

**RANCANG BANGUN APLIKASI BERBASIS ANDROID UNTUK PREDIKSI  
TINGKAT KEBERHASILAN PIKUNG PADA TANAMAN JERUK DENGAN  
*CONVOLUTIONAL NEURAL NETWORK***

**TUGAS AKHIR**



**UNIVERSITAS  
MA CHUNG**

**HANDIKA GUNAWAN PUTRA**

**NIM: 311910009**

**PROGRAM STUDI TEKNIK INFORMATIKA  
FAKULTAS TEKNOLOGI DAN DESAIN  
UNIVERSITAS MA CHUNG  
MALANG  
2024**

## DAFTAR GAMBAR

Gambar 2. 1 Tanaman daun jeruk keprok	7
Gambar 2. 2 Tanaman jeruk keprok setelah di pikung	8
Gambar 2. 3 Lux meter	9
Gambar 2. 4 Colorimeter	10
Gambar 2. 5 Arsitektur ResNet50V2	15
Gambar 2. 6 Arsitektur VGG16	16
Gambar 2. 7 Arsitektur MobileNetV2	17
Gambar 2. 8 Arsitektur InceptionV3	18
Gambar 2. 9 Arsitektur YoloV5	18
Gambar 2. 10 Tabel Confusion Matrix	20
Gambar 3. 1 Alur penelitian	23
Gambar 3. 2 Alur pengumpulan data	28
Gambar 3. 3 preprocessing data (a) Sebelum dan (b) Sesudah pemotongan	30
Gambar 3. 4 Alur desain dan perancangan sistem	31
Gambar 3. 5 Confusion Matriks model	33
Gambar 3. 6 Mock up aplikasi bagian tutorial	34
Gambar 3. 7 Mock up bagian inti aplikasi	34
Gambar 4. 1 Contoh 3 titik daerah yang diambil menggunakan colorimeter	35
Gambar 4. 2 Grafik Rata-rata RGB Data Colorimeter	37
Gambar 4. 3 Grafik Standar Deviasi RGB Data Colorimeter	38
Gambar 4. 4 Grafik Rata-rata RGB Data Citra	39
Gambar 4. 5 Grafik Standar Deviasi RGB Data Citra	40
Gambar 4. 6 Grafik Indikator Kinerja VGG_Adam (a) Akurasi dan (b) <i>Loss</i>	43
Gambar 4. 7 <i>Confusion matrix</i> Data Test VGG_Adam	44
Gambar 4. 8 Grafik Indikator Kinerja VGG_Adamax (a) Akurasi dan (b) <i>Loss</i>	45
Gambar 4. 9 <i>Confusion matrix</i> Data Test VGG_Adamax	46
Gambar 4. 10 Grafik Indikator Kinerja ResNet50V2_Adam (a) Akurasi dan (b) <i>Loss</i>	47
Gambar 4. 11 <i>Confusion matrix</i> Data Test ResNet50V2_Adam	48

Gambar 4. 12 Grafik Indikator Kinerja ResNet50V2_Adamax (a) Akurasi dan (b) <i>Loss</i>	49
Gambar 4. 13 <i>Confusion matrix</i> Data Test ResNet50V2_Adamax	50
Gambar 4. 14 Grafik Indikator Kinerja MobileNetV2_Adam (a) Akurasi dan (b) <i>Loss</i>	51
Gambar 4. 15 <i>Confusion matrix</i> Data Test MobileNetV2_Adam	52
Gambar 4. 16 Grafik Indikator Kinerja MobileNetV2_Adamax (a) Akurasi dan (b) <i>Loss</i>	53
Gambar 4. 17 <i>Confusion matrix</i> Data Test MobileNetV2_Adamax	54
Gambar 4. 18 Grafik Indikator Kinerja InceptionV3_Adam (a) Akurasi dan (b) <i>Loss</i>	55
Gambar 4. 19 <i>Confusion matrix</i> Data Test InceptionV3_Adam	56
Gambar 4. 20 Grafik Indikator Kinerja InceptionV3_Adamax (a) Akurasi dan (b) <i>Loss</i>	57
Gambar 4. 21 <i>Confusion matrix</i> Data Test InceptionV3_Adamax	58
Gambar 4. 22 Perbandingan Kinerja Model	59
Gambar 4. 23 Perbandingan Ukuran Model dalam bentuk Megabyte (MB)	60
Gambar 4. 24 Tampilan Home aplikasi	61
Gambar 4. 25 Tampilan prediksi dengan kondisi (a) Daun tidak terdeteksi dan (b) Daun terdeteksi	62
Gambar 4. 26 Hasil Evaluasi pada data asli (a) Tingkat Keberhasilan Rendah (b) Tingkat Keberhasilan Sedang (c) Tingkat Keberhasilan Tinggi	63

## DAFTAR ISI

LEMBAR PENGESAHAN	i
Abstrak	ii
Abstract	iii
KATA PENGANTAR	iv
DAFTAR ISI	v
DAFTAR GAMBAR	viii
DAFTAR TABEL	x
BAB I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Identifikasi Masalah	3
1.3 Batasan Masalah	3
1.4 Rumusan Masalah	3
1.5 Tujuan Penelitian	4
1.6 Manfaat Penelitian	4
1.7 Luaran Penelitian	4
1.8 Sistematika Penulisan	4
BAB II TINJAUAN PUSTAKA	6
2.1 Pigmen Tanaman	6
2.2 Tanaman Jeruk	6
2.3 Metode Pijat Lengkung (Pikung)	7
2.4 Lux Meter	9
2.5 Colorimeter	9
2.8 <i>Visible Atmospherically Resistant Index (VARI)</i>	10
2.9 Java	11

2.10	Python	11
2.11	Google Colaboratory	12
2.12	Augmentasi Data	12
2.13	Transfer Learning	13
2.14	Convolutional Neural Network (CNN)	14
2.14.1	Arsitektur	14
2.14.2	<i>Optimizer</i>	19
2.14.3	<i>Loss</i>	19
2.14.4	<i>Confusion Matrix</i>	20
2.15	Android Studio	22
2.16	Penelitian terdahulu	22
BAB III ANALISIS DAN PERANCANGAN SISTEM		23
3.1	Alur Penelitian	23
3.2	Identifikasi Masalah	24
3.3	Analisis Kebutuhan	24
3.3.1	Kebutuhan Pengguna	24
3.3.2	Kebutuhan Peneliti	25
3.4	Studi Pustaka	25
3.5	Pengumpulan Data	27
3.5.1	Pembuatan Dataset	29
3.5.2	Preprocessing Dataset	30
3.6	<i>Profiling</i>	31
3.7	Desain dan Perancangan Sistem	31
3.7.1	Pelatihan Model	32
3.7.2	Pengujian Model	32
3.8	Pengembangan Aplikasi	33

3.8.1	Mockup Aplikasi	33
BAB IV HASIL DAN PEMBAHASAN		35
4.1	Dataset	35
4.2	<i>Profilling</i>	36
4.3	Augmentasi	40
4.4	Implementasi CNN	42
4.5	Pengujian Model CNN	42
4.5.1	VGG16_Adam	43
4.5.2	VGG16_Adamax	45
4.5.3	ResNet50V2_Adam	47
4.5.4	ResNet50V2_Adamax	49
4.5.5	MobileNetV2_Adam	51
4.5.6	MobileNetV2_Adamax	53
4.5.7	InceptionV3_Adam	55
4.5.8	InceptionV3_Adamax	57
4.6	Hasil Aplikasi	60
14.7	Evaluasi Aplikasi pada Data Asli	62
BAB V KESIMPULAN DAN SARAN		64
5.1	Kesimpulan	64
5.2	Saran	65
DAFTAR PUSTAKA		66

## DAFTAR PUSTAKA

- Alsamir, M., Mahmood, T., Trethowan, R., & Ahmad, N. (2021). An overview of heat stress in tomato (*Solanum lycopersicum* L.). In *Saudi Journal of Biological Sciences* (Vol. 28, Issue 3, pp. 1654–1663). Elsevier B.V. <https://doi.org/10.1016/j.sjbs.2020.11.088>
- Bardono, S. (2018, July 8). *Metode Pijat-Lengkung (Pikung) Agar Pohon Jeruk Cepat Berbuah*. Technology-Indonesia. <https://technology-indonesia.com/pertanian-dan-pangan/inovasi-pertanian/metode-pijat-lengkung-pikung-agar-pohon-jeruk-cepat-berbuah/>
- Faiz Nashrullah, Suryo Adhi Wibowo, & Gelar Budiman. (2020). The Investigation of Epoch Parameters in ResNet-50 Architecture for Pornographic Classification. *Journal of Computer, Electronic, and Telecommunication*, 1(1). <https://doi.org/10.52435/complete.v1i1.51>
- Gunawan, R. J., Irawan, B., & Setianingsih, C. (n.d.). *Pengenalan Ekspresi Wajah Berbasis Convolutional Neural Network Dengan Model Arsitektur Vgg16 Facial Expression Recognition Based on Convolutional Neural Network With Vgg16 Architecture Model*.
- Ibrahim, N., Lestary, G. A., Hanafi, F. S., Saleh, K., Pratiwi, N. K. C., Haq, M. S., & Mastur, A. I. (2022). Klasifikasi Tingkat Kematangan Pucuk Daun Teh menggunakan Metode Convolutional Neural Network. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(1), 162. <https://doi.org/10.26760/elkomika.v10i1.162>
- Irfan, D., Rosnelly, R., Wahyuni, M., Samudra, J. T., & Rangga, A. (2022). Perbandingan Optimasi Sgd, Adadelta, Dan Adam Dalam Klasifikasi Hydrangea Menggunakan Cnn. In *Journal of Science and Social Research* (Issue 2). <http://jurnal.goretanpena.com/index.php/JSSR>
- Paraijun, F., Nur Aziza, R., Kuswardani, D., Teknologi PLN Menara PLN, I., Lkr Luar Barat, J., Kosambi, D., Cengkareng, K., Jakarta Barat, K., & Khusus Ibukota Jakarta, D. (2022). *Implementasi Algoritma Convolutional Neural Network Dalam Mengklasifikasi Kesegaran Buah Berdasarkan Citra Buah*. 11(1). <https://doi.org/10.33322/kilat.v11i1.1458>

- Rega, K., Christianto O, I., & Setiawan, H. (2018). *Implementasi Convolutional Neural Network untuk Sistem Prediksi Pigmen Fotosintesis pada Tanaman Secara Real Time*. 2443–2229. <https://doi.org/10.28932/jutisi.v4i2.812>
- Menon, S., Raman, S., & Sahoo, R. K. (2019). A Comprehensive Review on Performance Metrics for Classification Algorithms. *Journal of Data, Information and Management*, 2(1), 12-25



## DAFTAR TABEL

Tabel 3. 1 Ringkasan Penelitian Terdahulu	26
Tabel 3. 2 Contoh citra data dengan kondisi Tingkat keberhasilan Rendah, Sedang, dan Tinggi	28
Tabel 4. 1 Jumlah data Rendah, Sedang, dan Tinggi	36
Tabel 4. 2 Hasil Augmentasi	41
Tabel 4. 3 Precision, recall, f1-score VGG_Adam	44
Tabel 4. 4 Precision, recall, f1-score VGG_Adamax	46
Tabel 4. 5 Precision, recall, f1-score ResNet50V2_Adam	48
Tabel 4. 6 precision, recall, f1-score ResNetV2_Adamax	50
Tabel 4. 7 precision, recall, f1-score MobileNetV2_Adam	52
Tabel 4. 8 precision, recall, f1-score MobileNetV2_Adamax	54
Tabel 4. 9 precision, recall, f1-score InceptionV3_Adam	56
Tabel 4. 10 precision, recall, f1-score Model InceptionV3_Adamax	58

## KATA PENGANTAR

Puji Syukur kepada Tuhan Yang Maha Esa atas berkat dan kasihnya sehingga penulis dapat menyelesaikan tugas penelitian dan laporan Tugas Akhir yang berjudul “Rancang Bangun Aplikasi Berbasis Android untuk Prediksi Tingkat Keberhasilan Pikung pada Tanaman Jeruk dengan *Convolutional Neural Network*.”

Laporan ini dibuat untuk menjelaskan hasil yang diperoleh dari pengerjaan Tugas Akhir yang telah selesai dilakukan. Tugas Akhir ini merupakan mata kuliah wajib Universitas Ma Chung yang harus ditempuh mahasiswa program studi Teknik Informatika sebagai prasyarat kelulusan.

Pada Kesempatan ini penulis ingin mengucapkan terima kasih kepada semua pihak yang sudah membantu penulis dalam pengerjaan Tugas Akhir ini. Ucapan terima kasih ini saya ucapkan kepada :

1. Ibu Dr.Kestrlia Rega Prilianti, M.Si., selaku dosen pembimbing proyek Tugas Akhir,
2. Bapak Hendry Setiawan, ST., M. Kom., selaku Kepala Program Studi Teknik Informatika Universitas Ma Chung,
3. Pusat Riset Hortikultura dan Perkebunan BRIN, yang membantu pelaksanaan pengambilan data.
4. Keluarga yang selalu mendoakan dan memberi dukungan kepada penulis untuk menyelesaikan proyek Tugas Akhir,
5. Serta teman-teman yang sudah membantu dalam pengerjaan proyek Tugas Akhir ini.

Malang, 29 Febuari 2024

Handika Gunawan Putra  
311910009

**LEMBAR PENGESAHAN  
TUGAS AKHIR**

**RANCANG BANGUN APLIKASI BERBASIS ANDROID UNTUK  
PREDIKSI TINGKAT KEBERHASILAN PIKUNG PADA TANAMAN JERUK  
DENGAN *CONVOLUTIONAL NEURAL NETWORK***

Oleh :

**HANDIKA GUNAWAN PUTRA**

**NIM: 311910009**

dari :

**PROGRAM STUDI TEKNIK INFORMATIKA  
FAKULTAS TEKNOLOGI DAN DESAIN  
UNIVERSITAS MA CHUNG**

Dosen Pembimbing 1,

**Dr. Kestriana Rega Prilianti, M.Si**  
**NIP. 20120035**

Dosen Pembimbing 2,

**Hendry Setiawan, ST., M.Kom.**  
**NIP. 20100006**

Dekan Fakultas Sains dan Teknologi



**Prof. Dr.Eng. Romy Budhi Widodo**  
**NIP.20070035**

**RANCANG BANGUN APLIKASI BERBASIS ANDROID UNTUK PREDIKSI  
TINGKAT KEBERHASILAN PIKUNG PADA TANAMAN JERUK DENGAN  
*CONVOLUTIONAL NEURAL NETWORK***

**Handika Gunawan Putra, Kestrilia Rega Prilianti, Hendry Setiawan  
Universitas Ma Chung**

**Abstrak**

Penelitian ini mengungkap pentingnya tanaman jeruk keprok 555 sebagai sumber vitamin C yang vital bagi manusia. Jeruk keprok memerlukan waktu yang lama, minimal 4 tahun, untuk berbuah. Oleh karena itu, metode Pijat Lengkung (Pikung) digunakan untuk meningkatkan sirkulasi air dan nutrisi, serta merangsang pertumbuhan tanaman. Namun, kendala terjadi dalam ketepatan waktu pikung yang optimal. Studi ini bertujuan mengembangkan model *Convolutional Neural Network* (CNN) untuk menentukan waktu pikung pada tanaman jeruk, dan membuat aplikasi Android berbasis model CNN. Penelitian menghasilkan delapan model yang berbeda, dioptimalkan dengan *optimizer* Adam dan Adamax. Model-model yang digunakan dalam penelitian ini adalah VGG16\_Adam, VGG16\_Adamax, ResNet50v2\_Adam, ResNet50v2\_Adamax, MobileNetv2\_Adam, MobileNetv2\_Adamax, InceptionV3\_Adam, InceptionV3\_Adamax. Hasil eksperimen menunjukkan model dengan *optimizer* Adamax memberikan performa lebih baik. Evaluasi menunjukkan bahwa model InceptionV3 dengan *optimizer* Adamax adalah yang terbaik, dengan akurasi mencapai 93% pada tahap validasi dan pengujian. Studi ini memberikan wawasan dalam meningkatkan efisiensi waktu pikung tanaman jeruk keprok 555 melalui pendekatan model CNN.

**Kata Kunci:** Jeruk Keprok, Pijat Lengkung (Pikung), Convolutional Neural Network (CNN)

**DESIGN AND DEVELOPMENT OF AN ANDROID-BASED APPLICATION  
FOR PREDICTING THE SUCCESS RATE OF GRAFTING IN CITRUS  
PLANTS USING CONVOLUTIONAL NEURAL NETWORK**

**Handika Gunawan Putra, Kestrlia Rega Prilianti, Hendry Setiawan**

**Universitas Ma Chung**

**Abstract**

This research reveals the importance of the 555 citrus orange plant as a vital source of Vitamin C for humans. The 555 citrus orange plant takes a long time, at least 4 years, to bear fruit. Therefore, the Curved Massage (Pikung) method is used to improve water and nutrient circulation, as well as stimulate plant growth. However, constraints arise in achieving optimal timing for Pikung. This study aims to develop a Convolutional Neural Network (CNN) model to determine the optimal Pikung time for citrus plants, and create an Android application based on the CNN model. The research produced eight different models, optimized with Adam and Adamax *optimizers*. The models used in this study are VGG16\_Adam, VGG16\_Adamax, ResNet50v2\_Adam, ResNet50v2\_Adamax, MobileNetv2\_adam, MobileNetv2\_adamax, InceptionV3\_Adam, and InceptionV3\_Adamax. The experimental results show that the model with the Adamax *optimizer* performs better. Evaluation indicates that the InceptionV3 model with the Adamax *optimizer* is the best, achieving an accuracy of 93% in the validation and testing phases. This study provides insights into improving the efficiency of Pikung time for 555 citrus orange plants through a CNN model approach.

**Keywords:** Citrus Orange, Pijat Lengkung (Pikung), Convolutional Neural Network (CNN)

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang Masalah**

Tanaman memiliki peran penting bagi manusia dan lingkungan, khususnya pada bidang pangan. Salah satu contoh pentingnya tanaman dalam bidang pangan yaitu tumbuhan jeruk karena menjadi salah satu sumber vitamin C terbesar bagi manusia. Untuk mengetahui kesehatan tanaman jeruk, salah satunya yaitu dapat memperhatikan warna pada daun tanaman. Warna pada daun biasanya dapat merepresentasikan kesehatan dan kondisi pada tanaman secara keseluruhan. Warna pada daun dipengaruhi oleh kandungan pigmen pada tanaman. Tanaman menggunakan cahaya sebagai energi dan untuk mengatur pertumbuhan dan respon terhadap lingkungan (Atmodjo, 2022)

Menurut Rahmawati dkk.,(2022), pigmen adalah zat yang memberi warna pada daun. Profil warna pigmen pada tanaman mencerminkan proses metabolisme dan tahap umur dari tanaman tersebut. Pigmen fotosintetik, seperti klorofil, berperan penting dalam proses fotosintesis dan dapat memberikan wawasan tentang kesehatan dan aktivitas metabolik tanaman. Perubahan dalam warna pigmen dapat mencerminkan perubahan dalam proses fisiologis, respons terhadap stres, dan tahap umur tanaman. Terdapat tiga jenis pigmen pada daun, yaitu klorofil, karotenoid, dan antosianin. Klorofil adalah kandungan yang menyebabkan warna hijau pada daun, klorofil ini menyerap energi dari matahari untuk memfasilitasi proses fotosintesis pada tumbuhan. Karotenoid dibagi menjadi dua, yaitu karoten dan xantofil. Karoten adalah pigmen yang menyebabkan warna jingga, sedangkan xantofil adalah pigmen yang menyebabkan warna kuning. Antosianin adalah pigmen yang memberikan warna merah. Pigmen daun pada tanaman, seperti klorofil, karotenoid, dan antosianin, memiliki hubungan yang erat dengan fungsi stress pada tanaman jeruk. Ketika tanaman jeruk mengalami stres, pigmen daun ini dapat menunjukkan respons yang berbeda-beda

Fungsi stress pada tanaman yang biasanya diterapkan terhadap beberapa tanaman untuk memicu produksi buah yang lebih cepat. Stress pada tanaman ini merujuk pada kondisi yang membuat tanaman tidak nyaman sehingga memicu

berbagai kondisi untuk tanaman beradaptasi seperti mempercepat produksi buah karena buah merupakan cara tanaman untuk menyimpan energi atau mengubah distribusi sumber daya yang awalnya pada pertumbuhan vegetatif menjadi fokus dalam pembentukan dan kematangan buah. Adapun beberapa stress yang dapat dilakukan seperti kekurangan air, kerusakan oleh hama atau penyakit, suhu, dll. Termotoleransi menunjukkan kemampuan suatu tanaman untuk bertahan hidup pada suhu yang sangat tinggi atau rendah dan menghasilkan hasil yang ekonomis (Alsamir et al., 2021)

Tumbuhan jeruk keprok 555 membutuhkan waktu yang lama untuk berbuah, pohon jeruk Keprok membutuhkan setidaknya 4 tahun untuk berbuah. Karena itu dilakukannya metode Pijat Lengkung (Pikung) dengan tujuan untuk memperbaiki sirkulasi air dan nutrisi, serta membantu merangsang pertumbuhan tanaman. Teknik ini dilakukan dengan pemijatan atau sentuhan lembut pada bagian-bagian tertentu pada batang dan cabang tanaman jeruk. Hasil dari metode pikung ini yaitu akan muncul bunga pada pohon setelah 2-3 bulan perlakuan dan akan muncul buah umur 2 minggu setelah bunga mekar. Keberhasilan melakukan metode Pikung ini yakni pohon jeruk dapat berbuah lebat walau usia pohon masih 2,5 tahun (Bardono, 2018)

Namun, teknik ini memiliki potensi terdapat kendala dalam ketepatan waktu pikung yang kurang optimal. Terdapat kemungkinan bahwa petani terlambat melakukan metode pikung atau terlalu cepat melakukan metode pikung berakibat pohon jeruk tidak berbuah dengan baik. Oleh karena itu, diperlukan pengembangan teknologi yang dapat menentukan waktu pikung dengan akurasi yang lebih baik. Salah satu pendekatan yang dapat digunakan adalah dengan menganalisis warna pada citra daun. Penelitian sebelumnya telah dilakukan oleh (Atmodjo, 2022) yakni tentang prediksi kandungan pigmen fotosintesis yang berfokus pada analisis warna pigmen dan mungkin memiliki relevansi yang tinggi dengan masalah yang ingin diselesaikan. Dengan mengintegrasikan penelitian terdahulu dan mengembangkan pendekatan yang tepat, diharapkan dapat mencapai hasil yang lebih baik dalam menentukan waktu pikung secara akurat.

## **1.2 Identifikasi Masalah**

Berdasarkan latar belakang yang telah disampaikan, dapat diperoleh identifikasi masalah bahwa profil warna pigmen daun merepresentasikan metabolisme dan umur pada tumbuhan. Namun, dalam konteks metode pikung pada tanaman jeruk, terdapat permasalahan dalam ketepatan waktu melakukan pikung, yang berpotensi menyebabkan kegagalan dalam pembungaan dan pembuahan pada tanaman jeruk.

## **1.3 Batasan Masalah**

Adapun Batasan masalah dalam pengerjaan proyek tugas akhir ini antara lain sebagai berikut:

- a. Lokasi pengambilan sampel untuk dataset berada di perkebunan jeruk di Pandanrejo, Kec. Bumiaji, Kota Batu, Jawa Timur.
- b. Jenis jeruk yang digunakan hanya jeruk Keprok 555,
- c. Pengambilan sampel dataset dilakukan menggunakan kamera *smartphone*.
- d. Bahasa pemrograman yang digunakan untuk pemrograman *Deep Learning* CNN adalah Python.
- e. Menggunakan alat Colorimeter sebagai alat validasi nilai sebenarnya dari warna daun.

## **1.4 Rumusan Masalah**

Adapun rumusan masalah dari proyek tugas akhir ini yaitu:

- a. Bagaimana menentukan tingkat keberhasilan metode pikung berdasarkan jumlah bunga yang dihasilkan?
- b. Bagaimana membangun aplikasi berbasis Android yang dapat menentukan tingkat keberhasilan pikung pada tanaman jeruk secara praktis dan efisien?



### **1.5 Tujuan Penelitian**

Adapun tujuan dari proyek tugas akhir ini berdasarkan rumusan masalah yaitu sebagai berikut:

- a. Membuat model CNN untuk penentuan waktu yang tepat untuk pikung berdasarkan jumlah bunga yang muncul pada tanaman jeruk.
- b. Membangun aplikasi berbasis android dan mengimplementasikan model CNN pada aplikasi yang dapat memberikan persentase tingkat keberhasilan metode pikung.

### **1.6 Manfaat Penelitian**

- a. Bagi masyarakat yaitu dapat menggunakan aplikasi untuk mempermudah petani jeruk dalam penentuan waktu pikung
- b. Bagi pembaca yaitu dapat digunakan sebagai bahan refrensi mengenai penentuan waktu pikung dengan CNN untuk belajar maupun kajian penelitian yang akan dilakukan.
- c. Bagi Penulis yaitu menambah dan memperluas wawasan mengenai rancang bangun aplikasi android untuk penentuan waktu pikung dengan CNN.

### **1.7 Luaran Penelitian**

Luaran dari penelitian ini adalah aplikasi berbasis android untuk melakukan deteksi waktu pikung pada tanaman jeruk dengan menggunakan metode CNN dan publikasi ilmiah.

### **1.8 Sistematika Penulisan**

Sistematika dalam penulisan proposal Tugas Akhir ini akan dibagi menjadi lima bab sebagai berikut.

#### **Bab I Pendahuluan**

Bab Pendahuluan ini akan membahas latar belakang, identifikasi masalah, batasan masalah, tujuan penelitian, manfaat penelitian, luaran Tugas Akhir, dan sistematika penulisan.

#### **Bab II Tinjauan Pustaka**

Bab tinjauan pustaka ini secara sistematis menguraikan literatur yang relevan dengan pembangunan Tugas Akhir, yang bertujuan untuk memperoleh landasan teori terkait dengan *Convolutional Neural Network* (CNN), platform Android, dan metode pikung pada tanaman Jeruk.

### Bab III Analisis dan Perancangan Sistem

Bab ini menguraikan tahapan pengerjaan serta analisis perancangan awal sistem yang akan dikembangkan. Tahapan ini mencakup identifikasi masalah, studi pustaka, pengumpulan data, *profiling*, desain sistem, serta pengembangan dan pengujian aplikasi.

### Bab IV Hasil dan Pembahasan

Bab ini menyajikan hasil-hasil dari tahapan pengerjaan serta analisis sistem yang telah dilakukan. Dalam bab ini, terdapat penjelasan mengenai identifikasi masalah, studi pustaka, pengumpulan data, *profiling*, desain sistem, serta pengembangan dan pengujian aplikasi.

### Bab V Kesimpulan dan Saran

Bab ini merupakan rangkuman simpulan dari hasil penelitian Tugas Akhir yang telah dilakukan, serta menyajikan saran-saran yang dapat diterapkan untuk meningkatkan sistem aplikasi dalam penelitian selanjutnya.

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Pigmen Tanaman**

Pigmen merupakan senyawa organik yang ada pada tumbuhan. Peran pigmen dalam tumbuhan yaitu ada dalam proses fotosintesis. Adapun beberapa jenis pigmen tumbuhan antara lain klorofil, karotenoid, dan antosianin. Klorofil merupakan pigmen tanaman yang memberikan warna hijau pada daun. Klorofil menyerap sinar matahari dan mengubah menjadi energi kimia yang digunakan dalam proses fotosintesis. Karotenoid adalah pigmen tanaman yang memberikan warna kuning, oranye, atau merah pada daun. Selain itu, pigmen ini juga berperan sebagai antioksidan dan dapat melindungi tumbuhan dari kerusakan akibat sinar UV. Antosianin adalah pigmen tanaman yang memberikan warna merah, ungu, atau biru pada buah dan sayuran. Pigmen ini juga berperan sebagai antioksidan dan dapat melindungi tumbuhan dari kerusakan akibat sinar UV.

#### **2.2 Tanaman Jeruk**

Tanaman jeruk (*Citrus spp*) merupakan salah satu tanaman buah di Indonesia yang memiliki nilai ekonomi yang tinggi karena sebagai sumber vitamin C dan bahan baku industri makanan dan minuman. Tanaman jeruk biasanya ditanam di daerah tropis dan subtropis. Adapun jenis-jenis jeruk yang sering kita jumpai yaitu :

a. Jeruk Manis (*Citrus sinensis*)

Jeruk manis memiliki buah yang besar dengan kulit jeruk yang tebal dan daging buah yang manis. Jeruk manis banyak digunakan sebagai buah segar dan bahan baku minuman. Beberapa penelitian menunjukkan bahwa ekstrak jeruk mengandung senyawa bioaktif yang berpotensi sebagai antioksidan dan agen antiinflamasi yang dapat membantu mengurangi risiko penyakit kardiovaskular (Park et al., 2018; Yu et al., 2020).

b. Jeruk Nipis (*Citrus aurantifolia*)

Jeruk nipis merupakan salah satu buah jeruk yang paling populer di Indonesia. Buah jeruk nipis kecil dengan kulit kuning kehijauan dan daging asam. Jeruk nipis banyak digunakan sebagai bahan baku industri makanan, minuman dan kosmetik. Beberapa penelitian telah dilakukan tentang nilai gizi dan manfaat jeruk nipis bagi kesehatan, seperti sifat antioksidan dan antiinflamasinya (Misra, Dwivedi, & Misra, 2017; Manikandan et al., 2020).

c. Jeruk keprok (*Citrus reticulata Blanco*)

Jeruk keprok merupakan jenis jeruk yang sangat populer di Indonesia. Buah mandarin kecil dengan kulit tipis dan daging manis. Jeruk mandarin banyak digunakan sebagai bahan minuman dan makanan ringan. Beberapa penelitian menunjukkan bahwa ekstrak jeruk keprok mengandung senyawa bioaktif yang berpotensi sebagai antioksidan dan dapat membantu melindungi sel tubuh dari kerusakan oksidatif (El-Guendouz et al., 2021; Siddique et al., 2021).



Gambar 2. 1 Tanaman daun jeruk keprok

### 2.3 Metode Pijat Lengkung (Pikung)

Pikung atau pijat lengkung merupakan teknik yang digunakan untuk meningkatkan pertumbuhan dan kesehatan tanaman. Cara ini dilakukan dengan memijat atau menekan secara lembut di area cabang dan batang pada tanaman.

Tanaman yang sudah dipikung nantinya akan terlihat bengkok atau merunduk. Dengan dilakukan Pikung ini diharapkan akan meningkatkan pertumbuhan dan Kesehatan tanaman, selain itu juga diharapkan dapat menghasilkan produksi buah yang lebih baik dan cepat.

Petani sering mengalami masalah ketika pohon jeruk mereka belum berbuah meskipun sudah melewati usia berbuah yang seharusnya. Jeruk Siam, yang dapat berbuah dalam waktu 2-3 tahun, sering menjadi pilihan petani karena waktu produksinya yang lebih singkat. Namun, jeruk Keprok memiliki nilai ekonomis yang lebih tinggi karena permintaan pasar yang tinggi untuk jeruk impor jenis Keprok. Untuk mengatasi masalah lamanya produksi jeruk, petani dapat menerapkan metode pemijatan dan pelengkungan atau pikung pada percabangan pohon jeruk. Metode ini telah berhasil diuji di Kebun Percobaan Banaran oleh Balai Penelitian Tanaman Jeruk dan Buah Subtropika. Hasilnya menunjukkan bahwa jeruk Keprok dapat berbuah pada usia 2,5 tahun dengan hasil produksi rata-rata sebesar 25 kilogram per pohon. Dengan menerapkan teknik ini, petani dapat meningkatkan efisiensi produksi jeruk Keprok dan memperoleh hasil yang lebih cepat dan lebih menguntungkan (Bardono, 2018).



Gambar 2. 2 Tanaman jeruk keprok setelah di pikung

Sumber : <https://technology-indonesia.com/pertanian-dan-pangan/inovasi-pertanian/berkat-metode-pikung-tanaman-jeruk-umur-30-bulan-mampu-berbuah-lebat/>

## 2.4 Lux Meter

Lux meter adalah alat yang digunakan untuk mengukur tingkat kecerahan atau intensitas cahaya yang ada di suatu area dalam satuan lux. Lux meter ini bekerja dengan membandingkan jarak sumber cahaya dengan sensor. Semakin jauh jarak sumber cahaya dengan sensor Lux Meter, maka intensitas cahaya akan semakin berkurang, begitu pula sebaliknya.



Gambar 2. 3 Lux meter

## 2.5 Colorimeter

Colorimeter adalah alat yang digunakan untuk mengukur warna suatu benda. Ketika suatu objek menyerap sebagian cahaya yang melewatinya dan akibatnya jumlah cahaya yang dipantulkan dari lingkungan berkurang. Dengan alat ini, cahaya yang diserap suatu benda kemudian ditentukan warnanya berdasarkan komponen merah, hijau, dan biru. Alat ini bekerja berdasarkan hukum Beer-Lambert, yang menyatakan bahwa penyerapan cahaya yang melewati suatu medium berbanding lurus dengan konsentrasi medium tersebut. Satuan dari Colorimeter ini adalah LAB. Satuan LAB adalah sistem pengukuran warna dalam ruang warna CIELAB. Ruang warna ini digunakan untuk menggambarkan secara numerik atribut-atribut warna seperti kecerahan (L), warna merah-kekuningan hingga hijau, dan warna kebiruan hingga kuning (B). L memiliki nilai berkisar 0



hingga 100, dengan 0 mewakili warna hitam dan 100 mewakili warna putih. A memiliki nilai berkisar -128 hingga 127, dengan nilai positif menunjukkan warna merah-kekuningan dan nilai negatif menunjukkan warna hijau-kebiruan. B memiliki nilai berkisar -128 hingga 127 dengan nilai positif menunjukkan warna biru-kebiruan dan nilai negatif menunjukkan warna kuning.



Gambar 2. 4 Colorimeter

## 2.8 *Visible Atmospherically Resistant Index (VARI)*

VARI adalah metode mengukur kepadatan dan klorofil pada tanaman dengan menggunakan informasi spektral pada daun yang terlihat (*visible spectrum*). Metode ini digunakan untuk mengatasi gangguan dari atmosfer yang dapat mempengaruhi akurasi pengukuran klorofil pada tanaman. VARI menghitung perbedaan rasio antara intensitas cahaya merah dan intensitas cahaya hijau pada daun. Perbedaan ini mencerminkan kandungan klorofil dalam daun, yang

merupakan indikator penting dari kesehatan dan produktivitas tanaman. Rumus untuk perhitungan VARI adalah sebagai berikut:

$$VARI = (G - R)/(G + R - B) \quad (2-1)$$

Pada rumus G dipresentasikan dengan *Green* atau intensitas cahaya hijau pada daun, R dipresentasikan *Red* atau intensitas cahaya merah pada daun, dan B dipresentasikan dengan *Blue* atau intensitas cahaya biru pada daun. Nilai VARI berkisar antara -1 hingga +1. Nilai positif menunjukkan adanya kandungan klorofil yang lebih tinggi, sementara nilai negatif menunjukkan adanya gangguan atmosfer atau gangguan lainnya pada pengukur. Metode ini membantu mengestimasi tingkat klorofil dan kepadatan tanaman dengan mengukur perbedaan rasio intensitas cahaya pada spektrum visible. Informasi ini dapat digunakan untuk memantau kesehatan tanaman, mendeteksi stres pada tanaman, mengoptimalkan pemupukan dan penggunaan pestisida, serta membantu dalam pengambilan keputusan untuk meningkatkan produktivitas pertanian.

## 2.9 Java

Java adalah bahasa pemrograman yang dikembangkan oleh James Gosling dan timnya pada tahun 1995. Bahasa pemrograman ini sangat populer dan fleksibel dikarenakan dapat dijalankan di berbagai platform, dukungan library yang banyak, dan fitur-fitur yang mempermudah berbagai proyek pengembangan aplikasi.

## 2.10 Python

Python adalah bahasa pemrograman tingkat tinggi yang populer dan mudah dipelajari. Bahasa ini diciptakan pada tahun 1991 oleh Guido van Rossum dan dikembangkan sebagai bahasa *open-source*. Python juga menjadi salah satu bahasa pemrograman yang populer di kalangan pengembang machine learning dan data science, karena dukungan untuk library seperti NumPy, Pandas, Matplotlib, dan TensorFlow.



## 2.11 Google Colaboratory

Google Colaboratory, atau lebih dikenal dengan sebutan "Colab", adalah sebuah platform pengembangan dan pengujian model machine learning yang disediakan secara gratis oleh Google. Colab menyediakan lingkungan pengembangan berbasis cloud yang berjalan di browser dan terintegrasi dengan Google Drive. Colab juga memungkinkan pengguna untuk berkolaborasi secara real-time dengan orang lain dalam satu dokumen, sehingga memudahkan dalam melakukan sharing dan presentasi proyek machine learning.

## 2.12 Augmentasi Data

penerapan teknik ini bertujuan menciptakan variasi dalam dataset, membantu model mengenali objek pada berbagai situasi, dan mencegah overfitting. Teknik augmentasi ini dirancang untuk memberikan model pengalaman yang lebih beragam dan meningkatkan ketangguhannya terhadap variasi dalam data pengujian. Adapun augmentasi yang dilakukan pada penelitian ini yaitu:

### A. rotation\_range

Teknik rotasi memungkinkan citra untuk diputar dalam rentang tertentu. Hal ini membantu model untuk dapat mengenali objek pada berbagai orientasi dan memperkaya variasi sudut pandang pada data pelatihan

### B. shear\_range

Shear range mengizinkan penggeseran sudut citra. Dengan melakukan shearing, model dapat belajar mengenali bentuk dan pola yang mungkin muncul pada sudut pandang yang sedikit miring

### C. zoom\_range

Zoom range memungkinkan perbesaran atau perkecilan citra. Ini bermanfaat untuk membantu model dalam menangani variasi jarak objek dalam citra dan meningkatkan ketahanannya terhadap perubahan skala

### D. horizontal\_flip

Horizontal flip menciptakan citra simetris dari citra asli dengan membaliknya secara horizontal. Teknik ini membantu model dalam mengenali objek yang mungkin muncul dalam orientasi yang berlawanan

E. `width_shift_range` dan `height_shift_range`

Teknik ini memungkinkan pergeseran citra ke kiri atau kanan (`width shift`) dan ke atas atau ke bawah (`height shift`). Pergeseran ini membantu model mengenali objek pada posisi yang berbeda dalam citra

### 2.13 Transfer Learning

Transfer Learning merupakan metode ataupun teknik yang menggunakan model pre-trained (sudah dilatih terhadap suatu dataset) untuk menyelesaikan permasalahan lain yang serupa dengan cara menggunakannya sebagai starting point, lalu memodifikasi dan mengupdate parameternya sehingga sesuai dengan dataset kasus permasalahan yang baru (Sena, 2018). Penerapan transfer learning pada CNN biasanya terdiri dari dua tahap utama:

1. **Pretraining:** Pada tahap ini, sebuah model CNN dilatih pada dataset yang besar dan beragam, seperti ImageNet, untuk mempelajari representasi fitur-fitur yang umum pada gambar, seperti garis-garis, tekstur, dan pola-pola yang kompleks.
2. **Fine-tuning:** Setelah model dasar dilatih, tahap selanjutnya adalah melakukan fine-tuning model tersebut pada dataset yang lebih spesifik untuk tugas tertentu. Pada tahap ini, beberapa lapisan terakhir dari model CNN biasanya akan dilatih kembali (*fine-tuned*) pada dataset yang baru, sedangkan lapisan-lapisan awal yang telah belajar fitur-fitur umum tetap dipertahankan.

Sebagai contoh untuk penerapan Transfer Learning yaitu diawali menggunakan model VGG16 yang dilatih pada dataset ImageNet yang terdiri dari jutaan gambar yang dibagi menjadi ribuan kategori, Model VGG16 ini dipelajari untuk mengenali fitur-fitur umum dari berbagai macam gambar, seperti bentuk, tekstur, dan warna. Setelah melatih model VGG16 pada ImageNet, model tersebut kemudian diubah untuk memecahkan masalah klasifikasi gambar medis, misalnya

untuk mengenali penyakit pada gambar rontgen. Beberapa lapisan terakhir dari model VGG16 dilatih kembali pada dataset klasifikasi gambar medis untuk menyesuaikan representasi fitur-fitur yang telah dipelajari pada dataset yang baru ini. Contoh ini mengilustrasikan bagaimana transfer learning memungkinkan pemanfaatan kembali pengetahuan yang sudah dipelajari oleh model pada tugas yang berbeda, sehingga mengurangi kebutuhan akan data pelatihan yang besar dan waktu komputasi yang lama.

## **2.14 Convolutional Neural Network (CNN)**

*Convolutional Neural Network* atau disingkat CNN merupakan salah satu algoritma deep learning yang populer digunakan di berbagai bidang khususnya dalam pengenalan gambar dan pengolahan citra. CNN bekerja dengan menggunakan lapisan *convulotional*, *pooling*, dan *fully connected*. Setiap lapisan pada CNN memiliki fungsi yang berbeda – beda. Fungsi dari lapisan *convulotional* yaitu untuk mendeteksi fitur visual pada input. Lalu fungsi lapisan *pooling* untuk mengurangi dimensi spasial dan melatih jaringan menjadi invariant terhadap pergeseran dan distorsi, dan fungsi lapisan *fully connected* untuk klasifikasi. Adapun struktur tata letak dari layer-layer atau disebut arsitektur di CNN dikembangkan dengan tujuan meningkatkan performa menjadi lebih baik dan efisiensi sumber daya.

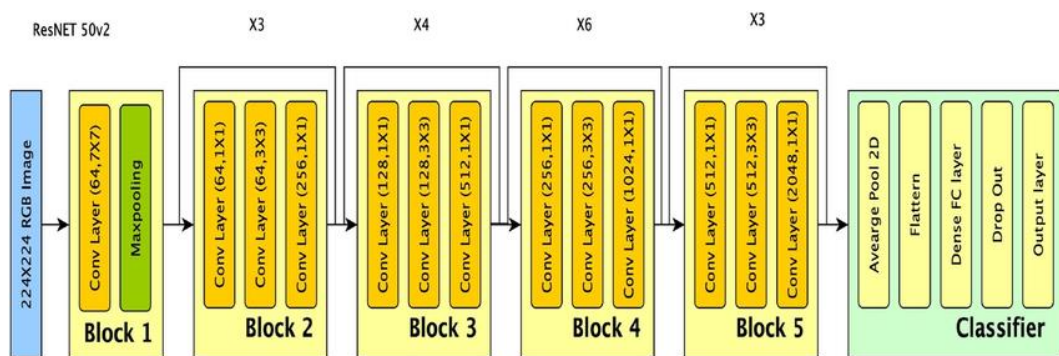
### **2.14.1 Arsitektur**

Arsitektur pada CNN ini merupakan struktur atau tata letak dari layer – layer ,terdapat beberapa arsitektur terkenal yang sering digunakan untuk melakukan pengenalan gambar, terdapat 4 arsitektur yang akan digunakan pada penelitian ini yaitu:

#### **1. ResNet50V2**

Arsitektur ResNet-50 V2 merupakan suatu jenis model jaringan saraf konvolusional (CNN) yang merupakan varian dari ResNet (Residual Network) yang dikembangkan untuk meningkatkan kinerja dan pelatihan jaringan saraf.


ResNet-50 V2 terdiri dari 50 lapisan (layer) utama dan mengintegrasikan konsep blok residu. Fitur utama dari arsitektur ini adalah penggunaan blok residu, yang memungkinkan aliran informasi melalui lapisan-lapisan jaringan dengan cara yang lebih efisien. Blok residu memanfaatkan shortcut connections (konektor pendek) untuk melompati satu atau beberapa lapisan, memungkinkan aliran mundur (backpropagation) yang lebih efektif selama pelatihan. Secara umum, arsitektur ResNet-50 V2 dikenal karena kemampuannya mengatasi masalah degradasi yang terjadi ketika jaringan menjadi terlalu dalam. Keberhasilannya dalam tugas-tugas seperti klasifikasi gambar membuatnya menjadi pilihan yang populer dalam berbagai aplikasi.



Gambar 2. 5 Arsitektur ResNet50V2

## 2. VGG16

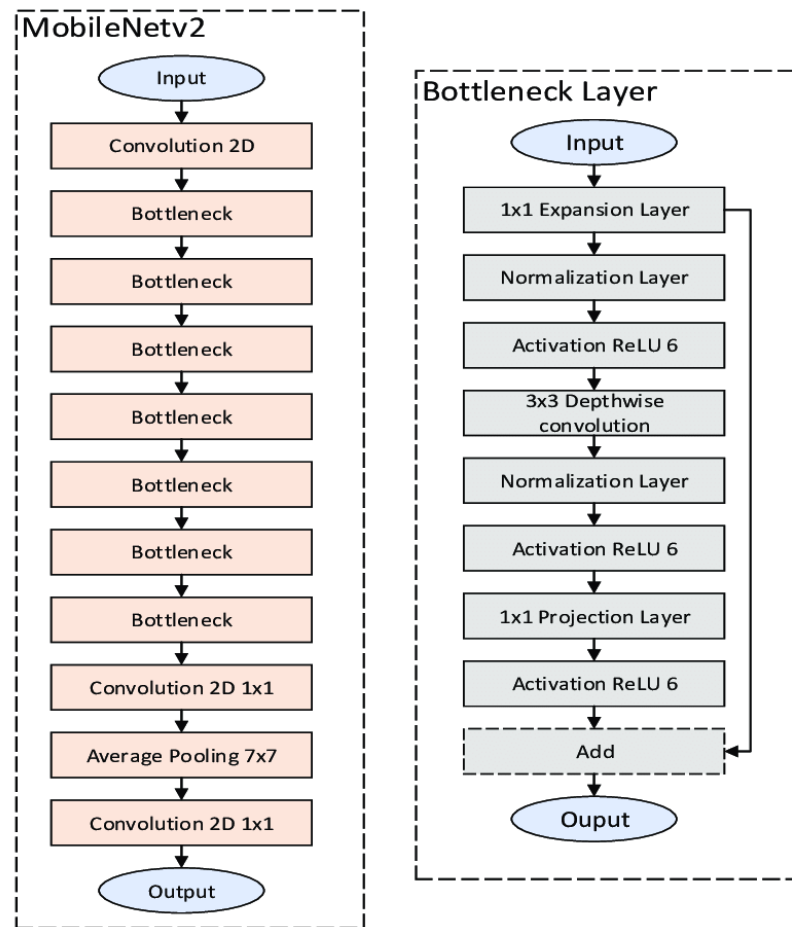
Arsitektur VGG16 merupakan salah satu arsitektur jaringan saraf konvolusional (CNN) yang populer dan efektif dalam tugas-tugas pengenalan gambar. Arsitektur ini pertama kali diperkenalkan oleh *Visual Geometry Group* (VGG) pada tahun 2014. VGG16 terdiri dari 16 lapisan konvolusional dan fully connected yang memanfaatkan filter konvolusional kecil (3x3) secara berulang-ulang, yang diikuti oleh lapisan max pooling untuk mengekstraksi fitur-fitur gambar dengan cara yang mendalam.



Gambar 2. 6 Arsitektur VGG16

### 3. MobileNetV2

MobileNetV2 adalah sebuah arsitektur jaringan saraf tiruan yang dirancang khusus untuk aplikasi dengan sumber daya terbatas, seperti perangkat seluler. Dikembangkan oleh Google, MobileNetV2 memiliki struktur yang ringan, efisien, dan dapat diimplementasikan pada perangkat dengan daya komputasi terbatas. Arsitektur ini dikenal karena menggabungkan teknik-teknik seperti depthwise separable convolution dan linear bottleneck untuk mencapai performa tinggi dengan ukuran model yang kecil. MobileNetV2 bertujuan untuk meningkatkan efisiensi komputasi dan ukuran model dibandingkan dengan arsitektur pendahulunya, MobileNetV1. Depthwise separable convolution, salah satu konsep kunci dalam MobileNetV2, membagi konvolusi menjadi dua langkah terpisah: konvolusi spatialis dan konvolusi depthwise. Hal ini mengurangi jumlah parameter dan komputasi yang dibutuhkan.




Gambar 2. 7 Arsitektur MobileNetV2

#### 4. InceptionV3

Arsitektur InceptionV3, yang dikembangkan oleh tim penelitian Google, merupakan salah satu arsitektur Convolutional Neural Network (CNN) yang canggih untuk tugas pengenalan gambar. InceptionV3 dikenal karena kemampuannya mengatasi tantangan dalam pengenalan objek pada berbagai skala dan tingkat kompleksitas.

Sayyed and Kulkarni (2019) menjelaskan bahwa InceptionV3 mengusung pendekatan inovatif dengan menggunakan modul Inception, yang terdiri dari beberapa jalur konvolusi yang beroperasi secara paralel. Modul Inception ini memungkinkan jaringan untuk secara efektif mengekstraksi fitur dari berbagai resolusi dan tingkat kompleksitas, memberikan kemampuan adaptasi yang lebih baik terhadap variasi objek dalam gambar.

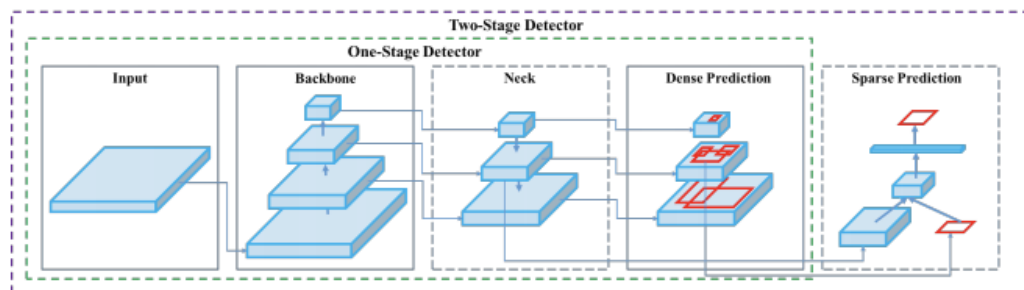


Gambar 2. 8 Arsitektur InceptionV3

## 5. YoloV5

YOLOv5 adalah model deteksi objek yang menggunakan *convolutional neural network* (CNN) sebagai backbone network untuk mengekstraksi fitur dari gambar. Model ini menggunakan piramida fitur untuk mendeteksi objek pada berbagai tingkat resolusi dalam gambar. Bagian deteksi menghasilkan kotak pembatas dan skor kepercayaan untuk setiap objek yang terdeteksi, diikuti dengan penggunaan algoritma *Non-Maximum Suppression* (NMS) untuk menghilangkan kotak pembatas yang tumpang tindih.

Hasil deteksi kemudian dapat disaring dan diproses lebih lanjut untuk meningkatkan presisi. Proses pelatihan melibatkan optimisasi parameter model menggunakan data latih yang diberi label untuk menghasilkan model yang akurat dalam mendeteksi objek pada gambar baru.



Gambar 2. 9 Arsitektur YoloV5

### 2.14.2 *Optimizer*

*Optimizer* pada CNN adalah algoritma yang digunakan untuk mengoptimalkan proses pelatihan atau training model CNN. *Optimizer* ini digunakan dengan tujuan menemukan nilai – nilai parameter model yang optimal sehingga meminimalisir fungsi *loss* atau error antara output yang diprediksi. Adapun 2 *Optimizer* yang digunakan, yaitu:

1. Adam

Adam (Adaptive Moment Estimation) adalah algoritma optimasi yang menggabungkan estimasi momentum pertama dan kedua untuk melacak pergerakan gradien pada setiap parameter. Algoritma ini menggunakan adaptif learning rate, yang disesuaikan secara otomatis berdasarkan pergerakan gradien. Hal ini memungkinkan penyesuaian learning rate yang lebih baik dan membantu menghindari learning rate yang terlalu besar atau terlalu kecil. Adam juga mendukung regularisasi L2 untuk mencegah overfitting. Keunggulan Adam termasuk kemampuan mengatasi permukaan gradien yang berbeda-beda dan konvergensi yang cepat.

2. AdamMax

Adamax adalah variasi dari algoritma optimasi Adam yang menggunakan estimasi momentum pertama untuk melacak pergerakan gradien. Algoritma ini memiliki adaptif *learning rate* dan normalisasi gradien dengan norma max. Adamax mampu mengatasi masalah gradien yang meledak dan dapat digunakan dalam berbagai tugas dan *arsitektur neural network*.

### 2.14.3 *Loss*

*Loss* pada CNN adalah ukuran yang digunakan untuk mengukur perbedaan antara output dengan nilai target sebenarnya. *Loss* ini digunakan sebagai acuan untuk mengoptimalkan parameter model selama proses pelatihan dengan tujuan meminimalkan kesalahan prediksi. Selama proses pelatihan, model CNN diperbarui



secara iteratif dengan memperhitungkan nilai *loss* dan mengoptimalkan parameter model menggunakan teknik seperti *backpropagation* dan *optimizer*. Tujuan utamanya adalah meminimalkan fungsi *loss* sehingga model dapat menghasilkan output yang semakin dekat dengan nilai target yang sebenarnya.

Pemilihan fungsi *loss* yang tepat tergantung pada jenis tugas yang dihadapi dan karakteristik dataset yang digunakan. Pemilihan yang tepat dapat membantu model untuk menghasilkan prediksi yang lebih akurat dan meningkatkan performa keseluruhan dari model CNN

#### 2.14.4 *Confusion Matrix*

*Confusion matrix* adalah alat evaluasi yang penting dalam analisis kinerja model klasifikasi. Tabel ini memberikan gambaran yang jelas tentang seberapa baik model dapat mengklasifikasikan data ke dalam setiap kelas target yang ada. Pada penelitian ini akan menggunakan confusion matrix dengan ukuran 3x3 karena terdapat tiga kelas target yang akan dievaluasi. Tabel *confusion matrix* akan terdiri dari tiga baris dan tiga kolom, mewakili tiga kelas yang diamati dalam penelitian ini. Diagonal utama dari matriks akan menunjukkan jumlah observasi yang benar diklasifikasikan oleh model untuk setiap kelas target. Diagonal luar dari matriks akan menunjukkan jumlah observasi yang salah diklasifikasikan untuk setiap kombinasi kelas.

		Predicted Label		
True Label		a	b	c
	d	d	e	f
	g	g	h	i

Gambar 2. 10 Tabel *Confusion Matrix*

Pada matriks terdapat *True Positive* (TP) yang menunjukkan jumlah data yang diklasifikasikan kelas yang benar oleh model, *True Negative* (TN) yang menunjukkan jumlah data yang diklasifikasikan kelas yang salah oleh model, *False Positive* (FP) yang menunjukkan jumlah data yang salah namun diklasifikasikan kelas yang benar oleh model, dan *False Negative* (FN) yang menunjukkan jumlah data yang benar namun diklasifikasikan kelas yang salah oleh model. *Confusion Matriks* membantu menganalisis seberapa jauh model berhasil dalam melakukan klasifikasi pada setiap kelas target. Selain itu, terdapat beberapa metrik evaluasi yang berguna dalam mengevaluasi kinerja model, antara lain:

a. *Precision*

*Precision* mengukur seberapa akurat model dalam mengidentifikasi *instance* positif dari semua *instance* yang diprediksi positif.

$$Precision = \frac{TP}{TP + FP} \quad (2- 2)$$

b. *Recall*

*Recall* mengukur seberapa baik model dalam menemukan semua *instance* positif.

$$Recall = \frac{TP}{TP + FN} \quad (2- 3)$$

c. *F1 Score*

*F1 Score* adalah ukuran yang menggabungkan *precision* dan *recall* menjadi satu nilai. Nilai *F1 score* yang tinggi menunjukkan bahwa model memiliki keseimbangan yang baik antara *precision* dan *recall* Menon dkk.,(2019).

$$F1\ Score = \frac{2}{\frac{1}{Precision} + \frac{1}{Recall}} = \frac{2 * (Precision * Recall)}{(Precision + Recall)} \quad (2- 4)$$

### **2.15 Android Studio**

Android Studio merupakan Integrated Development Environment (IDE) untuk mengembangkan aplikasi android. Dalam pengembangan aplikasi Android, Android Studio menyediakan fitur-fitur yang sangat berguna seperti debugging, emulasi perangkat, manajemen kode sumber, tampilan desain, dan banyak lagi. Android Studio juga menyediakan plugin dan framework yang berguna untuk memperluas fungsionalitas dari aplikasi yang dibuat.

### **2.16 Penelitian terdahulu**

Siahaan dkk.,(2020) merancang sebuah sistem yang dapat memantau dan mengontrol pemupukan pada budidaya tanaman tomat menggunakan CNN. Melalui pengambilan gambar daun menggunakan kamera dan pengolahan citra, sistem ini dapat mendeteksi kekurangan unsur hara pada tanaman berdasarkan warna daun. Dengan demikian, penerapan pupuk yang dibutuhkan dapat dioptimalkan, menghemat konsumsi pupuk tanpa mengurangi kualitas produksi. Hasil dari eksperimen dan implementasi alat menunjukkan bahwa sistem ini mampu mengklasifikasi dan memberikan pupuk pada tanaman dengan akurasi deteksi warna daun mencapai 87%.


Ginawa dkk.,(2020) merancang dua model CNN yaitu AlexNet dan ResNet. Masing-masing model digunakan untuk menguji sekelompok gambar yang terdiri dari daun jeruk yang sehat dan berbagai jenis penyakit daun jeruk, seperti *Phyllocnistis citrella*, kekurangan elemen, dan serangga skala. Hasil pengujian menunjukkan bahwa model AlexNet memberikan akurasi terbaik dengan penggunaan data augmentasi sebesar 97.92%, sementara model ResNet memberikan akurasi sebesar 95.83%. Sementara itu, hasil pengujian tanpa menggunakan data augmentasi memberikan akurasi yang sedikit lebih rendah, yaitu 95.83% untuk AlexNet dan 93.75% untuk ResNet. Dari hasil ini, peneliti menyimpulkan bahwa melatih model jaringan saraf *deep learning* dengan lebih banyak data akan menghasilkan model yang lebih terampil. Teknik augmentasi data juga menghasilkan variasi gambar yang dapat meningkatkan kemampuan model untuk menggeneralisir apa yang telah dipelajari ke gambar-gambar baru.

## **BAB III**

### **ANALISIS DAN PERANCANGAN SISTEM**

#### **3.1 Alur Penelitian**

Pengerjaan proyek tugas akhir ini bertujuan untuk merancang dan membangun aplikasi pendeteksi waktu pikung yang tepat. Alur penelitian proyek ini dapat dilihat pada gambar 3.1.



Gambar 3. 1 Alur penelitian

Tahap awal pada penelitian ini yaitu dimulai dengan memahami permasalahan yang ada di lapangan. dilanjutkan dengan studi pustaka, mencari jurnal dan artikel dari penelitian-penelitian terdahulu yang berkaitan dengan permasalahan penelitian yang sedang dilakukan. Lalu dilanjutkan dengan pengumpulan data di lapangan. Lalu dilanjutkan dengan *profiling* pada data dengan tujuan mendapatkan perbedaan dari setiap kategori. Selanjutnya yaitu melakukan perancangan model CNN yang nantinya akan digunakan untuk perancangan aplikasi prediksi waktu pikung.

### **3.2 Identifikasi Masalah**

Adapun masalah yang dihadapi yaitu Teknik pijat lengkung atau pikung ini tidak selalu berhasil dikarenakan butuh ketepatan waktu saat melakukan teknik ini. Oleh karena itu, dibutuhkan aplikasi yang memprediksi waktu yang tepat untuk melakukan Teknik pikung ini hanya dilihat dari citra daunnya saja.

### **3.3 Analisis Kebutuhan**

Untuk merancang sistem aplikasi berbasis Android dengan baik dan tepat, analisis yang komprehensif diperlukan. Analisis ini melibatkan pemahaman mendalam terhadap kebutuhan perangkat dari perspektif pengguna dan peneliti. Dengan melakukan analisis ini, proyek dapat dilakukan secara efisien dan memastikan bahwa aplikasi yang dihasilkan memenuhi standar yang diharapkan serta memenuhi kebutuhan utama para pengguna dan peneliti.

#### **3.3.1 Kebutuhan Pengguna**

Kebutuhan pengguna aplikasi prediksi waktu pikung tanaman jeruk ini adalah menggunakan *smartphone*. Pengguna nantinya hanya perlu mengambil citra daun jeruk dari aplikasi. Setelah itu aplikasi nantinya akan merekomendasikan apakah tanaman sudah siap dipikung atau tidak.

### **3.3.2 Kebutuhan Peneliti**

Berikut adalah perangkat yang digunakan peneliti untuk membantu proyek yang dilakukan.

#### **a. Perangkat Keras**

1. Samsung Galaxy A53 5G
  - i. Exynos 1280
  - ii. Mali-G68 GPU
  - iii. 8GB RAM / 256 GB Internal Memory
  - iv. Android 13, One UI 5.1
2. Laptop Lenovo Legion 5
  - i. Processor 12<sup>th</sup> Gen intel® Core™ i7-12700H 2.30GHz
  - ii. RAM 16 GB
3. Digital Lux Meter AR823
4. Colorimeter
  - i. Model WR-10
  - ii. Color Space CIELAB
  - iii. Sensor Photodiode array
5. Color Checker

#### **b. Perangkat Lunak**

1. Python 3
2. Java
3. Google Colaboratory
4. Android Studio

### **3.4 Studi Pustaka**

Tahap studi Pustaka ini dilakukan dengan mempelajari penelitian-penelitian terdahulu yang berkaitan dengan penentuan waktu melakukan suatu teknik atau kegiatan yang membutuhkan ketepatan waktu menggunakan metode CNN. Pada penelitian ini, terdapat 2 jurnal yang menjadi rujukan dalam pengembangan aplikasi dengan CNN.

Tabel 3. 1 Ringkasan Penelitian Terdahulu

No	Topik	Pengetahuan	Temuan
1	Pengontrolan sistem pemupukan budidaya tanaman tomat dengan <i>Convolutional Neural Network</i>	Arsitektur yang digunakan pembuatan yaitu <i>Feature Learning</i> dan <i>Classification</i> (MLP), Pengujian deteksi daun memiliki nilai akurasi sebesar 87%.	Arsitektur <i>Feature Learning</i> berguna untuk mentranslasikan suatu input menjadi fitur-fitur berdasarkan ciri dari input tersebut yang berbentuk angka-angka dalam vektor. <i>Classification Layer</i> berguna untuk mengklasifikasikan tiap neuron yang telah diekstraksi fitur pada sebelumnya.
2	Klasifikasi Tingkat Kematangan Pucuk Daun Teh menggunakan Metode <i>Convolutional Neural Network</i>	Model <i>Convolutional Neural Network</i> yang digunakan yaitu VGGNet dan ResNet untuk mengklasifikasikan tingkat kematangan pucuk daun teh	Sistem yang digunakan mampu menangani banyak data gambar yang digunakan. Arsitektur yang digunakan juga mampu mengklasifikasikan tingkat kematangan pucuk daun teh dengan performa terbaiknya yaitu VGGNet19.
3	Cekaman Kekeringan Berat Mempengaruhi Keberhasilan Induksi Bunga Jeruk Keprok Madura	Cekaman kekeringan pada kadar air 50% dan 40% dari kapasitas lapang tidak memicu induksi bunga pada jeruk keprok varietas Madura	Ambang batas cekaman kekeringan pada induksi bunga jeruk keprok Madura di dataran rendah, di mana cekaman berat mengganggu proses tersebut




### 3.5 Pengumpulan Data


Data yang menjadi fokus dalam pengembangan CNN adalah citra daun tanaman jeruk. Proses ini memerlukan tiga jenis citra daun yang memiliki tingkat keberhasilan yang berbeda yaitu rendah, sedang, dan tinggi. Setiap daun yang telah dilabeli akan diambil masing-masing lima sampel pada setiap cabang pohon. Penentuan tingkat keberhasilan didasarkan pada jumlah bunga yang tumbuh pada dahan tersebut. Sebagai contoh, daun yang menghasilkan 0 hingga 37 bunga dikategorikan sebagai tingkat keberhasilan rendah. Sedangkan daun dengan jumlah bunga antara 38 hingga 70 diklasifikasikan sebagai tingkat keberhasilan sedang, dan daun dengan 70 bunga atau lebih dianggap sebagai tingkat keberhasilan tinggi.

Proses selanjutnya adalah pengambilan nilai VARI (*Visible Atmospherically Resistant Index*) pada setiap citra dengan menggunakan colorimeter. VARI akan digunakan sebagai salah satu teknik untuk mengamati persebaran warna pada kondisi daun. Pemilihan daun tanaman jeruk yang akan digunakan dalam pembuatan dataset dilakukan dengan bantuan pakar dari Pusat Riset Hortikultura dan Perkebunan Badan Riset dan Inovasi Nasional (BRIN) yang ahli dalam teknik pikung. Pakar tersebut membantu dalam memilih daun-daun yang tepat dan representatif, yang kemudian akan digunakan sebagai data dalam pengembangan model CNN. Contoh data yang diambil dari penelitian ini dapat ditemukan dalam tabel 3.2, yang memberikan gambaran mengenai citra daun tanaman jeruk beserta tingkat keberhasilan yang telah ditetapkan berdasarkan jumlah bunga yang tumbuh. Dengan demikian, pengembangan model CNN ini menggabungkan informasi tentang jumlah bunga pada tanaman jeruk dengan analisis citra menggunakan VARI, dengan tujuan akhir untuk mengidentifikasi pola atau karakteristik yang berkaitan dengan tingkat keberhasilan pertumbuhan tanaman jeruk.



Tabel 3. 2 Contoh citra data dengan kondisi Tingkat keberhasilan Rendah, Sedang, dan Tinggi

Gambar Daun	Tingkat keberhasilan
	Rendah
	Sedang
	Tinggi



Gambar 3. 2 Alur pengumpulan data

Berdasarkan gambar 3.2 citra daun tanaman jeruk akan diambil dengan kamera *smartphone*. Sebelum itu perlu dilakukan pengukuran pencahayaan dengan Lux Meter untuk mengetahui data yang sedang diambil berada pada tingkat dan kondisi pencahayaan apa dikarenakan perbedaan kondisi pencahayaan menghasilkan pantulan warna yang berbeda, sehingga perlu dikoreksi pencahayaan. Tahap selanjutnya yaitu daun akan diukur warna aslinya menggunakan Colorimeter. Adapun 2 tahap lainnya pada pengumpulan data yaitu tahap pembuatan dataset dan tahap preprocessing dataset, Tahap pembuatan dataset adalah saat informasi atau data dikumpulkan dan diorganisir menjadi satu set data yang lengkap untuk analisis lebih lanjut, Sementara itu, tahap preprocessing dataset adalah langkah-langkah yang dilakukan untuk membersihkan, memformat, dan menyiapkan data sebelum dilakukan analisis lebih lanjut.

### **3.5.1 Pembuatan Dataset**

Dalam tahap pembuatan dataset, data yang terkumpul diorganisir ke dalam tiga kategori utama yang disebut sebagai kelas Rendah (C), Sedang (B), dan Tinggi (A). Penetapan kategori ini mencerminkan tingkat keberhasilan metode pikung pada tanaman yang diamati. Pemilihan tiga kelas ini didasarkan pada evaluasi hasil metode pikung terhadap tanaman yang telah dilakukan.

Pengelompokan ke dalam kelas Rendah, Sedang, dan Tinggi mencerminkan tingkat kemajuan atau performa metode pikung pada setiap individu tanaman. Kelas Rendah (C) mungkin mencakup tanaman yang menunjukkan tingkat keberhasilan pikung yang rendah. Kelas Sedang (B) mencakup tanaman dengan tingkat keberhasilan pikung yang lebih baik, menunjukkan respons sedang terhadap metode tersebut. Sementara itu, Kelas Tinggi (A) merujuk pada tanaman yang secara umum menunjukkan tingkat keberhasilan pikung yang tinggi.


Penentuan tingkat keberhasilan metode ini didasarkan pada penelitian yang dilakukan di perkebunan jeruk di Pandanrejo, Kecamatan Bumiaji, Kota Batu, Jawa Timur. Metode pikung dilakukan pada beberapa pohon jeruk dan cabangnya dilabeli. Kemudian, satu bulan kemudian, peneliti kembali untuk melihat hasil pikung. Hasil observasi menunjukkan bahwa beberapa pohon jeruk yang telah dilakukan metode pikung menghasilkan pertumbuhan bunga pada cabang pohon.

Jumlah percabangan bunga pada cabang pohon berkisar dari satu hingga delapan ratus enam puluh tujuh.

Berdasarkan data lapangan, peneliti menetapkan kriteria tingkat keberhasilan yaitu, jika jumlah percabangan bunga pada cabang pohon jeruk kurang dari tiga puluh tujuh, akan ditetapkan sebagai tingkat keberhasilan rendah. Jumlah bunga antara tiga puluh tujuh hingga tujuh puluh akan ditetapkan sebagai tingkat keberhasilan sedang, sedangkan jumlah bunga lebih dari tujuh puluh akan ditetapkan sebagai tingkat keberhasilan tinggi.

### 3.5.2 Preprocessing Dataset

Dalam tahap ini, citra yang diambil akan mengalami proses pemotongan dengan rasio 3:4. Tujuannya adalah untuk mengkonsentrasikan perhatian model pada bagian yang paling relevan dari gambar, yaitu potongan daun. Melalui pemotongan ini, informasi yang tidak diperlukan di luar area daun dapat dieliminasi, memungkinkan model untuk lebih fokus pada fitur-fitur yang bersifat spesifik pada bagian daun. Pemotongan citra dilakukan dengan teliti untuk memastikan bahwa hanya bagian daun yang dipertahankan, sehingga hasilnya adalah potongan citra yang lebih kecil tetapi mengandung informasi yang esensial. Rasio 3:4 dipilih dengan pertimbangan untuk menciptakan proporsi yang optimal antara tinggi dan lebar citra, mengikuti karakteristik umum dari bentuk daun yang lebih panjang. Untuk contoh pemotongan dapat dilihat pada gambar 3.3.



Gambar 3. 3 preprocessing data (a) Sebelum dan (b) Sesudah pemotongan


Selanjutnya, untuk memastikan konsistensi dalam pelatihan model CNN, dilakukan proses *resizing* terhadap potongan citra. Ukuran gambar disesuaikan menjadi 500 x 500 piksel. Hal ini dilakukan agar semua citra yang masuk ke dalam proses pelatihan memiliki dimensi yang seragam, mendukung stabilitas model.

### 3.6 *Profiling*

Pada tahap ini, dilakukan proses pembuatan profil untuk setiap kategori daun dengan menggunakan data colorimeter yang dikumpulkan bersamaan dengan pengambilan citra daun tanaman jeruk. Tujuan dari proses *profiling* ini adalah untuk mengidentifikasi perbedaan antara ketiga kelas data citra daun. Data dari colorimeter akan diubah dari format LAB ke format RGB, kemudian dilakukan perhitungan rata-rata dan standar deviasi untuk mendapatkan karakteristik perbedaan dari ketiga kelas data citra daun yang diamati.

### 3.7 Desain dan Perancangan Sistem

Adapun tahap-tahap yang perlu dilakukan dalam perancangan aplikasi berbasis android ini agar dapat memprediksi waktu pikung dapat dilihat pada gambar 3.4.



Gambar 3. 4 Alur desain dan perancangan sistem

### 3.7.1 Pelatihan Model

Pada tahap ini, fokus penelitian beralih ke pelatihan model *Convolutional Neural Network* (CNN), yang menjadi inti dari sistem yang dikembangkan. Data yang telah melewati proses preprocessing, termasuk pemotongan dan pengubahan ukuran (*resizing*), akan diekstraksi fiturnya dan dipelajari oleh model. Empat arsitektur digunakan dalam eksperimen ini yaitu, VGG16, ResNet50V2, MobileNetV2, dan InceptionV3, dengan tambahan YOLOv5 untuk deteksi daun. Pemilihan variasi arsitektur ini bertujuan untuk membandingkan kinerja dan kemampuan adaptasi masing-masing model terhadap dataset gambar daun yang telah diproses.

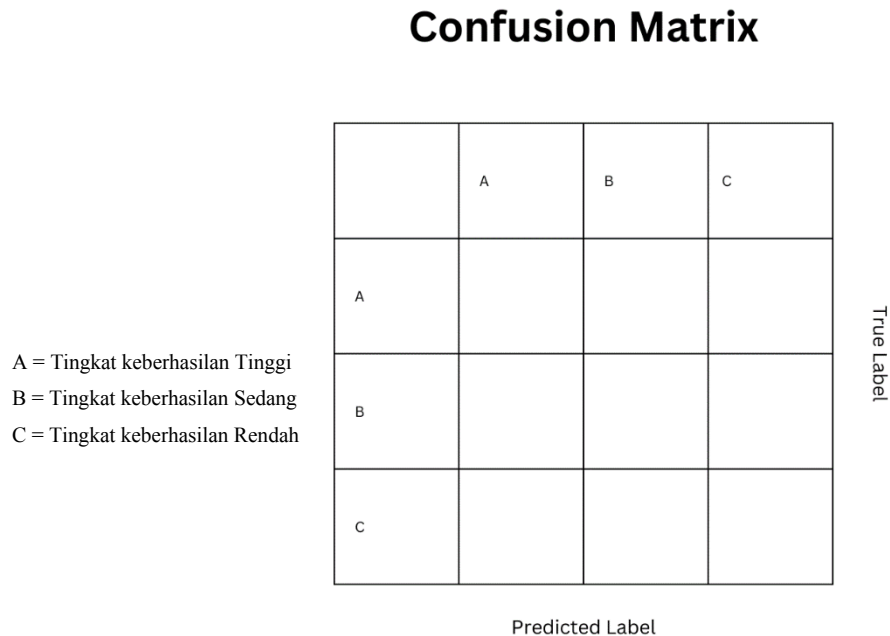
Dalam konteks pelatihan model, dua *optimizer* yang digunakan adalah Adam dan AdamMax. Penggunaan *optimizer* ini diperhatikan karena memengaruhi kecepatan konvergensi model dan dapat berdampak pada hasil akhir. Kedua *optimizer* ini akan diuji secara eksperimental untuk mengevaluasi kinerja mereka terhadap tujuan penelitian. Fungsi *loss* yang dipilih untuk penelitian ini adalah *Categorical Cross-Entropy Loss*. Fungsi *loss* ini umumnya digunakan dalam tugas klasifikasi multikelas seperti yang dilakukan dalam penelitian ini. Tujuannya adalah untuk mengukur sejauh mana distribusi probabilitas hasil prediksi model mendekati distribusi probabilitas yang seharusnya.

Keluaran dari model ini adalah apakah objek daun terdeteksi atau tidak. Jika daun terdeteksi, model akan memberikan prediksi kategori kelas serta tingkat kepercayaan atau *confidence level* untuk setiap prediksi kategori yang diberikan.

### 3.7.2 Pengujian Model

Setelah pembuatan model selesai, langkah selanjutnya adalah melakukan evaluasi model dengan menguji model menggunakan data testing yang tidak digunakan dalam pelatihan. Proses pengujian ini bertujuan untuk melakukan rekomendasi menggunakan model yang telah dibuat. Hasil dari pengujian akan menghasilkan metrik evaluasi seperti akurasi, presisi, dan *recall* yang mencerminkan kemampuan model dalam melakukan rekomendasi. Selain itu,

penggunaan *confusion matriks* juga dapat memberikan gambaran yang lebih rinci tentang performa model dalam rekomendasi waktu pikung.



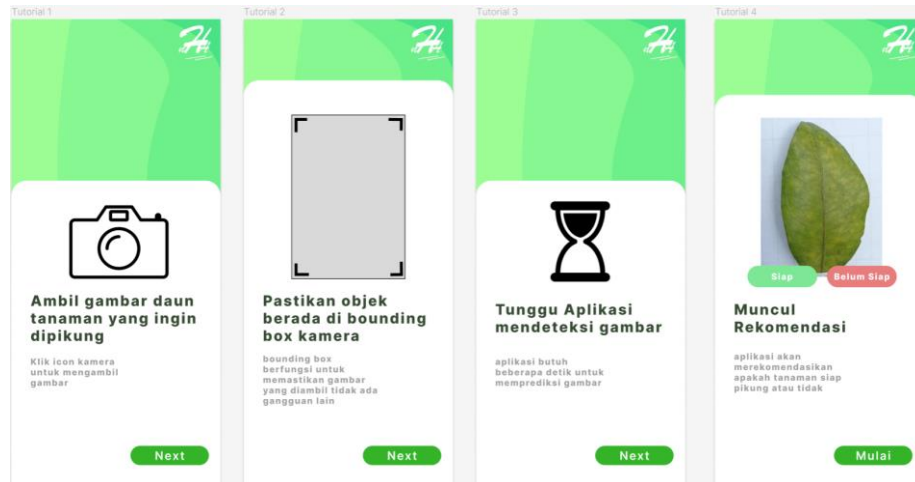
Gambar 3. 5 Confusion Matriks model

### 3.8 Pengembangan Aplikasi

Pada tahap ini, model yang dibuat akan di implementasikan ke dalam aplikasi android. Model nantinya akan melakukan prediksi melalui citra daun jeruk yang diambil dengan keluaran daun siap untuk dipikung atau daun tidak siap untuk dipikung.

#### 3.8.1 Mockup Aplikasi

Pada awal pembukaan aplikasi, pengguna akan dihadapkan dengan *tutorial* aplikasi yang selanjutnya akan dibawa ke inti aplikasi.



Gambar 3. 6 Mock up aplikasi bagian tutorial

Pada inti aplikasi terdapat 2 tombol yaitu tombol untuk mengambil gambar dan tombol untuk mengunggah gambar. Lalu terdapat 4 tombol dibagian bawah. Tombol pertama untuk kembali ke main aplikasi atau *home*, tombol kedua untuk menuju galeri, tombol ketiga untuk kembali ke *tutorial*, dan tombol terakhir untuk informasi lisensi aplikasi.




Gambar 3. 7 Mock up bagian inti aplikasi

## **BAB IV**

### **HASIL DAN PEMBAHASAN**

#### **4.1 Dataset**

Sebagaimana telah diuraikan sebelumnya dalam bagian sebelumnya, penelitian ini mengelompokkan tanaman jeruk ke dalam tiga kelas berbeda, yaitu kelas Rendah (C), Sedang (B), dan Tinggi (A). Untuk mendapatkan karakteristik yang representatif dari setiap kondisi tanaman jeruk, dilakukan pengambilan data colorimeter pada tiga titik tertentu pada daun tanaman yaitu pada bagian ujung daun, tengah daun, dan pangkal daun.



Gambar 4. 1 Contoh 3 titik daerah yang diambil menggunakan colorimeter

Pengambilan nilai colorimeter ini dimaksudkan untuk melakukan profilisasi dan mendapatkan ciri-ciri khas dari setiap kelas kondisi tanaman. Penyajian hasil pengelompokan citra daun jeruk ke dalam kelas Rendah, Sedang, dan Tinggi dapat ditemukan secara menyeluruh dalam Tabel 4.1.




Tabel 4. 1 Jumlah data Rendah, Sedang, dan Tinggi

No	Tingkat Keberhasilan	Jumlah
1	Rendah (C)	70
2	Sedang (B)	56
3	Tinggi (A)	46

Dari tabel 4.1 dalam penelitian ini, dapat diamati bahwa pada tingkat keberhasilan Rendah terdapat 70 data citra, sedangkan pada tingkat keberhasilan Sedang terdapat 56 citra data, dan pada tingkat keberhasilan Tinggi terdapat 46 citra data. Perbedaan signifikan dalam jumlah data ini disebabkan oleh kurangnya jumlah sampel pohon yang diambil.


#### 4.2 *Profiling*

Proses *profiling* yang dilakukan dalam penelitian ini memiliki tujuan utama untuk mendeteksi dan mengidentifikasi perbedaan-perbedaan yang ada pada setiap kondisi dengan memanfaatkan data yang diperoleh dari alat Colorimeter. Alat Colorimeter digunakan untuk mengukur karakteristik warna pada setiap kondisi yang diamati, dan hasilnya kemudian dimanfaatkan untuk mengembangkan profil warna yang lebih mendalam. Dalam konteks ini, *profiling* tidak hanya berfokus pada pengukuran nilai warna secara umum, tetapi juga mengeksplorasi variasi warna dengan memperhatikan parameter-parameter spesifik. Data yang dihasilkan oleh alat colorimeter menjadi dasar untuk pemahaman yang lebih rinci tentang karakteristik warna pada setiap kondisi yang diamati. Berikut adalah hasil dari *profiling* dengan data Colorimeter.



Gambar 4. 2 Grafik Rata-rata RGB Data Colorimeter


Gambar 4.2 menggambarkan hasil analisis rata-rata nilai *Red* (R), *Green* (G), dan *Blue* (B) pada daun tanaman jeruk dalam kondisi Rendah, Sedang, dan Tinggi. Terlihat bahwa pada kelas Rendah, nilai rata-rata R dan G lebih kecil dibandingkan dengan kelas Sedang dan Tinggi, menunjukkan perubahan intensitas warna merah dan hijau. Sebaliknya, nilai rata-rata Blue pada kelas Rendah lebih besar dibandingkan dengan kelas Sedang dan Tinggi, mengindikasikan perbedaan dalam komponen biru.



Gambar 4. 3 Grafik Standar Deviasi RGB Data Colorimeter


Gambar 4.3 memberikan gambaran rinci mengenai persebaran nilai Red (R), Green (G), dan Blue (B) pada setiap kondisi daun tanaman jeruk. Terlihat bahwa kelas rendah menonjol dengan persebaran nilai yang paling tinggi pada ketiga warna. Hal ini menunjukkan variasi yang signifikan dalam intensitas warna pada daun jeruk yang Tingkat keberhasilan Rendah.

Adapun juga dilakukan *profiling* memanfaatkan data yang diperoleh dari citra gambar yang diambil. *Profiling* dengan Data Citra ini dilakukan agar dapat mengetahui perbedaan warna yang ditangkap oleh alat Colorimeter dengan Citra gambar yang diambil. Berikut adalah hasil dari *profiling* dengan data Citra:



Gambar 4. 4 Grafik Rata-rata RGB Data Citra

Dalam Gambar 4.4, dapat diamati bahwa nilai Red (R), Green (G), dan Blue (B) pada tingkat keberhasilan Tinggi menunjukkan nilai tertinggi dibandingkan dengan Tingkat keberhasilan Rendah dan Sedang. Selain itu, terlihat bahwa pada tingkat keberhasilan Sedang, nilai Blue (B) memiliki tingkat yang paling rendah dibandingkan dengan Tingkat keberhasilan Rendah dan Tinggi. Analisis ini menunjukkan pola yang menarik dalam karakteristik warna antara tiga tingkat keberhasilan yang berbeda. Tingkat keberhasilan Tinggi cenderung memiliki nilai warna yang lebih tinggi secara keseluruhan, menunjukkan potensi adanya pengaruh positif dari metode pikung terhadap citra yang dihasilkan. Di sisi lain, tingkat keberhasilan Sedang menunjukkan nilai Blue (B) yang paling rendah, yang mungkin menunjukkan variasi dalam respons tanaman terhadap metode pikung atau faktor-faktor lain yang mempengaruhi karakteristik warna pada tingkat tersebut.



Gambar 4. 5 Grafik Standar Deviasi RGB Data Citra







Dari Gambar 4.5, dapat diperhatikan bahwa terdapat perbedaan yang signifikan dalam persebaran nilai Red (R), Green (G), dan Blue (B) antara tingkat keberhasilan Rendah, Sedang, dan Tinggi. Persebaran nilai Blue (B) pada Tingkat Sedang terlihat paling kecil dibandingkan dengan Tingkat keberhasilan Rendah dan Tinggi. Sebaliknya, persebaran nilai Red (R) dan Green (G) terlihat paling besar pada Tingkat Sedang dibandingkan dengan tingkat keberhasilan lainnya.

### 4.3 Augmentasi

Pada penelitian ini, augmentasi yang digunakan adalah `rotation_range`, `shear_range`, `zoom_range`, `horizontal flip`, `width_shift_range`, dan `height_shift_range`. Augmentasi yang dilakukan adalah untuk memberikan gambaran mengenai contoh data hasil augmentasi, dapat dirujuk pada tabel 4.2 berikut ini. Tabel ini menyajikan contoh representatif dari sampel-sampel data yang

telah mengalami berbagai transformasi melalui teknik augmentasi yang diimplementasikan.

Tabel 4. 2 Hasil Augmentasi

Augmentasi	Sebelum	Sesudah
rotation_range		
shear_range		
zoom_range		

Setelah proses augmentasi selesai dilakukan, dataset yang awalnya terdiri dari 172 citra data telah berkembang menjadi 884 citra data baru. Augmentasi ini bertujuan untuk meningkatkan variasi dan representasi dataset yang digunakan. Dari hasil augmentasi tersebut terdapat 214 citra data dengan tingkat keberhasilan tinggi (A), 295 citra data dengan tingkat keberhasilan sedang (B), dan 375 citra data dengan tingkat keberhasilan rendah (C).

#### **4.4 Implementasi CNN**

Pada tahap implementasi dalam penelitian ini, arsitektur *Convolutional Neural Network* (CNN) diimplementasikan menggunakan library Keras. Keras digunakan sebagai sarana utama untuk membangun arsitektur CNN, serta untuk melakukan berbagai tugas seperti preprocessing data, pelatihan (training), dan pengujian (testing) model. Pentingnya Keras sebagai library utama memberikan fleksibilitas dan efisiensi dalam pengembangan model.

Penulisan kode dilakukan secara khusus menggunakan Google Colaboratory. Penggunaan Google Colaboratory menjadi pilihan utama karena memungkinkan akses ke unit pemrosesan grafis (GPU) yang dapat mempercepat proses pelatihan model. GPU yang tersedia di Google Colaboratory sangat mendukung tugas pelatihan model yang memerlukan daya komputasi tinggi.

Arsitektur yang diimplementasikan mencakup VGG16, ResNet50V2, MobileNetV2, dan InceptionV3. Keempat arsitektur ini dipilih karena masing-masing memiliki karakteristik dan keunggulan tersendiri. Pemilihan arsitektur ini bertujuan untuk mengevaluasi kinerja dan adaptasi masing-masing model terhadap dataset gambar daun yang telah diproses sebelumnya.

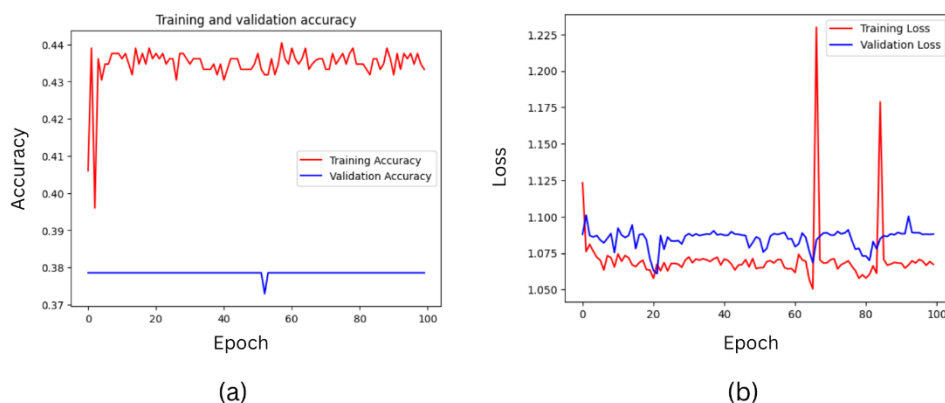
#### **4.5 Pengujian Model CNN**

Dalam penelitian ini, terdapat total delapan model yang dibangun dengan menggunakan dua jenis *optimizer*, yaitu Adam dan Adamax. Selain itu, keberagaman diwujudkan melalui penerapan empat arsitektur berbeda untuk setiap kombinasi *optimizer*. Dengan demikian, keseluruhan penelitian mencakup variasi yang luas melalui kombinasi *optimizer* dan arsitektur. Lebih khususnya, setiap

*optimizer* (Adam dan Adamax) diaplikasikan pada masing-masing dari empat arsitektur yang terpilih, yaitu VGG16, ResNet50V2, MobileNetV2, dan InceptionV3. Pendekatan ini bertujuan untuk menyelidiki dan membandingkan kinerja optimasi antar arsitektur serta mengevaluasi pengaruh jenis *optimizer* terhadap hasil model.

#### 4.5.1 VGG16\_Adam

Model VGG16\_Adam dikonstruksi dengan mengadopsi arsitektur VGG16 dan menerapkan teknik optimasi Adam dengan menjalankan proses pelatihan sebanyak 100 epoch. Pada tahap akhir proses pelatihan, performa model dievaluasi dengan memeriksa nilai akurasi dan *loss* pada set pelatihan dan set pengujian. Visualisasi hasil evaluasi ini dapat diamati pada Gambar 4.6.




Gambar 4. 6 Grafik Indikator Kinerja VGG\_Adam (a) Akurasi dan (b) *Loss*

Dari visualisasi pada gambar 4.6, terlihat bahwa nilai akurasi pada fase pelatihan (*training*) dan validasi tidak mengalami perubahan yang signifikan seiring berjalannya epoch. Begitu pula dengan nilai *loss* yang tidak menunjukkan tren penurunan atau peningkatan yang substansial. Pada akhir proses pelatihan, diperoleh hasil akurasi train sebesar 43% dan akurasi validasi sebesar 37%. Secara bersamaan, nilai *loss* untuk training adalah 1.0673 dan nilai *loss* untuk validasi adalah 1.0881. Hal ini menunjukkan bahwa model mungkin telah mencapai titik jenuh dalam pembelajaran pada dataset pelatihan. Titik jenuh ini dapat disebabkan oleh beberapa faktor, seperti kompleksitas model yang tidak sebanding dengan



jumlah data atau adanya *overfitting*, di mana model terlalu memahami dan "menghafal" data pelatihan. Untuk pengujian menggunakan data test mendapatkan akurasi sebesar 38% dengan *confusion matrix* yang dapat dilihat pada gambar 4.7.



Gambar 4. 7 *Confusion matrix* Data Test VGG\_Adam


Melalui analisis gambar 4.7, terlihat bahwa model saat ini mengalami kendala dalam kemampuannya untuk memprediksi kelas A dan kelas B. Hasil pengamatan menunjukkan bahwa seluruh citra pada dataset pengujian diprediksi sebagai kelas C. Model menghadapi kesulitan dalam memahami dan membedakan pola atau ciri khas yang membedakan antara kelas A, kelas B, dan kelas C. Untuk mengevaluasi kinerja model dapat dilihat pada tabel 4.3.

Tabel 4. 3 Precision, recall, f1-score VGG\_Adam

	precision	recall	f1-score	support
A	0	0	0	44
B	0	0	0	66
C	0.38	1.00	0.55	67
Accuracy			0.38	177
Macro avg	0.13	0.33	0.18	177
Weighted avg	0.14	0.38	0.21	177


#### 4.5.2 VGG16\_Adamax

Model VGG16\_Adamax dikonstruksi dengan mengadopsi arsitektur VGG16 dan menerapkan teknik optimasi Adamax dengan menjalankan proses pelatihan sebanyak 100 epoch. Pada tahap akhir proses pelatihan, performa model dievaluasi dengan memeriksa nilai akurasi dan *loss* pada set pelatihan dan set pengujian. Visualisasi hasil evaluasi ini dapat diamati pada Gambar 4.8.



Gambar 4. 8 Grafik Indikator Kinerja VGG\_Adamax (a) Akurasi dan (b) *Loss*

Dari visualisasi yang terdapat pada Gambar 4.8, terlihat bahwa terjadi peningkatan dalam nilai akurasi selama fase pelatihan (training) dan validasi seiring dengan berjalannya epoch. Meskipun demikian, perubahan pada nilai *loss* tidak menunjukkan tren penurunan yang konsisten. Pada akhir proses pelatihan, diperoleh hasil akurasi training sebesar 89% dan akurasi validasi sebesar 77%. Sementara itu, nilai *loss* untuk tahap training adalah 0.2778, dan nilai *loss* untuk tahap validasi adalah 0.7677. Hasil akhir tersebut menunjukkan bahwa model mencapai tingkat akurasi yang tinggi pada data pelatihan, tetapi terdapat sejumlah perbedaan yang signifikan pada data validasi. Peningkatan nilai *loss* pada validasi mungkin mengindikasikan adanya overfitting. Untuk pengujian menggunakan data test mendapatkan akurasi sebesar 78% dengan *confusion matrix* yang dapat dilihat pada gambar 4.9.



Gambar 4. 9 *Confusion matrix* Data Test VGG\_Adamax

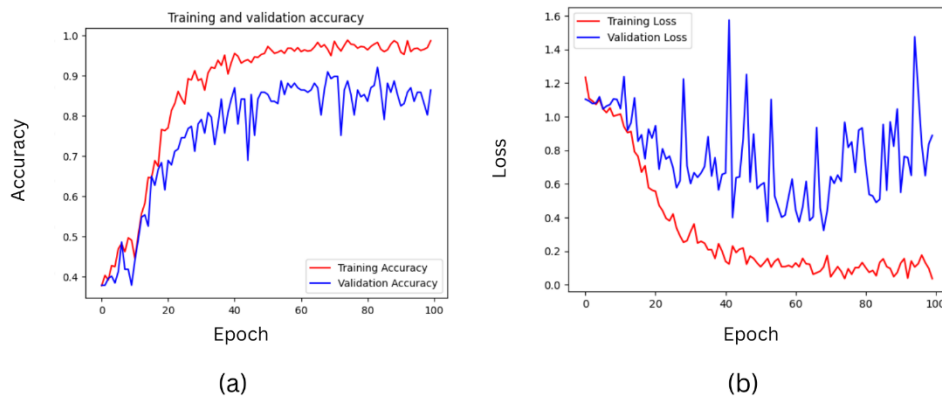
Melalui analisis pada Gambar 4.9, dapat ditemukan bahwa dari 44 citra daun yang termasuk dalam kelas A, model berhasil memprediksi dengan benar sebanyak 32 citra. Selain itu, 8 citra dari kelas A tersebut diprediksi sebagai kelas B, dan 4 citra diprediksi sebagai kelas C. Pada kelas B, model mencapai keberhasilan prediksi sebanyak 55 citra, di mana 4 citra dari kelas B diprediksi sebagai kelas A, dan 7 citra diprediksi sebagai kelas C. Sementara itu, pada kelas C, model berhasil memprediksi dengan benar sebanyak 51 citra, dengan 13 citra kelas C yang terprediksi sebagai kelas A, dan 3 citra terprediksi sebagai kelas B. Untuk mengevaluasi kinerja model dapat dilihat pada tabel 4.4.

Tabel 4. 4 Precision, recall, f1-score VGG\_Adamax

	precision	recall	f1-score	support
A	0.65	0.73	0.69	44
B	0.83	0.83	0.83	66
C	0.82	0.76	0.79	67
Accuracy			0.78	177
Macro avg	0.77	0.77	0.77	177
Weighted avg	0.78	0.78	0.78	177


### 4.5.3 ResNet50V2\_Adam

Model ResNet50V2\_Adam dikonstruksi dengan mengadopsi arsitektur ResNet50V2 dan menerapkan teknik optimasi Adam dengan menjalankan proses pelatihan sebanyak 100 epoch. Pada tahap akhir proses pelatihan, performa model dievaluasi dengan memeriksa nilai akurasi dan *loss* pada set pelatihan dan set pengujian. Visualisasi hasil evaluasi ini dapat diamati pada Gambar 4.10.



Gambar 4. 10 Grafik Indikator Kinerja ResNet50V2\_Adam (a) Akurasi dan (b) *Loss*

Melalui analisis visual pada Gambar 4.10, terlihat bahwa terjadi peningkatan dalam nilai akurasi selama fase pelatihan (training) dan validasi seiring dengan berjalannya epoch. Meskipun demikian, pada nilai *loss* terlihat adanya fluktuasi yang tidak konsisten menurun. Pada akhir proses pelatihan, diperoleh hasil akurasi training sebesar 98% dan akurasi validasi sebesar 86%. Secara bersamaan, nilai *loss* untuk training adalah 0.0356 dan nilai *loss* untuk validasi adalah 0.8880. Hal ini mengindikasikan bahwa model mampu dengan sangat baik mempelajari pola dan fitur pada dataset pelatihan, mencapai tingkat akurasi yang sangat tinggi. Namun, perbedaan yang cukup signifikan antara akurasi training dan validasi menunjukkan kemungkinan adanya overfitting. Untuk pengujian menggunakan data test mendapatkan akurasi sebesar 85% dengan *confusion matrix* yang dapat dilihat pada gambar 4.11.



Gambar 4. 11 *Confusion matrix* Data Test ResNet50V2\_Adam


Dengan melakukan analisis pada Gambar 4.11, dapat ditemukan bahwa pada kelas A berhasil diprediksi dengan benar sebanyak 36 citra. Namun, terdapat 5 citra yang salah diprediksi sebagai kelas B dan 3 citra yang salah diprediksi sebagai kelas C. Untuk kelas B, terlihat bahwa 56 citra diprediksi dengan benar, sementara 1 citra salah diprediksi sebagai kelas A dan 9 citra salah diprediksi sebagai kelas C. Pada kelas C, sebanyak 61 citra berhasil diprediksi dengan benar, namun terdapat 2 citra yang salah diprediksi sebagai kelas A dan 4 citra yang salah diprediksi sebagai kelas B. Untuk mengevaluasi kinerja model dapat dilihat pada tabel 4.5.

Tabel 4. 5 Precision, recall, f1-score ResNet50V2\_Adam

	precision	recall	f1-score	support
A	0.92	0.82	0.87	44
B	0.86	0.85	0.85	66
C	0.84	0.91	0.87	67
Accuracy			0.86	177
Macro avg	0.87	0.86	0.86	177
Weighted avg	0.87	0.86	0.86	177


#### 4.5.4 ResNet50V2\_Adamax

Model ResNetV2\_Adamax dikonstruksi dengan mengadopsi arsitektur ResNet50V2 dan menerapkan teknik optimasi Adamax dengan menjalankan proses pelatihan sebanyak 100 epoch. Pada tahap akhir proses pelatihan, performa model dievaluasi dengan memeriksa nilai akurasi dan *loss* pada set pelatihan dan set pengujian. Visualisasi hasil evaluasi ini dapat diamati pada Gambar 4.12.



Gambar 4. 12 Grafik Indikator Kinerja ResNet50V2\_Adamax (a) Akurasi dan (b) *Loss*

Melalui analisis visual pada Gambar 4.12, terlihat bahwa terjadi peningkatan dalam nilai akurasi selama fase pelatihan (training) dan validasi seiring dengan berjalannya epoch. Meskipun demikian, pada nilai *loss* terlihat adanya fluktuasi yang tidak konsisten menurun. Pada akhir proses pelatihan, diperoleh hasil akurasi training sebesar 99% dan akurasi validasi sebesar 83%. Secara bersamaan, nilai *loss* untuk training adalah 0.00152 dan nilai *loss* untuk validasi adalah 1.0411. Hal ini mengindikasikan bahwa model mampu dengan sangat baik mempelajari pola dan fitur pada dataset pelatihan, mencapai tingkat akurasi yang sangat tinggi. Namun, perbedaan yang cukup signifikan antara akurasi training dan validasi menunjukkan kemungkinan adanya overfitting. Untuk pengujian menggunakan data test mendapatkan akurasi sebesar 83% dengan *confusion matrix* yang dapat dilihat pada gambar 4.13.



Gambar 4. 13 *Confusion matrix* Data Test ResNet50V2\_Adamax


Dengan melakukan analisis pada Gambar 4.13, dapat ditemukan bahwa pada kelas A berhasil diprediksi dengan benar sebanyak 29 citra. Namun, terdapat 3 citra yang salah diprediksi sebagai kelas B dan 12 citra yang salah diprediksi sebagai kelas C. Untuk kelas B, terlihat bahwa 52 citra diprediksi dengan benar, sementara 14 citra salah diprediksi sebagai kelas C. Pada kelas C, sebanyak 66 citra berhasil diprediksi dengan benar, namun terdapat 1 citra yang salah diprediksi sebagai kelas B. Untuk mengevaluasi kinerja model dapat dilihat pada tabel 4.6.

Tabel 4. 6 precision, recall, f1-score ResNetV2\_Adamax

	precision	recall	f1-score	support
A	1.00	0.66	0.79	44
B	0.93	0.79	0.85	66
C	0.72	0.99	0.83	67
Accuracy			0.83	177
Macro avg	0.88	0.81	0.83	177
Weighted avg	0.87	0.83	0.83	177

#### 4.5.5 MobileNetV2\_Adam


Model MobileNetV2\_Adam dikonstruksi dengan mengadopsi arsitektur MobileNetV2 dan menerapkan teknik optimasi Adam dengan menjalankan proses pelatihan sebanyak 100 epoch. Pada tahap akhir proses pelatihan, performa model dievaluasi dengan memeriksa nilai akurasi dan *loss* pada set pelatihan dan set pengujian. Visualisasi hasil evaluasi ini dapat diamati pada Gambar 4.14.



Gambar 4. 14 Grafik Indikator Kinerja MobileNetV2\_Adam (a) Akurasi dan (b) *Loss*

Melalui analisis visual pada Gambar 4.14, terlihat bahwa terjadi peningkatan dalam nilai akurasi selama fase pelatihan (training) dan validasi seiring dengan berjalannya epoch. Namun, terdapat ketidakstabilan pada nilai *loss*, di mana pada akhir epoch terlihat adanya peningkatan. Pada akhir proses pelatihan, diperoleh hasil akurasi training sebesar 43% dan akurasi validasi sebesar 37%. Bersamaan dengan itu, nilai *loss* untuk training adalah 1.0712 dan nilai *loss* untuk validasi adalah 0.3785. Hal ini menunjukkan bahwa model mungkin telah mencapai titik jenuh dalam pembelajaran pada dataset pelatihan. Titik jenuh ini dapat disebabkan oleh beberapa faktor, seperti kompleksitas model yang tidak sebanding dengan jumlah data atau adanya *overfitting*, di mana model terlalu memahami dan "menghafal" data pelatihan. Untuk pengujian menggunakan data test mendapatkan akurasi sebesar 38% dengan *confusion matrix* yang dapat dilihat pada gambar 4.15.





Gambar 4. 15 *Confusion matrix* Data Test MobileNetV2\_Adam


Dengan melakukan analisis pada Gambar 4.14, terlihat bahwa model saat ini mengalami kendala dalam kemampuannya untuk memprediksi kelas A dan kelas B. Hasil pengamatan menunjukkan bahwa seluruh citra pada dataset pengujian diprediksi sebagai kelas C. Model menghadapi kesulitan dalam memahami dan membedakan pola atau ciri khas yang membedakan antara kelas A, kelas B, dan kelas C. Untuk mengevaluasi kinerja model dapat dilihat pada tabel 4.7.

Tabel 4. 7 precision, recall, f1-score MobileNetV2\_Adam

	precision	recall	f1-score	support
A	0.00	0.00	0.00	44
B	0.00	0.00	0.00	66
C	0.38	1.00	0.55	67
Accuracy			0.38	177
Macro avg	0.13	0.33	0.18	177
Weighted avg	0.14	0.38	0.21	177


#### 4.5.6 MobileNetV2\_Adamax

Model MobileNetV2\_Adamax dikonstruksi dengan mengadopsi arsitektur MobileNetV2 dan menerapkan teknik optimasi Adamax dengan menjalankan proses pelatihan sebanyak 100 epoch. Pada tahap akhir proses pelatihan, performa model dievaluasi dengan memeriksa nilai akurasi dan *loss* pada set pelatihan dan set pengujian. Visualisasi hasil evaluasi ini dapat diamati pada Gambar 4.16.



Gambar 4. 16 Grafik Indikator Kinerja MobileNetV2\_Adamax (a) Akurasi dan (b) *Loss*

Melalui analisis visual pada Gambar 4.16, terlihat bahwa terjadi peningkatan dalam nilai akurasi selama fase pelatihan (training) dan validasi seiring dengan berjalannya epoch. Meskipun demikian, terdapat fluktuasi pada nilai *loss* yang tidak stabil, namun pada akhir epoch terlihat bahwa terjadi penurunan nilai *loss*. Pada akhir proses pelatihan, diperoleh hasil akurasi training sebesar 99% dan akurasi validasi sebesar 81%. Bersamaan dengan itu, nilai *loss* untuk training adalah 0.0097 dan nilai *loss* untuk validasi adalah 1.3828. Namun, perbedaan yang cukup signifikan antara akurasi training dan validasi menunjukkan kemungkinan adanya overfitting. Untuk pengujian menggunakan data test mendapatkan akurasi sebesar 81% dengan *confusion matrix* yang dapat dilihat pada gambar 4.17.



Gambar 4. 17 *Confusion matrix* Data Test MobileNetV2\_Adamax


Dengan melakukan analisis pada Gambar 4.17, dapat ditemukan bahwa pada kelas A berhasil diprediksi dengan benar sebanyak 31 citra. Namun, terdapat 3 citra yang salah diprediksi sebagai kelas B dan 10 citra yang salah diprediksi sebagai kelas C. Untuk kelas B, terlihat bahwa 47 citra diprediksi dengan benar, sementara 2 citra salah diprediksi sebagai kelas A dan 17 citra salah diprediksi sebagai kelas C. Pada kelas C, sebanyak 66 citra berhasil diprediksi dengan benar, namun terdapat 4 citra yang salah diprediksi sebagai kelas B. Untuk mengevaluasi kinerja model dapat dilihat pada tabel 4.8.

Tabel 4. 8 precision, recall, f1-score MobileNetV2\_Adamax

	precision	recall	f1-score	support
A	0.94	0.70	0.81	44
B	0.92	0.71	0.80	66
C	0.71	0.99	0.83	67
Accuracy			0.81	177
Macro avg	0.86	0.80	0.81	177
Weighted avg	0.85	0.81	0.81	177


#### 4.5.7 InceptionV3\_Adam

Model InceptionV3\_Adam dikonstruksi dengan mengadopsi arsitektur InceptionV3 dan menerapkan teknik optimasi Adam dengan menjalankan proses pelatihan sebanyak 100 epoch. Pada tahap akhir proses pelatihan, performa model dievaluasi dengan memeriksa nilai akurasi dan *loss* pada set pelatihan dan set pengujian. Visualisasi hasil evaluasi ini dapat diamati pada Gambar 4.18.



Gambar 4. 18 Grafik Indikator Kinerja InceptionV3\_Adam (a) Akurasi dan (b) *Loss*

Dari analisis visual pada Gambar 4.17, terlihat bahwa terjadi peningkatan dalam nilai akurasi selama fase pelatihan (*training*) dan validasi seiring dengan berjalannya epoch. Namun, terdapat fluktuasi dalam nilai *loss* yang menunjukkan ketidakstabilan dalam proses pelatihan, meskipun pada akhir epoch terlihat adanya penurunan nilai *loss*. Pada akhir proses pelatihan, hasil akurasi training mencapai 87% dan akurasi validasi mencapai 74%. Sementara itu, nilai *loss* untuk training adalah 0.3029 dan untuk validasi adalah 0.9521. Namun, perbedaan yang cukup signifikan antara akurasi training dan validasi menunjukkan kemungkinan adanya overfitting. Untuk pengujian menggunakan data test mendapatkan akurasi sebesar 88% dengan *confusion matrix* yang dapat dilihat pada gambar 4.19.



Gambar 4. 19 *Confusion matrix* Data Test InceptionV3\_Adam


Dengan melakukan analisis pada Gambar 4.19, dapat ditemukan bahwa pada kelas A berhasil diprediksi dengan benar sebanyak 32 citra. Namun, terdapat 12 citra yang salah diprediksi sebagai kelas B. Untuk kelas B, terlihat bahwa 47 citra diprediksi dengan benar dan 13 citra salah diprediksi sebagai kelas A dan 6 citra salah diprediksi sebagai kelas C. Pada kelas C, sebanyak 53 citra berhasil diprediksi dengan benar dan 2 citra yang salah diprediksi sebagai kelas A dan 12 citra salah diprediksi sebagai kelas B. Untuk mengevaluasi kinerja model dapat dilihat pada tabel 4.9

Tabel 4. 9 precision, recall, f1-score InceptionV3\_Adam

	precision	recall	f1-score	support
A	0.68	0.73	0.70	44
B	0.66	0.71	0.69	66
C	0.90	0.79	0.84	67
Accuracy			0.75	177
Macro avg	0.75	0.74	0.74	177
Weighted avg	0.76	0.75	0.75	177


#### 4.5.8 InceptionV3\_Adamax

Model InceptionV3\_Adamax dikonstruksi dengan mengadopsi arsitektur InceptionV3 dan menerapkan teknik optimasi Adamax dengan menjalankan proses pelatihan sebanyak 100 epoch. Pada tahap akhir proses pelatihan, performa model dievaluasi dengan memeriksa nilai akurasi dan *loss* pada set pelatihan dan set pengujian. Visualisasi hasil evaluasi ini dapat diamati pada gambar 4.20.



Gambar 4. 20 Grafik Indikator Kinerja InceptionV3\_Adamax (a) Akurasi dan (b) *Loss*

Melalui visualisasi pada Gambar 4.20, terlihat bahwa terjadi peningkatan yang konsisten pada nilai akurasi baik pada tahap pelatihan (training) maupun validasi seiring dengan berjalannya epoch. Meskipun demikian, terdapat fluktuasi pada nilai validasi *loss*. Pada akhir proses pelatihan, diperoleh hasil akurasi training sebesar 99% dan akurasi validasi sebesar 89%. Ini menunjukkan bahwa model telah berhasil mempelajari pola-pola yang ada dalam dataset pelatihan dan mampu menggeneralisasikan pengetahuan ini dengan baik pada data validasi yang belum pernah dilihat sebelumnya. Secara bersamaan, nilai *loss* untuk training adalah 0.0197 dan nilai *loss* untuk validasi adalah 0.6430, yang menunjukkan bahwa model telah berhasil mengurangi tingkat kesalahan dalam proses pembelajaran. Untuk pengujian menggunakan data test, diperoleh akurasi sebesar 90%, yang menunjukkan bahwa model mampu memberikan prediksi yang cukup akurat pada data baru yang belum pernah dilihat sebelumnya. Untuk *confusion matrix* dapat dilihat pada gambar 4.21.



Gambar 4. 21 *Confusion matrix* Data Test InceptionV3\_Adamax


Dengan melakukan analisis pada Gambar 4.21, dapat ditemukan bahwa pada kelas A berhasil diprediksi dengan benar sebanyak 34 citra. Namun, terdapat 2 citra yang salah diprediksi sebagai kelas B dan 8 citra yang salah diprediksi sebagai kelas C. Untuk kelas B, terlihat bahwa 58 citra diprediksi dengan benar, sementara 1 citra salah diprediksi sebagai kelas A dan 7 citra salah diprediksi sebagai kelas C. Pada kelas C, sebanyak 67 citra berhasil diprediksi dengan benar. Untuk mengevaluasi kinerja model dapat dilihat pada tabel 4.10

Tabel 4. 10 precision, recall, f1-score Model InceptionV3\_Adamax

	precision	recall	f1-score	support
A	0.97	0.77	0.86	44
B	0.97	0.88	0.92	66
C	0.82	1.00	0.90	67
Accuracy			0.90	177
Macro avg	0.92	0.88	0.89	177
Weighted avg	0.91	0.90	0.90	177

Hasil kinerja model, sebagaimana ditampilkan dalam Gambar 4.22, menunjukkan bahwa model yang menggunakan *optimizer* Adamax mengungguli

model yang menggunakan *optimizer* Adam dalam hal akurasi. Selain itu, terlihat bahwa model InceptionV3 dengan *optimizer* Adamax mencapai akurasi paling tinggi, dengan nilai akurasi training mencapai 99%, akurasi validasi sebesar 89%, dan akurasi pada data uji (test) sebesar 90%. Pencapaian akurasi yang tinggi pada model InceptionV3 dengan *optimizer* Adamax menunjukkan keefektifan metode optimasi tersebut dalam meningkatkan kinerja model. Dengan akurasi training yang mendekati 100%, model ini mampu dengan sangat baik mempelajari pola-pola yang ada dalam data latih. Selain itu, akurasi yang cukup tinggi pada data validasi dan data uji menunjukkan bahwa model ini juga memiliki kemampuan yang baik.




Gambar 4. 22 Perbandingan Kinerja Model Akurasi Test, Train, dan Validasi

Untuk memastikan bahwa aplikasi dapat berjalan dengan baik, perlu juga mempertimbangkan ukuran dari tiap model yang digunakan. Hal ini karena ukuran model yang besar dapat menyebabkan kendala dalam implementasi aplikasi, seperti lamanya waktu yang diperlukan untuk mengunduh atau memuat model, serta penggunaan sumber daya yang berlebihan di perangkat pengguna.

Oleh karena itu, dalam pengembangan aplikasi, penting untuk memperhatikan ukuran dari masing-masing model yang digunakan. Pemilihan model dengan ukuran yang lebih kecil dapat menjadi solusi yang tepat untuk mengatasi masalah tersebut. Model dengan ukuran yang lebih kecil biasanya



memiliki jumlah parameter yang lebih sedikit, sehingga membutuhkan lebih sedikit sumber daya untuk diunduh, dimuat, dan di eksekusi. Untuk visualisasi perbandingan ukuran model dapat dilihat di gambar 4.23.



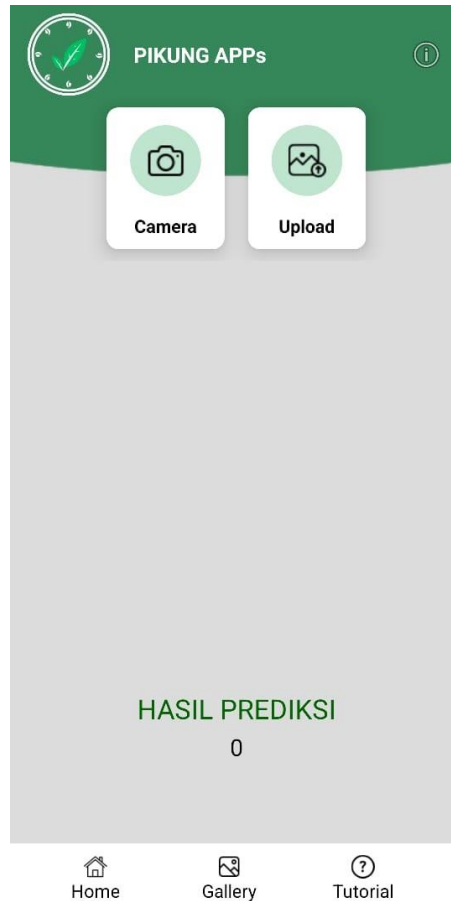
Gambar 4. 23 Perbandingan Ukuran Model dalam bentuk *Megabyte* (MB)

Gambar 4.23 memberikan informasi yang penting terkait dengan ukuran dari beberapa model yang dievaluasi. Terlihat bahwa model MobileNetV2 memiliki ukuran yang paling kecil, sementara model ResNet50V2 memiliki ukuran yang paling besar, bahkan melebihi 100 MB. Dari perspektif implementasi aplikasi, penting untuk mempertimbangkan ukuran model ini. Pemilihan ukuran yang sesuai adalah kunci dalam mengoptimalkan kinerja aplikasi. Meskipun model dengan ukuran yang lebih kecil umumnya lebih disukai karena membutuhkan ruang penyimpanan yang lebih sedikit dan dapat diunduh lebih cepat, namun juga penting untuk mempertimbangkan akurasi model. Idealnya, pengguna ingin memilih model dengan ukuran yang terkecil yang masih memiliki kinerja atau akurasi yang memadai untuk tujuan aplikasi.

#### 4.6 Hasil Aplikasi

Setelah melalui proses pengembangan, hasil akhir aplikasi mengalami perubahan yang signifikan dibandingkan dengan *mockup* aplikasi yang tertera pada

Bab 3. Perubahan ini bertujuan untuk meningkatkan pengalaman pengguna (*user experience*) dan memastikan aplikasi dapat digunakan dengan mudah serta memberikan kenyamanan kepada pengguna.




Gambar 4. 24 Tampilan Home aplikasi

Pada gambar 4.24 terdapat perubahan pada tampilan aplikasi, terdapat penempatan strategis untuk dua tombol utama, tombol Camera dan tombol Upload. Keduanya diletakkan di bagian atas antarmuka pengguna aplikasi untuk memudahkan akses pengguna.

Ketika pengguna memilih tombol “*Camera*”, aplikasi akan membuka kamera perangkat untuk langsung mengambil gambar. Begitu citra berhasil diambil, model YOLOv5 akan mendeteksi apakah citra tersebut mengandung objek daun atau tidak. Jika daun terdeteksi, gambar yang telah diambil akan ditampilkan bersama dengan informasi mengenai tingkat kepercayaan (*confidence level*).

Informasi ini memberikan gambaran tentang seberapa yakin model dalam memprediksi kategori daun dari gambar yang diambil.

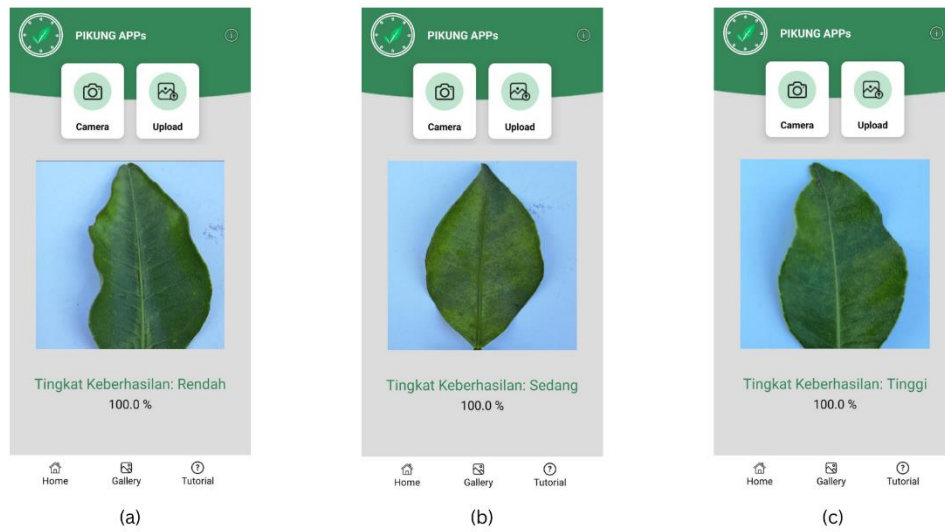
Sebaliknya, jika pengguna memilih tombol “*Upload*”, pengguna dapat memilih citra dari galeri untuk diunggah ke aplikasi. Setelah citra berhasil diunggah, model YOLOv5 akan mendeteksi apakah citra tersebut mengandung objek daun atau tidak. Jika daun terdeteksi, gambar yang diunggah akan ditampilkan bersama dengan informasi mengenai tingkat kepercayaan (*confidence level*).



Gambar 4. 25 Tampilan prediksi dengan kondisi (a) Daun tidak terdeteksi dan (b) Daun terdeteksi

#### 14.7 Evaluasi Aplikasi pada Data Asli

Untuk memastikan keakuratan model pada aplikasi, dilakukan evaluasi menggunakan data asli dengan membandingkan hasil prediksi model dengan label yang sebenarnya pada dataset. Hal ini memungkinkan untuk menilai sejauh mana model dapat mengenali dan mengklasifikasikan dengan benar contoh-contoh daun yang diberikan. Hasil evaluasi ini ditampilkan pada gambar 4.26.



Gambar 4. 26 Hasil Evaluasi pada data asli (a) Tingkat Keberhasilan Rendah (b) Tingkat Keberhasilan Sedang (c) Tingkat Keberhasilan Tinggi

Berdasarkan hasil evaluasi, ditemukan bahwa pada ketiga kategori yang diuji, model memberikan *confidence* sebesar 100%, ini menandakan bahwa model memiliki tingkat akurasi yang sangat tinggi dalam mengklasifikasikan daun-daun tersebut. Dengan kata lain, model dengan sangat tepat mengklasifikasikan setiap contoh daun dalam kategori yang sesuai.

## **BAB V**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Berdasarkan penelitian tugas akhir yang bertujuan untuk mengembangkan model Convolutional Neural Network (CNN) guna menentukan waktu pikung pada tanaman jeruk dan membangun aplikasi berbasis Android yang mengimplementasikan model CNN tersebut, dapat disimpulkan bahwa proses pembuatan model CNN telah berhasil dilakukan. Penelitian ini menghasilkan delapan model berbeda, yang masing-masing menggunakan arsitektur yang berbeda dan dioptimalkan dengan dua jenis *optimizer* yang berbeda, yaitu Adam dan Adamax. Kedelapan model yang digunakan dalam penelitian ini yaitu VGG16\_Adam, VGG16\_Adamax, ResNet50v2\_Adam, ResNet50v2\_Adamax, MobileNetv2\_adam, MobileNetv2\_adamax, InceptionV3\_Adam, dan InceptionV3\_Adamax.

Hasil eksperimen menunjukkan bahwa dari kedelapan model tersebut, model yang menggunakan *optimizer* Adamax memberikan performa yang lebih baik daripada yang menggunakan *optimizer* Adam. Selain itu, melalui proses evaluasi, ditemukan bahwa model InceptionV3 yang dioptimalkan dengan Adamax adalah model terbaik, dengan tingkat akurasi yang paling tinggi. Pada tahap training, model ini mencapai akurasi sebesar 99%, pada tahap validasi dan pengujian, model tersebut mampu mencapai akurasi sebesar 93%, dan pada tahap test, model ini mencapai akurasi sebesar 93%.

Dengan demikian, kesimpulan dari penelitian ini adalah bahwa penggunaan model CNN untuk menentukan waktu pikung pada tanaman jeruk telah sukses dilakukan, dan model InceptionV3\_Adamax menjadi pilihan terbaik berdasarkan hasil evaluasi. Implikasi dari penelitian ini adalah kontribusi penting dalam meningkatkan efisiensi dan akurasi dalam mendeteksi waktu pikung pada tanaman jeruk melalui pendekatan berbasis teknologi.

## 5.2 Saran

Sebagai saran dan masukan untuk penelitian selanjutnya, terutama yang berkaitan dengan topik penentuan waktu pikung pada tanaman jeruk, dapat dipertimbangkan beberapa hal berikut ini. Salah satunya adalah meningkatkan performa dan akurasi model dengan menambahkan lebih banyak data, terutama pada kelas dengan tingkat keberhasilan sedang dan tinggi. Dengan demikian, dapat menciptakan keseimbangan antara jumlah data pada kelas-kelas tersebut dengan kelas yang memiliki tingkat keberhasilan rendah.

Langkah ini diharapkan dapat meningkatkan kemampuan model untuk mengenali dan memprediksi waktu pikung dengan lebih baik, serta menghasilkan hasil yang lebih konsisten dan dapat diandalkan. Selain itu, penggunaan teknik-teknik baru dalam preprocessing data dan peningkatan dalam proses augmentasi data juga dapat dieksplorasi untuk meningkatkan keberhasilan model. Hal ini dapat mencakup penggunaan teknik augmentasi data yang lebih kompleks dan khusus, serta penerapan teknik-teknik baru dalam pengolahan citra yang dapat memperkaya informasi yang diperoleh oleh model. Dengan demikian, penelitian selanjutnya diharapkan dapat memberikan kontribusi yang lebih besar dalam pengembangan sistem yang efektif dan handal dalam penentuan waktu pikung pada tanaman jeruk