

**KLASIFIKASI TINGKAT KEMATANGAN BUAH PISANG  
BERBASIS CITRA MENGGUNAKAN ARSITEKTUR  
MOBILENETV3**

**SKRIPSI**

**OLEH:**

**SISKA OCTIANI**

**228160047**



**PROGRAM STUDI TEKNIK INFORMATIKA  
FAKULTAS TEKNIK  
UNIVERSITAS MEDAN AREA  
MEDAN  
2026**

**UNIVERSITAS MEDAN AREA**

© Hak Cipta Di Lindungi Undang-Undang

Document Accepted 1/7/26

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Access From (repository.uma.ac.id)1/7/26

**KLASIFIKASI TINGKAT KEMATANGAN BUAH PISANG  
BERBASIS CITRA MENGGUNAKAN ARSITEKTUR  
MOBILENETV3**

**SKRIPSI**

**Diajukan sebagai Salah Satu Syarat untuk Memperoleh  
Gelara Sarjana di Fakultas Teknik  
Universitas Medan Area**

**Oleh:**

**SISKA OCTIANI**

**228160047**

**PROGRAM STUDI TEKNIK INFORMATIKA  
FAKULTAS TEKNIK  
UNIVERSITAS MEDAN AREA  
MEDAN  
2026**

**UNIVERSITAS MEDAN AREA**

© Hak Cipta Di Lindungi Undang-Undang

Document Accepted 1/7/26

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Access From (repository.uma.ac.id)1/7/26

## HALAMAN PENGESAHAN

Judul Skripsi : KLASIFIKASI TINGKAT KEMATANGAN BUAH PISANG  
BERBASIS CITRA MENGGUNAKAN ARSITEKTUR  
MOBILENETV3

Nama : SISKA OCTIANI  
NPM : 228160047  
Fakultas : TEKNIK

Disetujui Oleh  
Komisi Pembimbing

Dr. Agus Sembiring, ST., M. Kom.  
Pembimbing I

Dr. Agus Sembiring, ST., MT.  
Fakultas Teknik

Dr. Agus Sembiring, ST., M. Kom.  
Ka. Prodi

Tanggal Lulus: 26 Februari 2026

## HALAMAN PERTANYAAN

Saya menyatakan bahwa skripsi yang saya susun, sebagai syarat memperoleh gelar sarjana merupakan hasil karya tulis saya sendiri. Adapun bagian-bagian tertentu dalam penulisan skripsi ini yang saya kutip dari hasil karya orang lain telah dituliskan sumbernya secara jelas sesuai dengan norma, kaidah, dan etika penulisan ilmiah.

Saya bersedia menerima sanksi pencabutan gelar akademik yang saya peroleh dan sanksi-sanksi lainnya dengan peraturan yang berlaku, apabila di kemudian hari ditemukan adanya plagiat dalam skripsi ini.

Medan, (26 Februari 2026)



SISKA OCTIANI  
228160047

**HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI  
TUGAS AKHIR/SKRIPSI/TESIS UNTUK KEPENTINGAN AKADEMIS**

Sebagai sivitas akademik Universitas Medan Area, saya yang bertanda tangan di bawah ini:

Nama : SISKA OCTIANI  
NPM : 228160047  
Program Studi : Teknik Informatika  
Fakultas : Teknik  
Jenis Karya : Skripsi

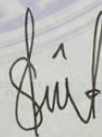
Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Medan Area **Hak Bebas Royalti Noneksklusif (*Non-exclusive Royalty-Free Right*)** atas karya ilmiah saya yang berjudul :

**Klasifikasi Tingkat Kematangan Buah Pisang Berbasis Citra Menggunakan Arsitektur MobileNetV3.**

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Noneksklusif ini Universitas Medan Area berhak menyimpan, mengalihmedia/format-kan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan memublikasikan Skripsi saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Medan  
Pada tanggal : 26 Februari 2026  
Yang menyatakan



(SISKA OCTIANI)  
228160047

## RIWAYAT HIDUP

Penulis bernama SISKI OCTIANI lahir di Rawa Jitu Selatan pada tanggal 11 Oktober 2003. Penulis merupakan anak ke-1 dari 3 bersaudara dari Bapak Darwin Simanihuruk dan Ibu Nelly Waty Tambun Saribu. Penulis menyelesaikan pendidikan sekolah dasar di SD Negeri 040540 Sibolangit Kab. Karo, Kec. Merek dan lulus pada tahun 2016, kemudian melanjutkan ke SMP Santo Paulus Martubung dan lulus pada tahun 2019. Setelah itu penulis menyelesaikan pendidikan menengah atas di SMK Santo Paulus Martubung dan lulus pada tahun 2022. Pada tahun 2022 penulis diterima sebagai mahasiswi di Program Studi Informatika, Fakultas Teknik, Universitas Medan Area. Selama menempuh pendidikan, penulis aktif dalam berbagai akademik maupun nonakademik. Skripsi ini disusun sebagai salah satu syarat untuk memperoleh gelar sarjana S. Kom.



## KATA PENGANTAR

Puji dan syukur penulis panjatkan kehadirat Tuhan Yang Maha Esa atas kasih, penyertaan, dan anugerah-Nya sehingga penulis dapat menyelesaikan skripsi ini dengan baik.

Skripsi ini berjudul "**Klasifikasi Tingkat Kematangan Buah Pisang Berbasis Citra Menggunakan Arsitektur MobileNetV3**". Skripsi ini diajukan untuk memenuhi tugas akhir sebagai salah satu syarat kelulusan pada Fakultas Teknik, Program Studi Teknik Informatika, Universitas Medan Area.


Dalam proses penyelesaian skripsi ini, penulis menyadari bahwa masih terdapat banyak kekurangan, baik dari segi isi, penulisan, maupun bahasa. Oleh karena itu, pada kesempatan ini penulis ingin menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Bapak Prof. Dr. Dadan Ramdan, M.Eng., M.Sc., selaku Rektor Universitas Medan Area.
2. Bapak Dr. Eng. Supriatno, ST., M.T. selaku Dekan Fakultas Teknik Universitas Medan Area.
3. Bapak Dr. Arnes Sembiring, ST, M. Kom selaku Dosen Pembimbing yang telah memberikan ilmu, arahan, serta masukan yang bermanfaat dalam penyelesaian skripsi ini.
4. Bapak Rizki Muliono, S.Kom., M.Kom., selaku Ketua Program Studi Teknik Informatika yang telah memberikan dukungan dan arahan selama masa perkuliahan di Program Studi Teknik Informatika Universitas Medan Area.

5. Teristimewa kepada kedua orang tua tercinta, yang dengan penuh kasih sayang telah mendidik, mendoakan, serta memberikan dukungan dan motivasi dalam menyelesaikan skripsi ini.
6. Seluruh dosen dan staf Program Studi Teknik Informatika Universitas Medan Area yang telah memberikan ilmu, bimbingan, serta bantuan selama proses perkuliahan.
7. Seluruh teman-teman Stambuk 2022 Teknik Informatika yang telah berbagi pengalaman dan kebersamaan selama masa perkuliahan.
8. Teruntuk teman-teman seperjuangan, Vica Sariani Situmorang, dan Adelina Br Nainggolan, terima kasih telah menjadi sahabat dalam suka dan duka selama menjalani perkuliahan, penelitian, hingga penyusunan skripsi ini. Terima kasih atas semangat, motivasi, serta kerja sama yang telah diberikan. Semoga segala perjuangan dan kebersamaan kita membawa manfaat dan berkat bagi kita semua, serta persahabatan kita tetap terjalin dengan baik.

Penulis berharap semoga Tuhan Yang Maha Esa senantiasa mengaruniakan rahmat dan kasih-Nya kepada semua pihak yang telah membantu. Semoga skripsi ini dapat memberikan manfaat bagi kita semua.

Medan, 26 Februari 2026



SISKA OCTIANI  
228160047

## ABSTRAK

Penelitian ini bertujuan mengembangkan dan menerapkan sistem klasifikasi tingkat kematangan buah pisang berbasis citra digital dengan menggunakan arsitektur *MobileNetV3* pada aplikasi *mobile Android*. Fokus masalah terletak pada keterbatasan penilaian manual yang bersifat subjektif, inkonsisten, dan tidak efisien untuk lingkungan industri saat ini. Untuk mengatasi masalah tersebut, acuan teori diambil dari bidang *computer vision* dan *deep learning*, khususnya melalui *Convolutional Neural Network* serta konsep *transfer learning*. Data diperoleh dengan mengambil citra langsung buah pisang Barangan di Desa Sibolangit, Kabupaten Karo, sebanyak 1.500 gambar yang dibagi ke dalam tiga kategori: mentah, setengah matang, dan matang. Selanjutnya, data diproses melalui tahap prapemrosesan yang mencakup *resizing*, normalisasi, dan augmentasi data. Model *MobileNetV3-Small* dan *MobileNetV3-Large* dilatih menggunakan pendekatan *transfer learning* dengan parameter pelatihan yang serupa, dan hasilnya dianalisis secara kuantitatif menggunakan metrik seperti akurasi, presisi, *recall*, *F1-score*, serta *confusion matrix*. Kajian ini menemukan bahwa kedua model menampilkan performa yang tinggi, namun *MobileNetV3-Small* lebih unggul dalam efisiensi komputasi dan waktu inferensi, menjadikannya pilihan yang lebih tepat untuk diimplementasikan di perangkat *mobile* berdaya rendah dalam sistem klasifikasi kematangan pisang secara *real-time*.

**Kata Kunci:** klasifikasi citra, kematangan pisang, *MobileNetV3*, *deep learning*, aplikasi *Android*.

## ABSTRACT

*This study aims to develop and implement a digital image-based banana ripeness classification system using the MobileNetV3 architecture in an Android mobile application. The problem focuses on the limitations of manual assessment, which is subjective, inconsistent, and inefficient for current industrial environments. To address this issue, theoretical references are drawn from the fields of computer vision and deep learning, particularly through Convolutional Neural Networks and the concept of transfer learning. The data were obtained by directly capturing images of Barangan bananas in Sibolangit Village, Karo Regency, totaling 1,500 images divided into three categories: unripe, half-ripe, and ripe. The data were then processed through preprocessing stages including resizing, normalization, and data augmentation. The MobileNetV3-Small and MobileNetV3-Large models were trained using a transfer learning approach with similar training parameters, and the results were analyzed quantitatively using metrics such as accuracy, precision, recall, F1-score, and confusion matrix. This study finds that both models demonstrate high performance; however, MobileNetV3-Small outperforms in terms of computational efficiency and inference time, making it a more appropriate choice for implementation on low-resource mobile devices in real-time banana ripeness classification systems.*

**Keywords:** *image classification, banana ripeness, MobileNetV3, deep learning, Android application.*


## DAFTAR ISI

<b>HALAMAN PENGESAHAN</b> .....	<b>i</b>
<b>HALAMAN PERTANYAAN</b> .....	<b>ii</b>
<b>RIWAYAT HIDUP</b> .....	<b>iv</b>
<b>KATA PENGANTAR</b> .....	<b>v</b>
<b>ABSTRAK</b> .....	<b>vii</b>
<b>ABSTRACT</b> .....	<b>viii</b>
<b>DAFTAR ISI</b> .....	<b>ix</b>
<b>DAFTAR TABEL</b> .....	<b>xi</b>
<b>DAFTAR GAMBAR</b> .....	<b>xii</b>
<b>DAFTAR LAMPIRAN</b> .....	<b>xiii</b>
<b>BAB I PENDAHULUAN</b> .....	<b>1</b>
1.1. Latar Belakang .....	1
1.2. Rumusan Masalah .....	3
1.3. Batasan Masalah.....	4
1.4. Tujuan Penelitian.....	4
1.5. Manfaat Penelitian.....	5
<b>BAB II TINJAUAN PUSTAKA</b> .....	<b>6</b>
2.1. <i>Deep Learning</i> .....	6
2.2. Klasifikasi Citra Digital.....	7
2.3. Arsitektur <i>MobileNetV3</i> .....	7
2.4. <i>Transfer Learning</i> .....	10
2.5. Pengaturan <i>Hyperparameter</i> .....	11
2.6. <i>Confusion Matrix</i> .....	12
2.7. Tingkat Kematangan Buah Pisang .....	14
2.8. Penelitian Terdahulu.....	15
<b>BAB III METODOLOGI PENELITIAN</b> .....	<b>17</b>
3.1. Tahapan Penelitian .....	17
3.2. Pengumpulan Data dan Pra-Pemrosesan .....	19
3.3. Inisialisasi dan Pelatihan Model .....	20
3.3.1. <i>Hyperparameter</i> .....	21
3.4. Evaluasi Model.....	22
3.4.1. Rumus Metrik Evaluasi.....	23
3.5. Implementasi .....	24
3.5.1. Perancangan Antarmuka Aplikasi.....	25

<b>BAB IV HASIL DAN PEMBAHASAN .....</b>	<b>28</b>
4.1 Akuisisi <i>Dataset</i> .....	28
4.2 <i>Preprocessing Dataset</i> .....	29
4.2.1 <i>Resize</i> (Pengubahan Ukuran Citra) .....	29
4.2.2 <i>Random Horizontal Flip</i> (Augmentasi Data).....	30
4.2.3 <i>Normalize</i> (Normalisasi Nilai Piksel) .....	30
4.3 Pelatihan Model <i>MobileNetV3</i> .....	31
4.3.1 <i>Loading Model</i> .....	31
4.3.2 <i>Freeze Feature Extractor</i> Menggunakan <i>Transfer Learning</i> .....	32
4.3.3 Pelatihan Lapisan Terakhir untuk <i>Classifier</i> .....	32
4.3.4 Parameter Pelatihan.....	32
4.3.5 Grafik Akurasi dan <i>Loss</i> .....	33
4.3.6 <i>Confusion Matrix</i> dan <i>recall</i> .....	35
4.4 Perbandingan Model.....	37
4.4.1 Perbandingan Performa Model .....	37
4.4.2 Perbandingan Efisiensi Model .....	38
4.5 Pengembangan Aplikasi <i>Mobile</i> .....	39
4.5.1 Halaman Utama Aplikasi .....	40
4.5.2 Halaman Beranda Aplikasi .....	40
4.5.3 Halaman Fitur Pemindaian dan Analisis Citra.....	41
4.5.4 Halaman Riwayat Klasifikasi.....	42
4.5.5 Halaman Profil dan Informasi Aplikasi .....	43
4.6 Pengujian Aplikasi .....	44
<b>BAB V KESIMPULAN DAN SARAN .....</b>	<b>47</b>
5.1 Kesimpulan.....	47
5.2 Saran .....	48
<b>DAFTAR PUSTAKA .....</b>	<b>49</b>
<b>LAMPIRAN.....</b>	<b>53</b>

## DAFTAR TABEL

	Halaman
Tabel 2. 1. Penelitian Terdahulu .....	15
Tabel 3. 1. Sampel Data .....	20
Tabel 3. 2. <i>Hyperparameter</i> .....	21
Tabel 3. 3. Perancangan Antarmuka Aplikasi .....	25
Tabel 4. 1. Akuisisi <i>Dataset</i> Citra Pisang .....	28
Tabel 4. 2. Parameter Pelatihan Model <i>MobileNetV3-Small</i> .....	33
Tabel 4. 3. Perbandingan Performa <i>MobileNetV3-Small</i> dan <i>MobileNetV3-Large</i> .....	38
Tabel 4. 4. Perbandingan Efisiensi <i>MobileNetV3-Small</i> dan <i>MobileNetV3-Large</i> .....	39



## DAFTAR GAMBAR

	Halaman
Gambar 2. 1. Arsitektur <i>MobileNetV3</i> .....	9
Gambar 2. 2. Detail konfigurasi <i>layer</i> (a). <i>MobileNetV3-large</i> , (b). <i>MobileNetV3-Small</i> .....	10
Gambar 2. 3. Konsep dasar <i>Transfer Learning</i> .....	11
Gambar 2. 4. <i>Confusion Matrix</i> .....	13
Gambar 3. 1. Tahapan Penelitian .....	17
Gambar 4. 1. Grafik Akurasi dan <i>Loss</i> dari <i>MobileNetV3-Small</i> .....	34
Gambar 4. 2. Grafik Akurasi dan <i>Loss</i> dari <i>MobileNetV3-Large</i> .....	34
Gambar 4. 3. <i>Confusion Matrix MobileNetV3-Small</i> .....	35
Gambar 4. 4. <i>Confusion Matrix MobileNetV3-Large</i> .....	36
Gambar 4. 5. Tampilan Halaman Utama Aplikasi .....	40
Gambar 4. 6. Tampilan Halaman Beranda Aplikasi .....	41
Gambar 4. 7. Tampilan Halaman Fitur Pemindaian dan Analisis Citra .....	42
Gambar 4. 8. Tampilan Halaman Riwayat Klasifikasi .....	43
Gambar 4. 9. Tampilan Halaman Profil .....	44
Gambar 4. 10. Hasil Klasifikasi Citra Pisang .....	45

## DAFTAR LAMPIRAN

	Halaman
1. Dokumentasi .....	53



# BAB I PENDAHULUAN

## 1.1. Latar Belakang

Industri pengolahan buah saat ini berkembang menuju sistem produksi otomatis yang mengutamakan kecepatan, efisiensi, dan konsistensi kualitas produk (Patel & Khan, 2021). Salah satu tahap penting dalam proses ini adalah penentuan tingkat kematangan buah pisang yang berfungsi untuk menentukan alur pengolahan, standar kualitas, dan jenis produk akhir yang akan dihasilkan (Martínez-Mora dkk., 2025). Pada industri berskala besar, proses ini sangat berpengaruh terhadap kelancaran proses *grading*, *quality control*, dan *packaging* otomatis (Sinanoglou dkk., 2023).

Meskipun demikian, banyak fasilitas industri yang masih mengandalkan penilaian manual oleh operator untuk mengidentifikasi tingkat kematangan buah. Metode ini memiliki kelemahan signifikan karena bersifat subjektif, dipengaruhi pencahayaan, kelelahan operator, dan tidak mampu mengikuti kecepatan lini produksi modern (Huang dkk., 2024). Selain itu, lingkungan industri seperti *conveyor* otomatis, mesin sortir, dan unit *packaging* tertutup tidak memungkinkan proses penilaian dilakukan oleh manusia secara langsung, sehingga dibutuhkan sistem otomatis yang mampu bekerja secara *real-time* dan konsisten (Arunima dkk., 2024).

Metode tradisional berbasis teknik pengolahan citra konvensional seperti *thresholding* warna terbukti kurang stabil karena sensitif terhadap perubahan cahaya dan bayangan yang umum terjadi pada pabrik pengolahan (Wang & Jiang,

2022). Oleh karena itu, pendekatan berbasis *deep learning* menjadi solusi yang lebih adaptif dan akurat (Karim dkk., 2024). Dalam bidang *computer vision*, model *Convolutional Neural Network (CNN)* terbukti mampu mengenali fitur visual dengan tingkat presisi yang tinggi, sehingga sangat cocok digunakan dalam sistem inspeksi otomatis di industri pangan (García-Navarrete dkk., 2024).

Beberapa penelitian terkait klasifikasi kematangan pisang menggunakan *CNN* seperti *VGG16* (Nafi'iyah dkk., 2023) dan *ResNet50* (Arunima dkk., 2024) telah menunjukkan akurasi tinggi, namun ukuran model yang besar membuatnya sulit diterapkan pada perangkat industri yang mengandalkan komputasi ringan (Rahman dkk., 2025). Hal ini menciptakan kebutuhan akan model yang akurat, namun juga kompak, cepat, dan efisien untuk diintegrasikan pada sistem otomatisasi industri, terutama perangkat *edge computing* dan kamera inspeksi.

Arsitektur *MobileNetV3* menjadi salah satu solusi yang dirancang khusus untuk memenuhi kebutuhan industri tersebut. Model ini memiliki ukuran ringan, konsumsi komputasi rendah, dan tetap memberikan akurasi tinggi melalui kombinasi *depthwise separable convolution*, fungsi aktivasi *h-swish*, dan modul *Squeeze-and-Excitation* (Howard dkk., 2020). Penelitian terbaru juga menunjukkan bahwa arsitektur *lightweight CNN* efektif diimplementasikan pada perangkat *edge* untuk sistem klasifikasi *real-time* (Zhang dkk., 2025). Selain itu, penelitian (Dhanalaxmi dkk., 2025) juga menunjukkan bahwa *MobileNetV3* dapat berjalan secara *real-time* pada perangkat dengan komputasi ringan tanpa penurunan performa.

*MobileNetV3* terdiri dari dua varian utama, yaitu *MobileNetV3-Large*, yang dioptimalkan untuk mencapai akurasi maksimal, dan *MobileNetV3-Small*, yang

dirancang untuk efisiensi serta kecepatan inferensi di perangkat *edge*, *IoT*, dan aplikasi *real-time* dengan sumber daya terbatas (Howard dkk., 2020) Karena karakteristik yang berbeda antara keduanya, perlu dilakukan perbandingan performa dan efisiensi untuk menentukan model yang paling tepat dalam klasifikasi tingkat kematangan buah pisang (Karim dkk., 2024).

Berdasarkan hasil perbandingan tersebut, penelitian ini selanjutnya memilih *MobileNetV3-Small* sebagai model yang diimplementasikan dalam sistem klasifikasi tingkat kematangan pisang berbasis citra. Pemilihan ini didasarkan pada pertimbangan bahwa *MobileNetV3-Small* memberikan keseimbangan terbaik antara akurasi dan efisiensi komputasi, sehingga mampu mendukung proses *grading* dan *packaging* buah secara *real-time* di lingkungan industri.

## 1.2. Rumusan Masalah

Adapun rumusan masalah dalam penelitian ini adalah:

1. Bagaimana performa *MobileNetV3-Small* dan *MobileNetV3-Large* dalam mengklasifikasikan tingkat kematangan buah pisang berbasis citra?
2. Seberapa besar perbedaan akurasi, *precision*, *recall*, dan *F1-score* antara *MobileNetV3-Small* dan *MobileNetV3-Large*?
3. Model manakah yang paling sesuai untuk diimplementasikan pada perangkat berkomputasi rendah berdasarkan hasil perbandingan performa dan efisiensi komputasi?

### 1.3. Batasan Masalah

Batasan masalah dalam penelitian ini yaitu:

1. Penelitian ini menggunakan data primer berupa citra buah pisang yang diperoleh dari Desa Sibolangit Kec. Merek, Kab. Karo. Dataset hanya mencakup jenis pisang Barangan dan tidak mencakup varietas pisang lain maupun objek buah lainnya. Total dataset terdiri dari 1.500 citra yang terbagi ke dalam tiga kategori tingkat kematangan, yaitu mentah, setengah matang, dan matang. Dataset telah diseimbangkan sehingga setiap kelas berjumlah 500 citra, dengan pembagian 70% untuk data latih, 15% untuk data validasi, dan 15% untuk data uji.
2. Model *deep learning* yang dibandingkan adalah *MobileNetV3-Small* dan *MobileNetV3-Large* dengan pendekatan *transfer learning*.
3. Berdasarkan hasil perbandingan, *MobileNetV3-Small* dipilih sebagai model yang diimplementasikan dalam prototipe sistem klasifikasi tingkat kematangan pisang berbasis *Android*.

### 1.4. Tujuan Penelitian

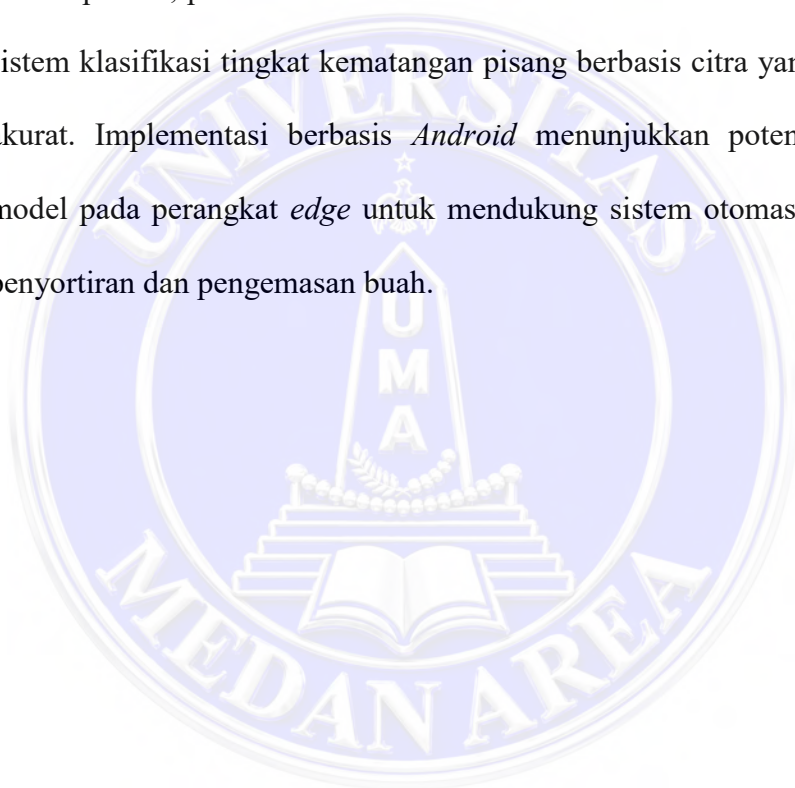
Tujuan dari penelitian ini adalah:

1. Membandingkan performa *MobileNetV3-Small* dan *MobileNetV3-Large* dalam klasifikasi tingkat kematangan pisang berbasis citra.
2. Menentukan model terbaik berdasarkan hasil perbandingan performa dan efisiensi komputasi.
3. Mengimplementasikan *MobileNetV3-Small* sebagai model terpilih dalam prototipe aplikasi *mobile* berbasis *Android*.

## 1.5. Manfaat Penelitian

Penelitian ini diharapkan memberikan manfaat:

1. Secara teoritis, penelitian ini berkontribusi dalam pengembangan ilmu di bidang *computer vision* dan *deep learning*, khususnya dalam kajian komparatif arsitektur *CNN* ringan antara *MobileNetV3-Small* dan *MobileNetV3-Large*.
2. Secara praktis, penelitian ini memberikan rekomendasi model terbaik untuk sistem klasifikasi tingkat kematangan pisang berbasis citra yang efisien dan akurat. Implementasi berbasis *Android* menunjukkan potensi penerapan model pada perangkat *edge* untuk mendukung sistem otomasi pada proses penyortiran dan pengemasan buah.



## BAB II TINJAUAN PUSTAKA

### 2.1. *Deep Learning*

*Deep learning* merupakan bagian dari *machine learning* yang menggunakan jaringan saraf tiruan berlapis (*multi-layer neural networks*) untuk mempelajari representasi data secara otomatis (García-Navarrete dkk., 2024). Teknologi ini mampu mengenali pola yang kompleks dari data berskala besar seperti gambar digital, teks, maupun suara tanpa perlu melalui proses ekstraksi fitur secara manual seperti pada metode tradisional (Lecture, 2021).

Menurut (Martínez-Mora dkk., 2025), kekuatan utama *deep learning* terletak pada struktur lapisan bertingkat yang dapat mempelajari fitur dari yang sederhana hingga yang kompleks, sehingga sangat efektif dalam mengenali pola visual. Teknologi ini memungkinkan komputer memahami karakteristik suatu objek dari data input melalui proses pelatihan berulang yang bertujuan untuk meminimalkan kesalahan (*loss function*) (Zhang dkk., 2025).

Sementara itu, (Chuquimarca dkk., 2023) menyebutkan bahwa *deep learning* telah memberikan kemajuan besar dalam bidang *computer vision* seperti klasifikasi, segmentasi, dan deteksi objek. Dalam bidang pertanian, teknologi ini banyak dimanfaatkan untuk mendeteksi penyakit pada daun, mengidentifikasi jenis tanaman, serta menentukan tingkat kematangan buah secara otomatis dengan akurasi yang tinggi.

## 2.2. Klasifikasi Citra Digital

Klasifikasi citra digital merupakan proses untuk mengelompokkan objek dalam sebuah gambar berdasarkan ciri visual seperti warna, tekstur, dan bentuk (Han dkk., 2024). Tujuan utama dari proses ini yaitu untuk mengenali kategori suatu citra secara otomatis dengan tingkat akurasi yang tinggi, contohnya dalam menentukan tingkat kematangan buah pisang melalui warna kulitnya.

Metode konvensional seperti *thresholding* dan *k-means clustering* sering kali memiliki keterbatasan karena sensitif terhadap perubahan pencahayaan dan latar belakang. Oleh karena itu, pendekatan berbasis *deep learning* kini lebih banyak digunakan karena mampu mempelajari fitur penting secara otomatis dan menghasilkan performa yang lebih stabil (Martínez-Mora dkk., 2025).

Menurut (García-Navarrete dkk., 2024), model *deep learning* dapat mendeteksi perubahan warna dan tekstur pada citra dengan tingkat presisi yang tinggi. Dalam bidang pertanian digital, klasifikasi citra berperan penting untuk menilai kualitas hasil panen, mendeteksi kerusakan pada produk, dan menentukan waktu panen yang optimal. Dengan demikian, teknologi ini dapat mengurangi subjektivitas dalam penilaian manusia serta meningkatkan efisiensi dan keakuratan proses produksi.

## 2.3. Arsitektur *MobileNetV3*

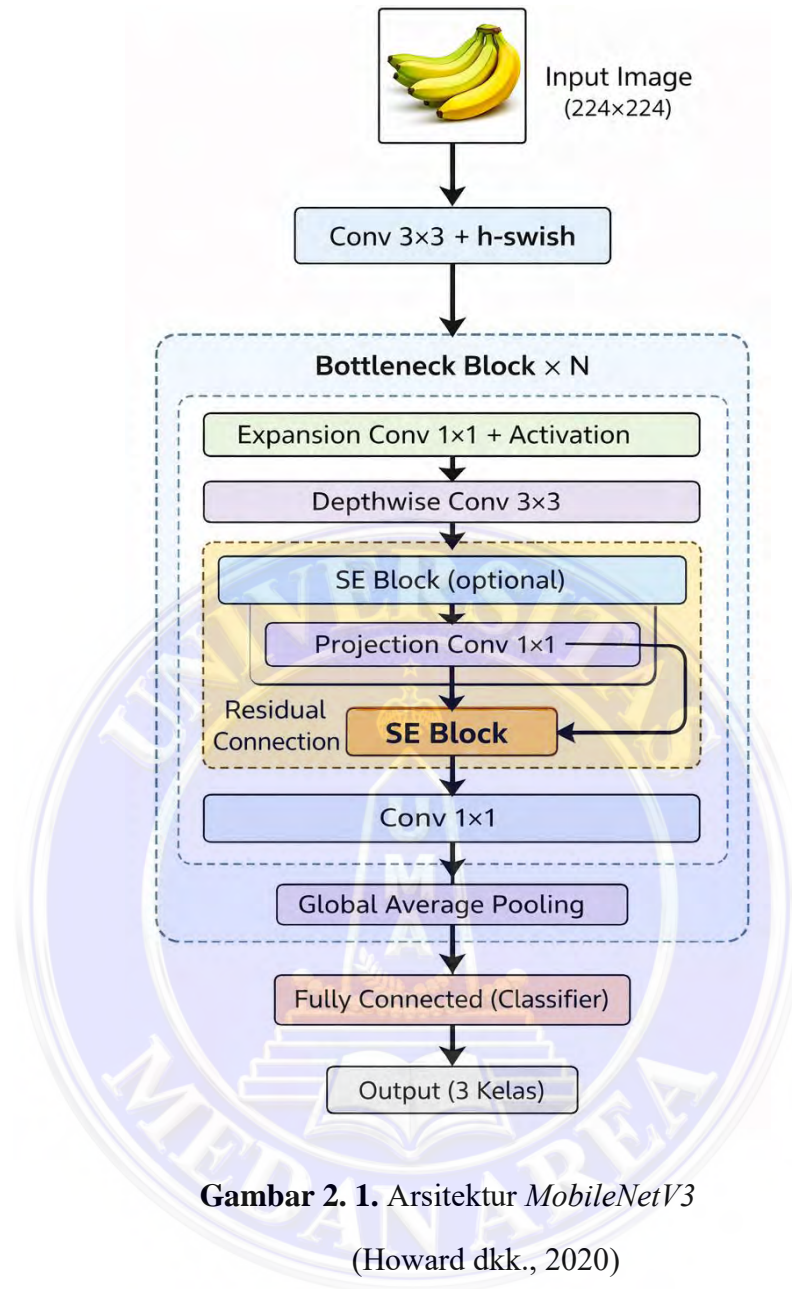
*MobileNetV3* merupakan arsitektur jaringan saraf konvolusional ringan (*lightweight convolutional neural network*) yang dikembangkan oleh (Howard dkk., 2020). Model ini dirancang untuk menghasilkan akurasi tinggi dengan jumlah parameter yang lebih efisien dibandingkan model besar seperti *ResNet* dan

*Inception*. *MobileNetV3* merupakan pengembangan dari *MobileNetV2* dengan menggabungkan pendekatan *Neural Architecture Search (NAS)* serta modul *Squeeze-and-Excitation (SE)* yang berfungsi untuk meningkatkan kualitas representasi fitur pada setiap kanal (Hu dkk., 2020).

Berdasarkan Gambar 2.1, struktur *MobileNetV3* terdiri dari lapisan konvolusi awal (*Conv 3×3*), diikuti oleh serangkaian *bottleneck block* sebagai bagian utama jaringan, serta diakhiri dengan *global average pooling* dan *fully connected layer* untuk proses klasifikasi. Setiap *bottleneck block* menggunakan konsep *inverted residual* yang mencakup tahap ekspansi (*expansion*), *depthwise convolution*, modul *SE* (opsional), dan *projection layer*. Struktur ini memungkinkan efisiensi komputasi yang tinggi tanpa mengurangi kemampuan model dalam mengekstraksi fitur penting dari citra.

Efisiensi *MobileNetV3* diperoleh melalui penggunaan *depthwise separable convolution*, yaitu teknik yang memisahkan proses konvolusi berdasarkan dimensi spasial dan kanal. Metode ini mampu mengurangi jumlah parameter secara signifikan dibandingkan konvolusi konvensional (Howard dkk., 2020). Selain itu, digunakan fungsi aktivasi *h-swish* sebagai pengganti *ReLU6* untuk meningkatkan stabilitas pelatihan dan efisiensi komputasi (Karim dkk., 2024).

Modul *Squeeze-and-Excitation (SE)* berperan sebagai mekanisme *channel attention*, yaitu memberikan bobot lebih besar pada fitur penting dan mengurangi pengaruh fitur yang kurang relevan. Dengan pendekatan ini, model dapat lebih fokus dalam mengenali karakteristik visual seperti warna dan tekstur objek.



*MobileNetV3* memiliki dua varian utama, yaitu *MobileNetV3-Large* dan *MobileNetV3-Small*. *MobileNetV3-Large* dirancang untuk menghasilkan akurasi yang lebih tinggi dengan jumlah parameter yang lebih besar. Sebaliknya, *MobileNetV3-Small* memiliki struktur yang lebih ringan sehingga lebih sesuai untuk perangkat dengan keterbatasan sumber daya seperti *smartphone* dan perangkat *edge computing*.

Perbedaan antara kedua varian tersebut terletak pada jumlah *bottleneck block*, ukuran ekspansi, serta penggunaan modul *SE* pada setiap lapisan. *MobileNetV3-Large* memiliki konfigurasi *layer* yang lebih kompleks untuk meningkatkan akurasi, sedangkan *MobileNetV3-Small* lebih dioptimalkan untuk efisiensi dan kecepatan inferensi. Detail konfigurasi setiap lapisan ditunjukkan pada Gambar 2.2.

Input	Operator	exp size	#out	SE	NL	s
$224^2 \times 3$	conv2d	-	16	-	HS	2
$112^2 \times 16$	bneck, 3x3	16	16	-	RE	1
$112^2 \times 16$	bneck, 3x3	64	24	-	RE	2
$56^2 \times 24$	bneck, 3x3	72	24	-	RE	1
$56^2 \times 24$	bneck, 5x5	72	40	✓	RE	2
$28^2 \times 40$	bneck, 5x5	120	40	✓	RE	1
$28^2 \times 40$	bneck, 5x5	120	40	✓	RE	1
$28^2 \times 40$	bneck, 3x3	240	80	-	HS	2
$14^2 \times 80$	bneck, 3x3	200	80	-	HS	1
$14^2 \times 80$	bneck, 3x3	184	80	-	HS	1
$14^2 \times 80$	bneck, 3x3	184	80	-	HS	1
$14^2 \times 80$	bneck, 3x3	480	112	✓	HS	1
$14^2 \times 112$	bneck, 3x3	672	112	✓	HS	1
$14^2 \times 112$	bneck, 5x5	672	160	✓	HS	2
$7^2 \times 160$	bneck, 5x5	960	160	✓	HS	1
$7^2 \times 160$	bneck, 5x5	960	160	✓	HS	1
$7^2 \times 160$	conv2d, 1x1	-	960	-	HS	1
$7^2 \times 960$	pool, 7x7	-	-	-	-	1
$1^2 \times 960$	conv2d 1x1, NBN	-	1280	-	HS	1
$1^2 \times 1280$	conv2d 1x1, NBN	-	k	-	-	1

Input	Operator	exp size	#out	SE	NL	s
$224^2 \times 3$	conv2d, 3x3	-	16	-	HS	2
$112^2 \times 16$	bneck, 3x3	16	16	✓	RE	2
$56^2 \times 24$	bneck, 3x3	72	24	-	RE	1
$28^2 \times 24$	bneck, 3x3	88	24	-	RE	1
$28^2 \times 24$	bneck, 5x5	96	40	✓	HS	2
$14^2 \times 40$	bneck, 5x5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5x5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5x5	120	48	✓	HS	1
$14^2 \times 48$	bneck, 5x5	144	48	✓	HS	1
$14^2 \times 48$	bneck, 5x5	288	96	✓	HS	2
$7^2 \times 96$	bneck, 5x5	576	96	✓	HS	1
$7^2 \times 96$	bneck, 5x5	576	96	✓	HS	1
$7^2 \times 96$	conv2d, 1x1	-	576	✓	HS	1
$7^2 \times 576$	pool, 7x7	-	-	-	-	1
$1^2 \times 576$	conv2d 1x1, NBN	-	1280	-	HS	1
$1^2 \times 1280$	conv2d 1x1, NBN	-	k	-	-	1

(a).

(b).

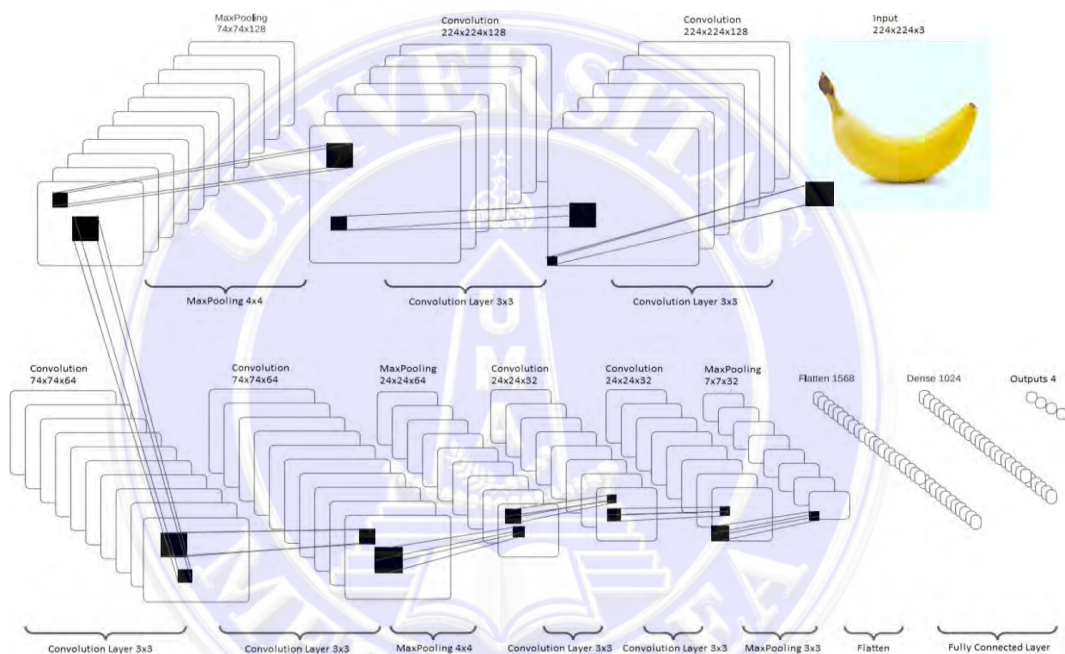
**Gambar 2. 2.** Detail konfigurasi *layer* (a). *MobileNetV3-large*, (b). *MobileNetV3-Small*

(Howard dkk., 2020)

## 2.4. Transfer Learning

*Transfer learning* merupakan metode yang memanfaatkan model yang sudah dilatih sebelumnya (*pre-trained model*) untuk menyelesaikan tugas baru dengan karakteristik serupa. Model awal berfungsi sebagai ekstraktor fitur untuk mengenali pola dasar seperti warna, bentuk, dan tekstur pada citra. Hasil ekstraksi ini kemudian diteruskan ke lapisan klasifikasi baru yang dilatih sesuai dengan kebutuhan penelitian (Chuquimarca dkk., 2023).

Pendekatan ini membuat proses pelatihan menjadi lebih cepat dan efisien karena model sudah memiliki pengetahuan awal dari *dataset* besar seperti *ImageNet*. Selain itu, *transfer learning* mampu meningkatkan performa model terutama ketika *dataset* terbatas (Martínez-Mora dkk., 2025). Konsep dasar *transfer learning* ini ditunjukkan pada Gambar 2.2, di mana model awal mengekstrak fitur-fitur penting dari gambar. Selanjutnya, *classifier* baru melakukan proses klasifikasi berdasarkan kategori yang diperlukan dalam penelitian.



**Gambar 2. 3.** Konsep dasar *Transfer Learning*

(Chuquimarca dkk., 2023)

## 2.5. Pengaturan *Hyperparameter*

Pengaturan *hyperparameter* merupakan tahap penting yang berpengaruh besar terhadap kinerja model *deep learning*. Beberapa parameter seperti *learning rate*, jumlah *epoch*, ukuran *batch size*, dan jenis *optimizer* sangat menentukan

seberapa cepat model mencapai konvergensi serta seberapa akurat hasil pelatihannya (Kumar & Bhawna, 2024).

*Learning rate* berfungsi untuk mengatur seberapa besar langkah perubahan bobot jaringan pada setiap iterasi. Jika nilainya terlalu besar, proses pelatihan bisa menjadi tidak stabil, sedangkan jika terlalu kecil, proses pembelajaran akan berjalan lambat. *Optimizer* seperti Adam sering digunakan karena mampu menyesuaikan laju pembelajaran secara adaptif dan mempercepat proses pelatihan (Srivastava dkk., 2022).

Jumlah *epoch* menggambarkan berapa kali seluruh *dataset* digunakan dalam proses pelatihan, sementara *batch size* menentukan jumlah data yang diproses sebelum bobot jaringan diperbarui. Selain itu, penerapan *dropout* berfungsi untuk mencegah *overfitting* dengan cara menonaktifkan sebagian neuron secara acak saat pelatihan berlangsung (Srivastava dkk., 2022). Dengan mengatur *hyperparameter* secara tepat, model dapat mencapai keseimbangan antara tingkat akurasi yang tinggi dan kemampuan generalisasi yang baik terhadap data baru.

## 2.6. Confusion Matrix

*Confusion matrix* digunakan sebagai alat untuk mengevaluasi performa model klasifikasi dengan cara membandingkan hasil prediksi model terhadap data aktual (Powers, 2020). Matriks ini memiliki empat komponen utama, yaitu *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*.

Melalui *confusion matrix*, dapat dihitung berbagai metrik evaluasi seperti akurasi (*accuracy*), presisi (*precision*), *recall*, dan *F1-score*. Akurasi menggambarkan seberapa besar tingkat kebenaran prediksi model, presisi

menunjukkan seberapa tepat model dalam mengklasifikasikan data positif, *recall* menggambarkan kemampuan model dalam mengenali seluruh data positif, sedangkan *F1-score* merupakan kombinasi harmonis antara presisi dan *recall* (Powers, 2020).

		Prediction	
		Positive	Negative
Actual	Negative	TP	FP
	Positive	FN	TN

**Gambar 2. 4.** *Confusion Matrix*  
(Powers, 2020)

Dalam penelitian ini, menggunakan *confusion matrix* sebagai alat untuk mengevaluasi kinerja model *MobileNetV3-Small* dan *MobileNetV3-Large* dalam mengklasifikasikan tingkat kematangan pisang. Dengan bantuan matriks ini, dapat menganalisis tingkat akurasi serta kesalahan klasifikasi untuk setiap kategori dalam *dataset* citra uji. Tujuan utama dari analisis ini adalah untuk memahami sejauh mana kedua model dapat mengenali dan membedakan tingkat kematangan pisang secara akurat, sehingga dapat memberikan wawasan yang lebih mendalam tentang efektivitas masing-masing model dalam tugas klasifikasi tersebut.

## 2.7. Tingkat Kematangan Buah Pisang

Pisang (*Musa spp.*) merupakan salah satu jenis buah klimakterik yang mengalami berbagai perubahan fisik dan kimia selama proses pematangan. Warna kulit pisang biasanya berubah dari hijau menjadi kuning, kemudian kecokelatan hingga hitam karena terjadinya penurunan klorofil dan peningkatan pigmen karotenoid (Munoz dkk., 2024). Selain itu, proses ini juga disertai peningkatan kadar gula, penurunan kadar pati, dan tekstur buah yang semakin lunak akibat aktivitas enzim amilase (Huang dkk., 2024).

Dalam lingkungan industri pengolahan buah, penentuan tingkat kematangan pisang biasanya masih dilakukan secara visual oleh operator. Proses manual ini memiliki kelemahan karena bersifat subjektif dan hasil penilaiannya tidak selalu konsisten, terutama ketika dilakukan pada lini produksi yang berlangsung cepat. Oleh karena itu, pemanfaatan teknologi berbasis citra digital menjadi alternatif yang lebih objektif, stabil, dan efisien untuk menentukan tingkat kematangan pisang (Chuquimarca dkk., 2023).

Seiring perkembangan teknologi *computer vision*, proses penentuan tingkat kematangan kini dapat dilakukan secara otomatis menggunakan model *deep learning* seperti *CNN*. Model ini mampu mengenali perubahan warna dan tekstur buah dengan akurasi tinggi sehingga sangat sesuai untuk kebutuhan inspeksi kualitas pada sistem industri. Pada penelitian ini, tingkat kematangan pisang difokuskan pada tiga kategori utama yaitu mentah, setengah matang, dan matang, yang mewakili perubahan visual yang paling mudah diamati melalui citra digital.


## 2.8. Penelitian Terdahulu

Berikut adalah tabel yang menampilkan beberapa penelitian terkait penentuan tingkat kematangan buah berbasis citra menggunakan berbagai metode pengolahan citra dan arsitektur *deep learning*.

**Tabel 2. 1.** Penelitian Terdahulu

No.	Penulis	Metode	Keterangan
1.	(Nafi'iyah dkk., 2023)	<i>CNN (VGG16)</i>	Penelitian ini mengelompokkan tingkat kematangan pisang menjadi tiga kategori yaitu mentah, matang, dan terlalu matang. Model <i>CNN</i> yang digunakan cukup akurat dengan hasil 93,2%, namun ukuran model masih besar sehingga belum cocok dijalankan pada perangkat <i>mobile</i> .
2.	(Wang & Jiang, 2022)	<i>K-Means Clustering</i>	Studi ini mendeteksi tingkat kematangan pisang berdasarkan warna kulit menggunakan metode <i>K-Means Clustering</i> . Akurasinya hanya mencapai 76,4% karena model sangat sensitif terhadap pencahayaan dan latar belakang gambar.
3.	(Arunima dkk., 2024)	<i>ResNet50 + Data Augmentation</i>	Penelitian ini menerapkan model <i>ResNet50</i> dengan teknik augmentasi data untuk klasifikasi pisang dan memperoleh akurasi 95,8%. Namun, waktu pelatihan cukup lama dan membutuhkan perangkat dengan kapasitas komputasi tinggi.
4.	(Martínez-Mora dkk., 2025)	<i>EfficientNet-B0</i>	Penelitian ini mengklasifikasikan tingkat kematangan tomat menggunakan <i>EfficientNet-B0</i> dengan akurasi 97,4%. Model relatif ringan, namun penelitian tidak berfokus pada buah pisang sehingga belum dapat langsung diterapkan.

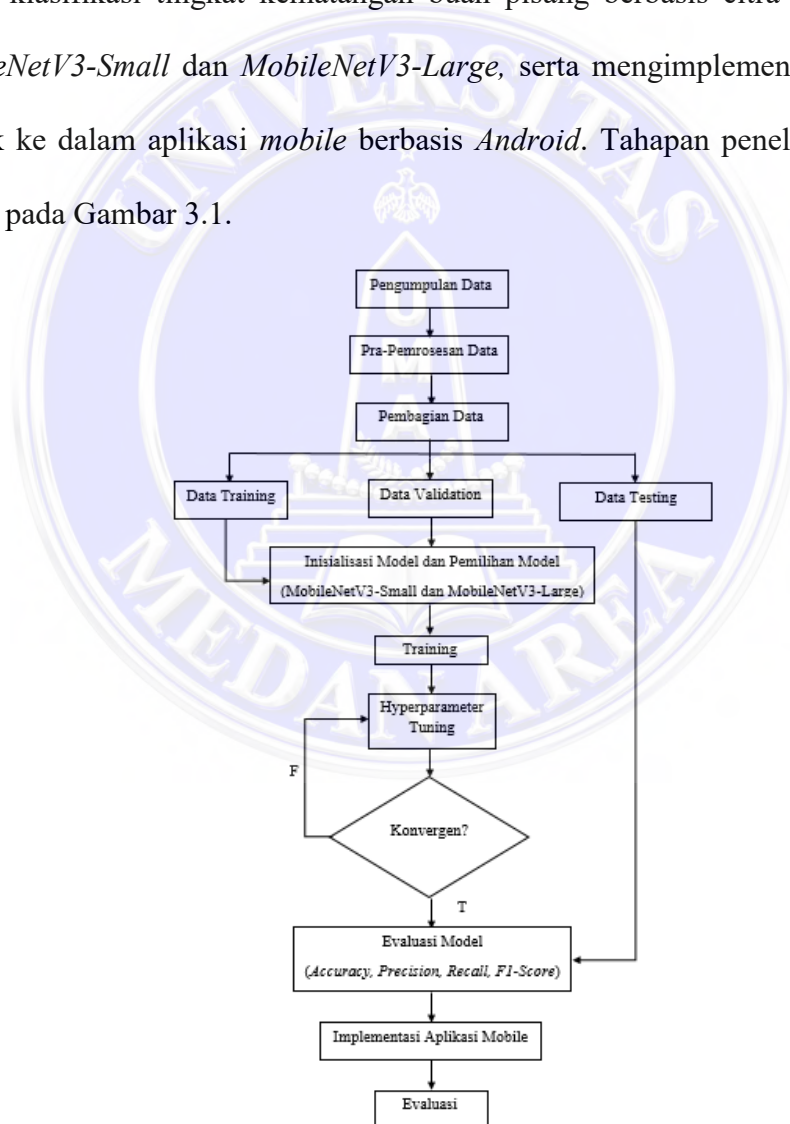
5.	(Fanny dkk., 2025)	<i>YOLOv5 + Image Enhancement</i>	Penelitian ini mendeteksi tingkat kematangan pisang menggunakan <i>YOLOv5</i> dengan teknik peningkatan citra dan menghasilkan akurasi 96,1%. Namun ukuran model masih cukup besar sehingga kurang optimal untuk perangkat <i>mobile</i> .
6.	(Dhanalaxmi dkk., 2025)	<i>MobileNetV3</i>	Penelitian ini menunjukkan bahwa <i>MobileNetV3</i> mampu melakukan klasifikasi penyakit kardiovaskular dengan akurasi sangat tinggi hingga 99,82% serta berjalan cepat dan efisien pada perangkat dengan komputasi rendah. Namun, penelitian ini difokuskan pada data medis sehingga belum diterapkan khusus untuk klasifikasi tingkat kematangan pisang.



## BAB III METODOLOGI PENELITIAN

### 3.1. Tahapan Penelitian

Penelitian ini dilaksanakan melalui beberapa tahapan yang disusun secara terstruktur untuk mencapai tujuan utama, yaitu membangun dan membandingkan model klasifikasi tingkat kematangan buah pisang berbasis citra menggunakan *MobileNetV3-Small* dan *MobileNetV3-Large*, serta mengimplementasikan model terbaik ke dalam aplikasi *mobile* berbasis *Android*. Tahapan penelitian ini dapat dilihat pada Gambar 3.1.



**Gambar 3. 1.** Tahapan Penelitian

Pada Gambar 3.1, terlihat bahwa proses penelitian ini dimulai dari pengumpulan *dataset* citra buah pisang dengan berbagai tingkat kematangan. Setelah data terkumpul, dilakukan tahap pra-pemrosesan, meliputi perubahan ukuran citra (*resizing*) dan normalisasi nilai piksel agar sesuai dengan kebutuhan model.

Selanjutnya, *dataset* dibagi menjadi tiga bagian, yaitu data latih, data validasi, dan data uji. Data latih dan data validasi digunakan dalam proses pelatihan dua varian arsitektur *MobileNetV3*, yaitu *MobileNetV3-Small* dan *MobileNetV3-Large*, termasuk pada tahap *hyperparameter tuning* untuk memperoleh konfigurasi terbaik dari masing-masing model.

Proses pelatihan dilakukan secara iteratif hingga masing-masing model mencapai kondisi konvergensi. Data uji kemudian digunakan untuk mengevaluasi performa kedua model berdasarkan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Berdasarkan hasil evaluasi tersebut, dilakukan perbandingan performa dan efisiensi komputasi untuk menentukan model yang paling sesuai digunakan pada perangkat *mobile*.

Setelah model terbaik ditentukan, yaitu *MobileNetV3-Small*, model tersebut diimplementasikan ke dalam aplikasi *mobile* berbasis *Android*. Implementasi ini bertujuan agar sistem mampu melakukan klasifikasi tingkat kematangan pisang secara otomatis dan *real-time* melalui kamera *smartphone*.

### 3.2. Pengumpulan Data dan Pra-Pemrosesan

Jenis data yang digunakan dalam penelitian ini merupakan data primer berupa kumpulan citra buah pisang yang berasal dari Desa Sibolangit, Kec. Merek, kab. Karo yang berisi gambar-gambar buah pisang dengan tiga kategori tingkat kematangan, yaitu mentah, setengah matang, dan matang.

Untuk memastikan jumlah data pada setiap kelas seimbang, dilakukan proses penyeimbangan data (*Balancing*) dengan cara *sampling* hingga diperoleh 500 citra per kelas, sehingga total data yang digunakan dalam penelitian ini berjumlah 1.500 citra.




Data tersebut kemudian dibagi menjadi tiga bagian, yaitu data latih sebesar 70%, data validasi sebesar 15%, dan data uji sebesar 15% dari total citra pada masing-masing kelas.

Selanjutnya dilakukan tahap pra-pemrosesan data, meliputi perubahan ukuran (*resizing*) citra menjadi  $224 \times 224$  piksel agar sesuai dengan ukuran input pada arsitektur *MobileNetV3*. Normalisasi citra dilakukan menggunakan nilai *mean* dan *standard deviation* dari *dataset ImageNet* agar sesuai dengan bobot *pre-trained* pada arsitektur *MobileNetV3*. Proses normalisasi ini bertujuan untuk mempercepat konvergensi model serta menjaga kestabilan proses pelatihan.

Selain itu, pada data latih diterapkan teknik *data augmentation* untuk meningkatkan keragaman data dan mengurangi risiko *overfitting*. Teknik augmentasi yang digunakan dibatasi pada pembalikan horizontal (*horizontal flip*) dengan probabilitas tertentu. Pendekatan augmentasi ini dipilih untuk menjaga efisiensi komputasi dan kestabilan proses pelatihan, mengingat arsitektur *MobileNetV3* dirancang sebagai model ringan yang dioptimalkan untuk perangkat

berdaya rendah. Penerapan augmentasi data ini diharapkan dapat meningkatkan kemampuan generalisasi model dalam mengenali tingkat kematangan buah pisang pada berbagai kondisi pencahayaan dan sudut pengambilan gambar. Adapun pembagian sampel data dapat dilihat pada Tabel 3.1.

**Tabel 3. 1.** Sampel Data

Citra Pisang	Nama Label	Jumlah Data
	Mentah	500
	Setengah Matang	500
	Matang	500

### 3.3. Inisialisasi dan Pelatihan Model

Model yang digunakan dalam penelitian ini adalah dua varian arsitektur *MobileNetV3*, yaitu *MobileNetV3-Small* dan *MobileNetV3-Large* dengan pendekatan *Transfer Learning*. Pendekatan ini memanfaatkan bobot model yang telah dilatih sebelumnya menggunakan *dataset ImageNet* sehingga proses pelatihan menjadi lebih efisien dan stabil, terutama ketika jumlah data pelatihan terbatas.

Pada tahap inialisasi model, lapisan konvolusi (*feature extractor*) dari arsitektur *MobileNetV3-Small* dibekukan (*frozen*) sehingga bobotnya tidak diperbarui selama proses pelatihan. Pembekuan lapisan ini bertujuan untuk mempertahankan kemampuan ekstraksi fitur umum seperti warna, bentuk, dan tekstur yang telah dipelajari dari *dataset ImageNet*.

Selanjutnya, lapisan klasifikasi (*classifier*) pada *MobileNetV3-Small* dan *MobileNetV3-Large* dimodifikasi dengan mengganti lapisan *fully connected* terakhir agar sesuai dengan kebutuhan klasifikasi tiga kelas tingkat kematangan buah pisang, yaitu mentah, setengah matang, dan matang. Proses pelatihan difokuskan pada lapisan klasifikasi tersebut dengan memperbarui bobotnya menggunakan data latih yang telah disiapkan hingga model mencapai performa yang optimal.

### 3.3.1. Hyperparameter

Selama proses *training*, *hyperparameter* yang digunakan dalam penelitian ini adalah:

**Tabel 3. 2. Hyperparameter**

No.	Hyperparameter	Nilai	Alasan Pemilihan
1.	Optimizer	Adam	<i>Optimizer</i> Adam dipilih karena mampu menyesuaikan <i>learning rate</i> secara adaptif pada setiap parameter, sehingga proses pelatihan menjadi lebih cepat dan stabil. Adam juga banyak digunakan pada model ringan seperti <i>MobileNetV3</i> untuk menjaga kestabilan nilai <i>loss</i> selama proses <i>training</i> (Srivastava dkk., 2022).

2.	<i>Learning Rate</i>	0.0001	Nilai <i>learning rate</i> ini dipilih untuk memastikan perubahan bobot model tetap stabil dan tidak terlalu agresif. Nilai tersebut terbukti efektif pada arsitektur <i>MobileNetV3</i> serta membantu mencegah kegagalan konvergensi selama proses pembelajaran (Dhanalaxmi dkk., 2025).
3.	<i>Batch size</i>	32	Ukuran <i>batch size</i> 32 dipilih karena memberikan keseimbangan antara kecepatan pelatihan dan kestabilan hasil pembelajaran. Nilai ini umum digunakan pada model <i>CNN</i> berukuran ringan hingga menengah karena tidak membebani memori namun tetap menghasilkan performa yang optimal (Kumar & Bhawna, 2024).
4.	<i>Epoch</i>	50	Jumlah <i>epoch</i> ditetapkan sebanyak 50 karena arsitektur <i>MobileNetV3</i> memiliki kemampuan konvergensi yang relatif cepat. Nilai ini dinilai cukup untuk memungkinkan model mempelajari pola dari data pelatihan secara optimal tanpa menyebabkan <i>overfitting</i> (Dhanalaxmi dkk., 2025).

Pemilihan nilai-nilai *hyperparameter* pada Tabel 3.2, tujuannya agar kedua model dapat mencapai akurasi yang tinggi dengan waktu pelatihan yang efisien dan stabil.

### 3.4. Evaluasi Model

Evaluasi adalah langkah penting yang dilakukan untuk mengukur seberapa baik performa model dalam melakukan klasifikasi menggunakan data uji. Pada tahap ini, digunakan beberapa metrik evaluasi, yaitu akurasi (*accuracy*), presisi (*precision*), *recall*, dan *F1-score* sebagai dasar untuk menilai kualitas hasil prediksi model.

### 3.4.1. Rumus Metrik Evaluasi

Perhitungan metrik dilakukan dengan rumus sebagai berikut:

#### 1. Akurasi (*Accuracy*)

Menghitung seberapa besar jumlah prediksi yang tepat dibandingkan dengan seluruh data uji yang digunakan.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

#### 2. Presisi (*Precision*)

Menunjukkan tingkat ketepatan model dalam mengenali data yang termasuk ke dalam kelas positif

$$Precision = \frac{TP}{TP + FP} \quad (3.2)$$

#### 3. Recall (Sensitivitas)

Menunjukkan sejauh mana model mampu menemukan atau mengenali seluruh data yang benar-benar termasuk dalam kelas positif.

$$Recall = \frac{TP}{TP + FN} \quad (3.3)$$

#### 4. *F1-Score*

Merupakan nilai rata-rata harmonis dari presisi dan *recall* yang digunakan untuk mengukur keseimbangan kinerja model secara keseluruhan.

$$F1 - Score = 2x \frac{Precision \times Recall}{Precision + Recall} \quad (3.4)$$

Hasil evaluasi selanjutnya akan ditampilkan dalam bentuk *confusion matrix* untuk menganalisis distribusi prediksi pada setiap kelas. Model dengan performa terbaik akan dipilih untuk tahap implementasi.

### 3.5. Implementasi

Implementasi merupakan tahap di mana model yang sudah dilatih diterapkan ke dalam aplikasi sehingga dapat digunakan langsung oleh pengguna. Pada tahap ini, model *MobileNetV3-Small* dengan performa terbaik berdasarkan hasil evaluasi disimpan dalam bentuk file bobot (*model weight*) setelah proses pelatihan selesai.


Model yang telah disimpan tersebut selanjutnya digunakan pada tahap implementasi aplikasi sebagai sistem klasifikasi tingkat kematangan buah pisang. Aplikasi dirancang dengan antarmuka yang sederhana agar mudah digunakan oleh pengguna. Pengguna dapat mengambil gambar buah pisang secara langsung melalui kamera atau memilih citra dari galeri perangkat.

Setelah gambar dipilih, sistem akan memproses citra tersebut dan menampilkan hasil prediksi tingkat kematangan buah pisang secara otomatis dan *real-time* sesuai dengan kategori yang telah ditentukan, yaitu mentah, setengah matang, dan matang. Implementasi ini berfungsi sebagai prototipe sistem klasifikasi berbasis citra yang dapat dijalankan pada perangkat bergerak dengan sumber daya terbatas.



### 3.5.1. Perancangan Antarmuka Aplikasi

Perancangan antarmuka aplikasi dirancang berdasarkan *mockup* untuk memberikan gambaran visual dan alur penggunaan sistem yang jelas. *Mockup* ini menampilkan struktur halaman yang sederhana, modern, dan mudah dipahami oleh pengguna. Perancangan antarmuka aplikasi yang telah dibuat dapat dilihat pada tabel 3.3.

**Tabel 3. 3.** Perancangan Antarmuka Aplikasi

Nama Tampilan	Deskripsi
<p data-bbox="443 891 616 922">Tampilan Awal</p> 	<p data-bbox="751 853 1358 1066">Halaman pembuka aplikasi menampilkan sapaan kepada pengguna dengan teks "Halo! Siap untuk memindai pisang?". Di halaman ini, pengguna diminta untuk mengisi nama panggilan sebagai identitas sebelum memulai penggunaan aplikasi. Terdapat tombol "Mulai Sekarang" untuk melanjutkan ke halaman utama aplikasi.</p>

<p style="text-align: center;"><b>Tampilan Beranda</b></p> 	<p>Halaman beranda menampilkan informasi tentang jumlah hasil klasifikasi pisang yang telah dilakukan, terdiri dari kategori Matang, Setengah Matang, dan Mentah, serta total keseluruhan klasifikasi. Di bagian tengah, terdapat tombol “Mulai Pindai Pisang” yang berfungsi untuk memulai proses klasifikasi. Selain itu, terdapat bagian Riwayat Terbaru yang menunjukkan histori hasil klasifikasi, jika data tersedia.</p>
<p style="text-align: center;"><b>Tampilan Scan</b></p> 	<p>Di halaman ini, pengguna dapat memilih metode pengambilan gambar untuk klasifikasikan kematangan pisang. Terdapat dua opsi, yaitu Ambil Foto menggunakan kamera secara langsung dan <i>Upload Galeri</i> untuk memilih gambar dari penyimpanan perangkat. Halaman ini berfungsi sebagai penghubung sebelum proses klasifikasi dimulai.</p>
<p style="text-align: center;"><b>Tampilan Riwayat</b></p> 	<p>Halaman riwayat klasifikasi menampilkan daftar hasil klasifikasi pisang yang telah dilakukan sebelumnya. Pengguna dapat memfilter riwayat berdasarkan kategori Semua, Matang, Setengah Matang, dan Mentah. Jika belum ada data, sistem akan menunjukkan informasi bahwa riwayat tidak tersedia.</p>

<p>Tampilan Profil</p> 	<p>Halaman profil menampilkan informasi akun pengguna, termasuk nama pengguna dan identitas aplikasi. Terdapat menu "Tentang Aplikasi" untuk melihat informasi versi aplikasi, serta tombol "Keluar Akun" yang digunakan untuk mengakhiri sesi penggunaan.</p>
<p>Tampilan Hasil Klasifikasi</p> 	<p>Halaman hasil klasifikasi menampilkan gambar pisang yang telah dianalisis beserta prediksi tingkat kematangannya, yaitu Matang, Setengah Matang, atau Mentah. Selain itu, tingkat keyakinan (<i>confidence score</i>) dari hasil klasifikasi juga ditampilkan. Pengguna dapat memilih tombol "Foto Ulang" untuk melakukan pemindaian kembali atau "Selesai" untuk mengakhiri proses.</p>

## BAB V KESIMPULAN DAN SARAN

### 5.1 Kesimpulan

Berdasarkan hasil penelitian mengenai klasifikasi tingkat kematangan pisang menggunakan arsitektur *MobileNetV3*, dapat disimpulkan bahwa pendekatan *deep learning* dengan model *Convolutional Neural Network (CNN)* efektif dalam mengklasifikasikan tingkat kematangan pisang secara akurat dan konsisten. Proses klasifikasi dilakukan pada tiga kategori, yaitu mentah, setengah matang, dan matang, dengan memanfaatkan ciri visual seperti warna dan tekstur kulit pisang.

Hasil uji menunjukkan bahwa kedua varian model, *MobileNetV3-Small* dan *MobileNetV3-Large*, memberikan performa klasifikasi yang sangat baik dengan akurasi, *precision*, *recall*, dan *F1-score* yang tinggi. Namun, *MobileNetV3-Small* memiliki keunggulan dalam hal efisiensi komputasi, ukuran model yang lebih kecil, dan waktu inferensi yang lebih cepat dibandingkan *MobileNetV3-Large*, sehingga lebih cocok untuk perangkat dengan sumber daya terbatas.

Dengan mempertimbangkan performa dan efisiensi, *MobileNetV3-Small* dipilih sebagai model terbaik dan diimplementasikan dalam aplikasi *mobile* berbasis *Android*. Implementasi ini membuktikan bahwa model *MobileNetV3-Small* dapat melakukan klasifikasi tingkat kematangan pisang secara *real-time* menggunakan citra dari kamera atau galeri perangkat. Penelitian ini berhasil menciptakan prototipe sistem klasifikasi tingkat kematangan pisang yang akurat, efisien, dan dapat digunakan pada perangkat bergerak.

## 5.2 Saran

Berdasarkan hasil penelitian yang telah diperoleh, terdapat beberapa saran untuk pengembangan penelitian selanjutnya. Disarankan untuk memperluas jenis *dataset* dengan menambahkan varietas pisang lain serta variasi kondisi pencahayaan agar model dapat memiliki kemampuan generalisasi yang lebih baik terhadap berbagai situasi nyata.

Selanjutnya, penelitian dapat mengembangkan sistem klasifikasi dengan jumlah kategori tingkat kematangan yang lebih rinci, seperti menambahkan kategori "terlalu matang." Ini akan membuat hasil klasifikasi menjadi lebih spesifik dan aplikatif untuk kebutuhan industri pengolahan buah. Penggunaan teknik augmentasi data yang lebih bervariasi juga perlu dipertimbangkan untuk meningkatkan ketahanan model terhadap variasi citra.

Dari sisi implementasi, pengembangan lebih lanjut dapat dilakukan dengan mengintegrasikan aplikasi ke dalam sistem *Internet of Things (IoT)* atau perangkat *edge computing* pada lini produksi industri. Di samping itu, optimasi model menggunakan teknik *quantization* atau *pruning* dapat diterapkan untuk meningkatkan efisiensi dan performa aplikasi pada perangkat dengan spesifikasi rendah.

## DAFTAR PUSTAKA

- Arunima, P. L., Gopinath, P. P., Lekshmi, P. R. G., & Esakkimuthu, M. (2024). Digital assessment of post-harvest Nendran banana for faster grading: CNN-based ripeness classification model. *Postharvest Biology and Technology*, 214, 112972.
- Chuquimarca, L. E., Vintimilla, B. X., & Velastin, S. A. (2023). Banana Ripeness Level Classification Using a Simple CNN Model Trained with Real and Synthetic Datasets. *Proceedings of the International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications*, 5, 536–543. <https://doi.org/10.5220/0011654600003417>
- Dhanalaxmi, B., Kumar, B. N., Raju, Y., & Channapragada, R. S. R. (2025). MobileNetV3: an efficient deep learning-based feature selection and classification technique for cardiovascular disease. *Journal of Engineering and Applied Science*, 72(1), 1–33. <https://doi.org/10.1186/s44147-025-00654-4>
- Fanny, D., Permadi, H., Utami, A., & Gustalika, M. A. (2025). *Experimental and Exploration Study of Deep Learning Model Performance of Convolutional Neural Network ( CNN ) algorithm for Skin Cancer Classification*
- Experimental and Exploration Study of Deep Learning Model Performance of Convolutional Neural Network ( . 0–22.*
- García-Navarrete, O. L., Correa-Guimaraes, A., & Navas-Gracia, L. M. (2024). Application of Convolutional Neural Networks in Weed Detection and Identification: A Systematic Review. *Agriculture (Switzerland)*, 14(4), 1–19.

<https://doi.org/10.3390/agriculture14040568>

Han, X., Zhang, L., Zhao, Y., & Wang, C. (2024). Banana ripeness determination based on CNN and XgBoost. *Food and Machinery*,

40(4). <https://doi.org/10.13652/j.spjx.1003.5788.2024.60015>

Howard, A., Wang, W., Chu, G., Chen, L., Chen, B., & Tan, M. (2020). Searching for MobileNetV3 Accuracy vs MADDs vs model size. *International Conference on Computer Vision*, 1314–1324.

Hu, J., Shen, L., & Sun, G. (2020).

Squeeze-and Excitation\_Networks\_CVPR\_2020\_paper.pdf. *Cvpr*,

7132–7141.

[http://openaccess.thecvf.com/content\\_cvpr\\_2020/html/Hu\\_Squeeze-and-](http://openaccess.thecvf.com/content_cvpr_2020/html/Hu_Squeeze-and-Excitation_Networks_CVPR_2018_paper.html)

[Excitation\\_Networks\\_CVPR\\_2018\\_paper.html](http://openaccess.thecvf.com/content_cvpr_2020/html/Hu_Squeeze-and-Excitation_Networks_CVPR_2018_paper.html)

Huang, P.-H., Cheng, Y.-T., Lu, W.-C., Chiang, P.-Y., Yeh, J.-L., Wang, C.-C., Liang, Y.-S., & Li, P.-H. (2024). Changes in nutrient content and physicochemical properties of cavendish bananas var. pei chiao during ripening. *Horticulturae*, 10(4), 384.

Karim, M. J., Goni, M. O. F., Nahiduzzaman, M., Ahsan, M., Haider, J., & Kowalski, M. (2024). Enhancing agriculture through real-time grape leaf disease classification via an edge device with a lightweight CNN architecture and Grad-CAM. *Scientific Reports*, 14(1),

1–23. <https://doi.org/10.1038/s41598-024-66989-9>

Kumar, M., & Bhawna. (2024). Introduction to Machine Learning. *Studies in Computational Intelligence*, 1169, 51–94. [https://doi.org/10.1007/978-981-](https://doi.org/10.1007/978-981-97-5624-7_2)

[97-5624-7\\_2](https://doi.org/10.1007/978-981-97-5624-7_2)

Lecture, T. (2021). *Deep Learning for AI*. 7. <https://doi.org/10.1145/3448250>

Martínez-Mora, O., Capuñay-Uceda, O., Caucha-Morales, L., Sánchez-Ancajima, R., Ramírez-Morales, I., Córdova-Márquez, S., & Cuenca-Mayorga, F. (2025). Artificial Vision-Based Dual CNN Classification of Banana Ripeness and Quality Attributes Using RGB Images. *Processes*, *13*(7), 1–11. <https://doi.org/10.3390/pr13071982>

Munoz, B., Hayes, M., Perkins-Veazie, P., Gillitt, N., Munoz, M., Kay, C. D., Lila, M. A., Ferruzzi, M. G., & Iorizzo, M. (2024). Genotype and ripening method affect carotenoid content and bio-accessibility in banana. *Food and Function*, *15*(7), 3433–3445. <https://doi.org/10.1039/d3fo04632j>

Nafi'iyah, N., Wardhani, R., & Prakasa, E. (2023). Identification of Banana Ripeness using Convolutional Neural Network Approaches. *Proceedings - 2023 10th International Conference on Computer, Control, Informatics and its Applications: Exploring the Power of Data: Leveraging Information to Drive Digital Innovation, IC3INA 2023, October*, 330–335. <https://doi.org/10.1109/IC3INA60834.2023.10285749>

Patel, K. K., & Khan, A. K. M. A. (2021). Monochrome computer vision for detecting common external defects of mango. *Journal of Food Science and Technology*, *58*(12), 4550–4557. <https://doi.org/10.1007/s13197-020-04939-9>

Powers, D. M. W. (2020). *Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation*. 37–63. <http://arxiv.org/abs/2010.16061>

Rahman, A., Raihan, A., Uddin, M. S., Hasan, M., & Habib, T. (2025). A Comprehensive Analysis of Classic Machine Learning and Deep Learning

- Modeling for Breed Recognition of Bananas. *IEEE Access*, 13(November), 194562–194579. <https://doi.org/10.1109/ACCESS.2025.3631557>
- Sinanoglou, V. J., Tsiaka, T., Aouant, K., Mouka, E., Ladika, G., Kritsi, E., Konteles, S. J., Ioannou, A. G., Zoumpoulakis, P., Strati, I. F., & Cavouras, D. (2023). Quality Assessment of Banana Ripening Stages by Combining Analytical Methods and Image Analysis. *Applied Sciences (Switzerland)*, 13(6). <https://doi.org/10.3390/app13063533>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2022). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15, 1929–1958.
- Wang, L. M., & Jiang, Y. (2022). Automatic classification of banana ripeness based on deep learning. *Food and Machinery*, 38(11), 149–154. <https://doi.org/10.13652/j.spjx.1003.5788.2022.80218>
- Zhang, J., Yang, X., Fu, X., Wang, B., & Li, H. (2025). *LDL-MobileNetV3S : an enhanced lightweight MobileNetV3-small model for potato leaf disease diagnosis through multi-module fusion*. October, 1–19. <https://doi.org/10.3389/fpls.2025.1656731>

## LAMPIRAN

### 1. Dokumentasi



The image shows a printed iThenticate similarity report. At the top left is the iThenticate logo. At the top right is the Similarity Report ID: oid:29477:127968866. The report is divided into two columns of metadata. The left column includes Paper Name (SISKA OCTIANI.pdf), Word Count (8152 Words), Page Count (57 Pages), Submission Date (Feb 11, 2026 8:00 AM GMT+7), and Report Date (Feb 11, 2026 8:01 AM GMT+7). The right column includes Author (SISKA OCTIANI), Character Count (58608 Characters), and File Size (1.4MB). A circular stamp from Universitas Medan Area is visible, dated 13/02/2026 and signed by Prof. Teknik Informatika. Below the metadata, the report shows a 4% Overall Similarity, broken down into 4% from Internet and Crossref databases, and 1% from Publications and Crossref Posted Content databases. Excluded items include Submitted Works, Cited material, Small Matches, Bibliographic material, and Abstract. A large watermark of the Universitas Medan Area logo is centered on the page. The word 'Summary' is at the bottom right of the report area.

FIELD	VALUE
PAPER NAME	SISKA OCTIANI.pdf
AUTHOR	SISKA OCTIANI
WORD COUNT	8152 Words
CHARACTER COUNT	58608 Characters
PAGE COUNT	57 Pages
FILE SIZE	1.4MB
SUBMISSION DATE	Feb 11, 2026 8:00 AM GMT+7
REPORT DATE	Feb 11, 2026 8:01 AM GMT+7

**4% Overall Similarity**  
The combined total of all matches, including overlapping sources, for each database.

- 4% Internet database
- 1% Publications database
- Crossref database
- Crossref Posted Content database

**Excluded from Similarity Report**

- Submitted Works database
- Bibliographic material
- Cited material
- Abstract
- Small Matches (Less than 15 words)

Summary



# UNIVERSITAS MEDAN AREA

## FAKULTAS TEKNIK

Kampus I : Jalan Kolam Nomor 1 Medan Estate / Jalan Gedung PBSI, Medan 20223  
Kampus II : Jalan Sei Serayu Nomor 70 A / Jalan Setia Budi Nomor 79 B, Medan 20112 Telepon : (061) 8225602, 8201994  
Fax : (061) 8226331 HP : 0811 607 259 website: www.uma.ac.id Email : univ\_medanarea@uma.ac.id

Nomor : 2580/FT/01.10/X/2025  
Lampiran : -  
Hal : **Pembimbing Tugas Akhir**

14 Oktober 2025

Yth. Pembimbing Tugas Akhir  
**Dr Arnes Sembiring ST, M. Kom ( Sebagai Pembimbing )**  
di Tempat

Dengan hormat, sehubungan telah dipenuhinya persyaratan untuk memperoleh Tugas Akhir dari mahasiswa atas :

Nama : SISKI OCTIANI  
NIM : 228160047  
Jurusan : TEKNIK INFORMATIKA

Maka dengan hormat kami mengharapkan kesediaan saudara :

**Dr Arnes Sembiring ST, M. Kom ( Sebagai Pembimbing )**

Adapun Tugas Akhir Skripsi berjudul :

**Klasifikasi Tingkat Kematangan Buah Pisang Berbasis Citra Menggunakan Arsitektur MobileNetV3**


SK Pembimbing ini berlaku selama enam bulan terhitung sejak SK ini diterbitkan. Jika proses pembimbing melebihi batas waktu yang telah ditetapkan, SK ini dapat ditinjau ulang.

Demikian kami sampaikan, atas kesediaan saudara diucapkan terima kasih.

Dekan,



Dr Eng. Supriatno.ST, MT.

 **UNIVERSITAS MEDAN AREA**  
**FAKULTAS TEKNIK**  
Kampus I : Jalan Kalam Nomor 1 Medan Estate ☎ (061) 7360168, Medan, 20223  
Kampus II : Jalan Setiabudi Nomor 79 / Jalan Gel Serayu Nomor 70 A ☎ (061) 42402994, Medan, 20122  
Website: www.teknik.uma.ac.id E-mail: univ\_medanarea@uma.ac.id

Nomor : 345 /FT.6/01.10/XI/2025 27 November 2025  
Lamp : -  
Hal : **Penelitian Dan Pengambilan Data Tugas Akhir**

Yth. Kepala Desa Sibolangit  
Desa Sibolangit, Kec. Merek  
Di  
Karo

Dengan hormat,  
Kami mohon kesediaan Bapak/Ibu berkenan untuk memberikan izin dan kesempatan kepada mahasiswa kami tersebut dibawah ini :


NO	N A M A	N P M	PRODI
1	Siska Octiani	228160047	Teknik Informatika

Untuk melaksanakan Penelitian dan Pengambilan Data Tugas Akhir pada perusahaan/Instansi yang Bapak/Ibu Pimpin.

Perlu kami jelaskan bahwa Pengambilan Data tersebut adalah semata-mata untuk tujuan ilmiah dan Skripsi yang merupakan salah satu syarat bagi mahasiswa tersebut untuk mengikuti ujian sarjana pada Fakultas Teknik Universitas Medan Area dan tidak untuk dipublikasikan, dengan judul penelitian :

**Klasifikasi Tingkat Kematangan Buah Pisang Berbasis Citra Menggunakan Arsitektur *MobileNetV3***

Atas perhatian dan kerja sama yang baik diucapkan terima kasih.

Dekan,  
  
Dr. Eng. Supriatno, ST, MT

**Tembusan :**  
1. Ka. BPMPP  
2. Mahasiswa  
3. File

