural network towards a digital agricultural system. *2019 22nd International Conference on Computer and Information Technology (ICCIT)*, 1–5.
- Al-Masri, E., & Mahmoud, Q. H. (2007). Discovering the best web service. *Proceedings of the 16th International Conference on World Wide Web*, 1257–1258.
- Arandjelovic, R., Gronat, P., Torii, A., Pajdla, T., & Sivic, J. (2016). NetVLAD: CNN architecture for weakly supervised place recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 5297–5307.
- Atmaja, R. A. W., Santosa, S. J., & Siswadi, S. (2020). KAJIAN PUPUK KANDANG TERHADAP INTENSITAS PENYAKIT BERCAK COKLAT SEMPIT (*Cercospora oryzae*) PADA TANAMAN PADI KETAN PUTIH (*Oryzae sativa* L. *Glutinosa*). *Innofarm: Jurnal Inovasi Pertanian*, *22*(1), 15–22.
- Brownlee, J. (2019). *Deep learning for computer vision: Image classification, object detection, and face recognition in python*. Machine Learning Mastery. Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., Cui, C., Corrado, G., Thrun, S., & Dean, J. (2019). A guide to deep learning in healthcare. *Nature Medicine*, *25*(1), 24–29. [19] “Relay Basics.” Internet: <http://www.jag-lovers.org/lumps/tech/basics/relays.htm>, 2012 [May 3, 2014].
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, *145*, 311–318.
- Fuentes, Alvaro. (2017). *A Robust Deep-Learning-Based Detector for Real-Time Tomato Plant Diseases and Pests Recognition*.
- Goncharov, P., Ososkov, G., Nechaevskiy, A., Uzhinskiy, A., & Nestsiarenia, I. (2018). Disease detection on the plant leaves by deep learning. *International Conference on Neuroinformatics*, 151–159.



- Hayat, M. K., Daud, A., Alshdadi, A. A., Banjar, A., Abbasi, R. A., Bao, Y., & Dawood, H. (2019). Towards deep learning prospects: Insights for social media analytics. *IEEE Access*, 7, 36958–36979.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Deep Residual Learning for Image Recognition* (arXiv:1512.03385). arXiv. <https://doi.org/10.48550/arXiv.1512.03385>
- Jez, J. M., Topp, C. N., Silva, G., Tomlinson, J., Onkokesung, N., Sommer, S., Mrisho, L., Legg, J., Adams, I. P., & Gutierrez-Vazquez, Y. (2021). Plant pest surveillance: From satellites to molecules. *Emerging Topics in Life Sciences*, 5(2), 275–287.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Liang, W., Zhang, H., Zhang, G., & Cao, H. (2019). Rice blast disease recognition using a deep convolutional neural network. *Scientific Reports*, 9(1), 1–10.
- Masnilah, R., Astono, T. H., & Aini, L. Q. (2013). Karakterisasi bakteri penyebab penyakit hawar daun edamame di Jember. *Berkala Ilmiah Pertanian*, 1(1), 10–14.
- Nisa, K. (2021). *Isolasi Xanthomonas oryzae pv. Oryzae dan Pengujian Ketahanan Varietas Padi terhadap Hawar Daun Bakteri di BB Padi Subang*. 63
- Oberweger, M., Wohlhart, P., & Lepetit, V. (2015). Hands deep in deep learning for hand pose estimation. *ArXiv Preprint ArXiv:1502.06807*. O’Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. *ArXiv Preprint ArXiv:1511.08458*.
- Pathak, A. R., Pandey, M., & Rautaray, S. (2018). Application of deep learning for object detection. *Procedia Computer Science*, 132, 1706–1717.
- Prasanna Mohanty, S., Hughes, D., & Salathe, M. (2016). Using Deep Learning for Image- Based Plant Disease Detection. *ArXiv E-Prints*, arXiv-1604.
- PRASETYO, M. S. H. (2017). *Kajian Intensitas Penyakit Bercak Coklat Sempit (Cercospora oryzae) dan Teknik Pengendaliannya pada Pertanaman Padi di Kecamatan Tanggul Kabupaten Jember*.
- Purwins, H., Li, B., Virtanen, T., Schlüter, J., Chang, S.-Y., & Sainath, T. (2019). Deep learning for audio signal processing. *IEEE Journal of Selected Topics in Signal Processing*, 13(2), 206–219.
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems*, 28.

- Sethy, P. K., Barpanda, N. K., Rath, A. K., & Behera, S. K. (2020). Rice false smut detection based on faster R-CNN. *Indonesian Journal of Electrical Engineering and Computer Science*, 19(3), 1590–1595.
- Sudir, S., Nasution, A., Santoso, S., & Nuryanto, B. (2015). *Penyakit blas Pyricularia grisea pada tanaman padi dan strategi pengendaliannya*. Sudir, S., Nuryanto, B., & Kadir, T. S. (2012). *Epidemiologi, patotipe, dan strategi pengendalian penyakit hawar daun bakteri pada tanaman padi*.

**Lampiran**

- 1. Makalah Avoer 15**
- 2. Sertifikat**