

**DETEKSI KEMATANGAN BUAH SAWIT DENGAN
MENGUNAKAN ALGORITMA CONVOLUTIONAL
NEURAL NETWORK**

SKRIPSI

DISUSUN OLEH

MUHAMMAD RIZKY PRATAMA SIREGAR

2009010081



UMSU

Unggul | Cerdas | Terpercaya

**PROGRAM STUDI SISTEM INFORMASI
FAKULTAS ILMU KOMPUTER DAN TEKNOLOGI INFORMASI
UNIVERSITAS MUHAMMADIYAH SUMATERA UTARA**

MEDAN

2024

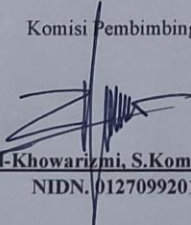
LEMBAR PENGESAHAN

LEMBAR PENGESAHAN

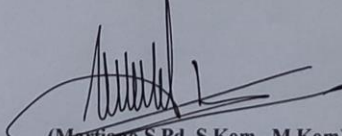
Judul Skripsi : DETEKSI KEMATANGAN BUAH SAWIT DENGAN
MENGUNAKAN ALGORITMA
CONVOLUTIONAL NEURAL NETWORK

Nama Mahasiswa : MUHAMMAD RIZKY PRATAMA SIREGAR
NPM : 2009010081
Program Studi : SISTEM INFORMASI


Menyetujui
Komisi Pembimbing


(Dr. Al-Khowarizmi, S.Kom., M.Kom.)
NIDN. 0127099201

Ketua Program Studi


(Marliano S.Pd, S.Kom., M.Kom)
NIDN. 0128029302

Dekan


(Dr. Al-Khowarizmi, S.Kom., M.Kom.)
NIDN. 0127099201

PERNYATAAN ORISINALITAS

PERNYATAAN ORISINALITAS

DETEKSI KEMATANGAN BUAH SAWIT DENGAN MENGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK

SKRIPSI

Saya menyatakan bahwa karya tulis ini adalah hasil karya sendiri, kecuali beberapa kutipan dan ringkasan yang masing-masing disebutkan sumbernya.

Medan, Juli 2024

Yang membuat pernyataan



Muhammad Rizky Pratama Siregar

2009010081

PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika Universitas Muhammadiyah Sumatera Utara, saya bertanda tangan dibawah ini:

Nama : Muhammad Rizky Pratama Siregar
NPM : 2009010081
Program Studi : Sistem Informasi

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Muhammadiyah Sumatera Utara Hak Bebas Royalti Non-Eksekutif (*Non-Exclusive Royalty free Right*) atas penelitian skripsi saya yang berjudul:

**DETEKSI KEMATANGAN BUAH SAWIT DENGAN
MENGUNAKAN ALGORITMA CONVOLUTIONAL
NEURAL NETWORK**

Beserta perangkat yang ada (jika diperlukan). Dengan Hak Bebas Royalti Non- Eksekutif ini, Universitas Muhammadiyah Sumatera Utara berhak menyimpan, mengalih media, memformat, mengelola dalam bentuk database, merawat dan mempublikasikan Skripsi saya ini tanpa meminta izin dari saya selama tetap mencantumkan nama saya sebagai penulis dan sebagai pemegang dan atau sebagai pemilik hak cipta.

Demikian pernyataan ini dibuat dengan sebenarnya.

Medan, Oktober 2024

Yang membuat pernyataan



Muhammad Rizky Pratama Siregar
2009010081

RIWAYAT HIDUP

DATA PRIBADI

Nama Lengkap : Muhammad Rizky Pratama Siregar
Tempat dan Tanggal Lahir : Medan, 16 April 2002
Alamat Rumah : Jl. Usman Sidik Pasar IV Gg. Anggrek III
Telepon/Faks/HP : 085762369343
E-mail : mrizkypratamasiregar24@gmail.com
Instansi Tempat Kerja : PT. Algonacci Sobat Nusantara
Alamat Kantor : Jl. Letjen S. Parman No.28 Grogol Petamburan, Kota Jakarta Barat, Daerah Khusus Ibukota Jakarta 11470

DATA PENDIDIKAN

SD	: SDIT AL-HIJRAH 2	TAMAT: 2014
SMP	: SMPN 27 MEDAN	TAMAT: 2017
SMA	: SMKN 1 PERCUT SEI TUAN	TAMAT: 2020

KATA PENGANTAR

Alhamdulillah puji dan syukur peneliti panjatkan kehadirat Allah Subhanahu wa Ta'ala atas segala limpahan rahmat dan hidayah-Nya kepada peneliti sehingga dapat menyelesaikan perkuliahan dan penelitian skripsi ini, guna memenuhi salah satu syarat dalam memperoleh gelar Sarjana Komputer pada Fakultas Ilmu Komputer dan Teknologi Informasi Universitas Muhammadiyah Sumatera Utara.

Pada kesempatan ini peneliti mengucapkan terima kasih kepada :

1. Bapak Prof. Dr. Agussani, MAP, selaku Rektor Universitas Muhammadiyah Sumatera Utara.
2. Bapak Dr. Al-Khowarizmi, S.Kom., M.Kom, selaku Dekan Fakultas Ilmu Komputer dan Teknologi Informasi. Sekaligus dosen pembimbing penulis. Bimbingan dan masukan berharga yang diberikan oleh Bapak Al-Khowarizmi telah memberikan kontribusi besar dalam menuntun penulis menyelesaikan skripsi ini tepat waktu. Keberhasilan penulisan ini tidak terlepas dari arahan, saran, dan bimbingan yang mendalam dari Bapak. Terima kasih atas dedikasi dan waktu yang diberikan untuk membimbing penulis. Semoga segala ilmu dan kebaikan yang telah diberikan menjadi amal jariyah yang diridhai Allah SWT.
3. Bapak Halim Maulana, ST., M.Kom selaku Wakil Dekan 1 Fakultas Ilmu Komputer dan Teknologi Informasi.
4. Bapak Dr. Lutfi Basit, S.Sos., M.I.Kom selaku Wakil Dekan III Fakultas Ilmu Komputer dan Teknologi Informasi.
5. Bapak Martiano, S.Pd, S.Kom, M.Kom selaku Ketua Program Studi Sistem

Informasi Fakultas Ilmu Komputer dan Teknologi Informasi.

6. Ibu Fatma Sari Hutagalung, S.Kom., M.Kom, dan Bapak Mhd. Basri, S.Si., M.Kom, selaku Ketua Program Studi Teknologi Informasi dan Sekretaris Program Studi Teknologi Informasi.
7. Ayah kandung penulis yaitu Ali Syahbana Siregar dan Juga Ibu Kandung saya yaitu Mariana Br Damanik orang tua yang selalu memberikan dukungan penuh dalam masa perkuliahan hingga sampai ditahap penulisan skripsi ini yang dimana perkuliahan ini dapat berjalan dengan baik, niat baik dan perjuangan yang cukup panjang akan membuahkan hasil yang baik nantinya.
8. Adik Kandung Penulis yaitu Nur Fitri Ramadhani Siregar dan Arif Tri Andhika Siregar yang dimana menjadi motivasi utama penulis hingga saat ini untuk bisa menjadi panutan yang baik bagi beliau dan adik kecil lainnya
9. Sahabat kecil saya yaitu Muhammad Mirza Pradana dan Nanda Repancya yang selalu memotivasi saya untuk menyelesaikan pendidikan sebaik baik mungkin dan selalu mendukung apa yang telah saya jalani selama ini .
10. Sahabat Perjuangan saya yaitu Aditya Bayu, Anggito Karta Wijaya, Hafiz Chaniago, Iqbal Pamula Ba'iq dan rekan discord lainnya yang selalu menjadi tempat terbaik untuk berdiskusi panjang terkait pikiran dan memberikan semangat secara mental dan perjuangan dalam kehidupan dan penyelesain skripsi ini
11. Teman Perjuangan yang ikut dalam pembangunan Himpunan Mahasiswa Teknologi Informasi dan juga teman teman satu angkatan Prodi Teknologi Informasi yang selalu memberikan keyakinan dan arahan terkait kebaikan bersama.

12. Teman dan Keluarga Besar Core Team GDSC UMSU 2022 – 2023, 2023 – 2024 yang cukup membantu penulis dalam pembangunan mentalitas penulis dan juga ikut membantu membangun dasar fondasi komunitas teknologi pada Universitas, terkhususnya Siti Raisha Rushainy sebagai Partner Community/MBKM dan kompetisi lainnya dan Elza Ahmad Raihan yang paling dekat dan berdiskusi selama perjalanan perkuliahan. Terimakasih atas kekompakan dan kebahagiaan yang telah kita jalani selalu.
13. Partner yaitu Latifa Nur Hani yang selalu membantu disela-sela kesibukan beliau demi selesainya perkuliahan ini, mendukung sekaligus tempat curhatan hati kecilku ketika aku sedang mengalami masalah.
14. Semua pihak yang terlibat baik secara langsung dan tidak langsung baik dari perkuliahan ataupun kegiatan non kuliah yang telah membangun diri penulis yang dimana penulis tidak bisa menyebutkan satu persatu nama tersebut. Terimakasih telah hadir

Semoga Allah Subhanahu wa Ta'Ala dapat memberikan balasan atas kebaikan-kebaikan yang telah diberikan kepada peneliti baik di dunia maupun di akhirat kelak. Saya menyadari bahwa skripsi ini masih jauh dari kesempurnaan, oleh karena itu saya mengharapkan saran dan kritikan yang membangun dari pembaca untuk perbaikan-perbaikan dimasa yang akan datang.

Medan, 30 Juli 2024

Peneliti



Muhammad Rizky Pratama Siregar

ABSTRAK

Penelitian ini bertujuan untuk mengembangkan sistem deteksi otomatis kematangan buah sawit menggunakan algoritma Convolutional Neural Network (CNN). Dataset yang digunakan terdiri dari ribuan gambar buah sawit matang dan tidak matang dengan variasi kondisi pencahayaan dan sudut pengambilan gambar. Model CNN yang digunakan adalah MobileNetV2 yang telah diadaptasi untuk tugas klasifikasi biner. Proses pelatihan dilakukan menggunakan teknik augmentasi data untuk meningkatkan generalisasi model. Hasil evaluasi menunjukkan bahwa model CNN yang dikembangkan mampu mengklasifikasikan kematangan buah sawit dengan akurasi sebesar 84%. Perbandingan dengan metode konvensional yang mengandalkan penilaian visual menunjukkan bahwa model CNN memberikan hasil yang lebih konsisten dan objektif. Implementasi model ini berpotensi meningkatkan efisiensi proses panen dan pengolahan buah sawit serta mengurangi biaya produksi.

Kata Kunci : Jaringan Syaraf Tiruan Konvolusional, Sawit , Model Arsitektur

ABSTRACT

This research aims to develop an automatic palm fruit ripeness detection system using the Convolutional Neural Network (CNN) algorithm. The dataset used consists of thousands of images of ripe and unripe palm fruits with varying lighting conditions and shooting angles. The CNN model used is MobileNetV2 which has been adapted for binary classification tasks. The training process is performed using data augmentation techniques to improve the generalization of the model. The evaluation results show that the developed CNN model is able to classify the ripeness of palm fruits with an accuracy of 84%. Comparison with conventional methods that rely on visual assessment shows that the CNN model provides more consistent and objective results. The implementation of this model has the potential to increase the efficiency of the harvesting and processing of palm fruits and reduce production costs.

Keywords: *Convolutional Artificial Neural Network, Palm, Architecture Model*

DAFTAR ISI

LEMBAR PENGESAHAN	ii
PERNYATAAN ORISINALITAS	iii
PERNYATAAN PERSETUJUAN PUBLIKASI	iv
RIWAYAT HIDUP	v
KATA PENGANTAR	vi
ABSTRAK	ix
<i>ABSTRACT</i>	x
DAFTAR ISI	xi
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xiv
BAB I	1
PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Rumusan Masalah	2
1.3 Batasan Masalah	3
1.4 Tujuan Penelitian	4
1.5 Manfaat Penelitian	4
BAB II	5
LANDASAN TEORI	5
2.1 Deep Learning	5
2.2 Supervised Learning	5
2.3 Convolutional Neural Network	6
2.4 MobileNetV2	8
2.5 TensorFlow	9
2.6 Kematangan buah sawit	9
BAB III	11
METODOLOGI PENELITIAN	11
3.1 Alur Penelitian	11
3.2.1 Observasi Perusahaan	11
3.2.2 Pengumpulan Dataset	13
3.2.3 Pelatihan Model	14
3.2.4 Pengujian Model	15
3.2.5 Pengujian peforma model	15
3.2 Kebutuhan Hardware & Software	16
3.3.1 Kebutuhan Hardware	16
3.3.2 Kebutuhan Software	16

BAB IV	18
HASIL DAN PEMBAHASAN.....	18
4.1 Data Training dan Validation.....	18
4.2 Pembangunan Model CNN	19
4.3 Testing Model MobileNetV2	20
4.4 Evaluasi Kinerja Model CNN	23
4.5 Pengujian Model	27
4.5.1 Matang Tandan buah segar (<i>Ripe</i>).....	27
4.5.2 Matang Buah brondolan (<i>Ripe</i>).....	28
4.5.3 Tidak matang Tandan buah segar (<i>Unripe</i>).....	29
4.5.4 Tidak Matang Buah brondolan (<i>Unripe</i>).....	30
BAB V	32
KESIMPULAN DAN SARAN.....	32
5.1 Kesimpulan	32
5.2 Saran	32
DAFTAR PUSTAKA	34
LAMPIRAN.....	36

DAFTAR TABEL

Tabel 2.1 Kriteria kematangan buah sawit berdasarkan fraksi panen.....	10
Tabel 3.1 Kebutuhan Hardware.....	16
Tabel 3.2 Kebutuhan Software.....	17
Tabel 4.1 Jumlah Data Training Setiap Kelas.....	18
Tabel 4.2 Jumlah Data Validasi Setiap Kelas.....	18

DAFTAR GAMBAR

Gambar 2.1 Supervised Learning	6
Gambar 2.2 Lapisan Konvolusi	7
Gambar 2.3 TF-MobileNet V2	9
Gambar 3.1 Alur Penelitian	11
Gambar 3.2 Observasi pertama	12
Gambar 3.3 Observasi kedua.....	12
Gambar 3.4 Sawit Matang	13
Gambar 3.5 Sawit Tidak Matang.....	13
Gambar 3.6 Pelatihan Model	14
Gambar 4.1 Model CNN dan MobileNetV2	19
Gambar 4.2 Akurasi Dataset Sebelum Augmentasi	20
Gambar 4.3 Akurasi Dataset Setelah Augmentasi.....	20
Gambar 4.4 Akurasi dan Loss Dataset Sebelum Augmentasi	21
Gambar 4.5 Akurasi dan Loss Dataset Setelah Augmentasi	21
Gambar 4.6 Perhitungan Hasil Akurasi Dataset Setelah Augmentasi.....	23
Gambar 4.7 Perhitungan Hasil Akurasi Dataset Sebelum Augmentasi.....	23
Gambar 4.8 Confussion Matrix Dataset Sebelum Augmentasi.....	24
Gambar 4.9 Confussion Matrix Setelah Augmentasi	26
Gambar 4.10 Hasil Prediksi Sawit Matang tandan buah segar.....	28
Gambar 4.11 Hasil Prediksi Sawit Matang brondolan	29
Gambar 4.12 Hasil Prediksi Tandan buah segar tidak matang.....	30
Gambar 4.13 Hasil Prediksi Sawit Matang brondolan	31

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Pemilihan kualitas kelapa sawit masih menggunakan cara tradisional pengambilan perbuah/*(example)* sehingga ada beberapa sawit yang tidak matang lolos kualifikasi untuk diolah. Buah sawit yang tidak matang akan memeberikan hasil yang tidak maksimal saat pengolahan di pabrik sawit,

Cara tradisonal tersebut sangat tidak objektif dikarenakan pemilihan hanya menggunakan kasat mata yang data nya tidak bisa dipertanggung jawabkan. Untuk itu dibutuhkan teknologi yang membantu permasalahan yang nantinya data-data tersebut dapat diolah untuk kebutuhan pengelola sawit.

Oleh karena itu, pengembangan metode deteksi otomatis yang lebih cepat dan akurat menjadi sangat penting dalam industri kelapa sawit. Sistem deteksi kematangan buah sawit berbasis *Convolutional Neural Network* (CNN) diharapkan dapat meningkatkan efisiensi dan akurasi dalam mendeteksi kematangan buah sawit, sehingga membantu meningkatkan kualitas dan jumlah produksi minyak kelapa sawit (Purna Irawan et al., n.d.).

Salah satu inovasi yang dapat mendukung peningkatan kualitas adalah penggunaan teknologi Machine Learning, khususnya CNN, dalam menganalisis kualitas kelapa sawit. Menurut Mahesh (2018), produk dari pembelajaran mesin adalah pengklasifikasi yang dapat digunakan pada perangkat keras yang tersedia dan pembuatan pengklasifikasi harus sangat

termekanisasi untuk meminimalkan bias manusia (Bowo et al., 2020). *Algoritme* ini harus didasarkan pada data yang konkret dan dapat diamati.

Farsi et al. (2021) menyatakan bahwa metode pembelajaran mendalam CNN sangat efektif untuk merepresentasikan pola spasial, memungkinkan ekstraksi berbagai properti vegetasi dari citra penginderaan jauh. Ulasan ini menjelaskan prinsip-prinsip CNN dan mengapa metode ini cocok untuk penginderaan jauh vegetasi, serta mencakup tren dan perkembangan saat ini, termasuk resolusi spektral, butir spasial, jenis sensor, dan pendekatan arsitektur CNN. Penerapan ini memerlukan dataset sawit untuk membentuk model prediksi tingkat kematangan sawit dan nilai kematangan yang mempertimbangkan kesiapan panen.

Dengan demikian, penelitian ini tidak hanya memberikan kontribusi teoritis pada pengembangan teknologi, tetapi juga menawarkan solusi praktis yang dapat langsung diterapkan dalam industri kelapa sawit di Indonesia.

1.2 Rumusan Masalah

Proses penyortiran buah sawit berbasis teknologi modern sangat penting untuk meningkatkan efisiensi dan kualitas produksi minyak sawit. Teknologi yang digunakan dapat mempermudah penyortiran dengan memberikan akurasi yang sangat signifikan mampu mendeteksi dan membedakan buah sawit berdasarkan tingkat kematangan dan kualitas, hanya buah berkualitas tinggi yang masuk ke proses produksi, sehingga menghasilkan minyak sawit berkualitas lebih baik. Selain itu, penyortiran yang tepat mengurangi limbah dan biaya produksi, serta mendukung keberlanjutan dengan mengurangi dampak lingkungan.

1.3 Batasan Masalah

Adapun batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Platform Pengembangan: Aplikasi deteksi tingkat kematangan buah sawit dibangun menggunakan teknologi *machine learning*.
2. Objek yang Dipindai: Penelitian ini difokuskan pada deteksi tingkat kematangan buah sawit dalam bentuk satuan atau brondolan. Buah sawit yang dipindai merupakan satuan buah, bukan tandan secara keseluruhan.
3. Metode Deteksi: Metode yang digunakan untuk mendeteksi tingkat kematangan buah sawit adalah Convolutional Neural Network (CNN). Pendekatan ini dipilih karena keakuratannya dalam pengenalan gambar dan analisis visual.
4. Lingkup Data: Dataset yang digunakan untuk melatih model CNN terdiri dari gambar-gambar buah sawit dengan berbagai tingkat kematangan. Gambar diambil dalam kondisi pencahayaan yang konsisten dan dari sudut pandang yang seragam untuk meminimalkan variasi yang tidak diinginkan.
5. Parameter Kematangan: Tingkat kematangan buah sawit dikelompokkan berdasarkan parameter visual seperti warna, tekstur, dan bentuk. Kategori kematangan yang digunakan adalah mentah dan matang.
6. Keterbatasan Lingkungan: Pengujian dilakukan dalam kondisi lingkungan yang terkendali. Penggunaan di lapangan dengan kondisi

pencerahan dan latar belakang yang bervariasi tidak menjadi fokus utama dalam penelitian ini.

7. Implementasi dan Evaluasi: Sistem akan dievaluasi berdasarkan akurasi deteksi tingkat kematangan. Evaluasi dilakukan melalui pengujian dengan sampel buah sawit yang tidak termasuk dalam dataset pelatihan.

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah :

1. Mengetahui model deteksi algoritma CNN untuk mengklasifikasikan kematangan buah sawit.
2. Berapa persentase akurasi yang didapat dari model deteksi CNN untuk mengklasifikasikan kematangan buah sawit.

1.5 Manfaat Penelitian

Berdasarkan implementasi CNN untuk klasifikasi tingkat kematangan buah sawit manfaatnya adalah:

1. Penelitian ini diharapkan dapat memberikan kontribusi signifikan pada pengembangan teknologi dalam industri perkebunan kelapa sawit.
2. Implementasi CNN untuk klasifikasi kematangan buah sawit bagi industri perkebunan kelapa sawit dapat memudahkan petani, serta memajukan pengetahuan dan teknologi dalam bidang pertanian.
3. Manfaat lainnya adalah peningkatan produktivitas perkebunan kelapa sawit, yang dapat berdampak positif pada pendapatan petani dan keberlanjutan industri perkebunan.
4. Implementasi CNN dalam klasifikasi kematangan buah sawit dapat meningkatkan akurasi dalam penentuan tingkat kematangan.

BAB II


LANDASAN TEORI

2.1 Deep Learning

Salah satu cabang *Machine Learning*, *Deep Learning* (DL) atau Pembelajaran mesin mendalam, terdiri dari algoritma pemodelan abstraksi data Tingkat tinggi yang digunakan oleh sekumpulan fungsi transformasi non-linear yang ditata secara mendalam dan berlapis-lapis. *Deep Learning* sangat cocok untuk pembelajaran yang diawasi, tidak diawasi, dan sebagian diawasi, serta pembelajaran pendukung untuk berbagai aplikasi seperti pengenalan citra, suara, klasifikasi teks, dan sebagainya (Imam Cholissodin et al., 2020)

2.2 Supervised Learning

Pembelajaran Terawasi adalah tugas pembelajaran mesin untuk mempelajari fungsi yang memetakan input ke output berdasarkan contoh pasangan input-output. Algoritma ini menyimpulkan sebuah fungsi dari data pelatihan berlabel yang terdiri dari sekumpulan contoh pelatihan. Algoritma pembelajaran mesin yang diawasi adalah algoritma yang membutuhkan bantuan eksternal. Dataset input dibagi menjadi dataset latih dan dataset uji. Dataset latih memiliki variabel keluaran yang perlu diprediksi atau diklasifikasikan. Semua algoritma (Batta, 2020).



Gambar 2.1 Supervised Learning
 Sumber: Mahesha Batta., 2018

Mempelajari beberapa jenis pola dari dataset pelatihan dan menerapkannya pada dataset pengujian untuk prediksi atau klasifikasi. Alur kerja algoritma pembelajaran mesin yang diawasi diberikan pada gambar di bawah ini. Algoritma pembelajaran mesin yang paling terkenal telah dibahas di sini.

2.3 Convolutional Neural Network


CNN adalah keluarga jaringan saraf yang penting. dirancang untuk menyaring dan mengekstrak fitur data masukan. Mereka telah digunakan secara luas di berbagai bidang berkat kemampuan mereka untuk menangani data dengan dimensi yang berbeda. Contoh lebih nya dua *layers* dan tiga *layers* diakui sebagai jaringan yang kuat untuk melakukan pemrosesan gambar, dan klasifikasi(Farsi et al., 2021)

Keragaman yang ada di antara profil beban menggunakan jaringan CNN dapat menimbulkan beberapa kesulitan secara Kompleksitas perilaku manusia, hari kerja, waktu, dan data cuaca mempengaruhi profil beban untuk mengatasi mengatasi kompleksitas dari beban program, CNN harus memiliki data masukan yang besar sebagai set pelatihan untuk mempelajari semua

parameter(Teknik Elektro & Wega Intyanto, n.d.) Dari sudut pandang teknis, CNN didasarkan pada konvolusi, seperti yang ditunjukkan pada rumus dibawah:

$$presisi = \left(\frac{total\ benar}{total\ terprediksi} \right) \dots \dots \dots (1)$$

di mana j berkisar antara 0 hingga $k-1$ dan kemudian membuat Y memiliki $n - k + 1$ dimensi, dan n adalah dimensi input. Meskipun operasi konvolusi adalah rumus matematika yang sederhana matematika yang sederhana, cara kerja CNN sedikit berbeda.



Gambar 2.2 Lapisan Konvolusi
 Sumber: Farsi et al.,2021

struktur bagian dalam dari keluarga jaringan syaraf ini, dan seperti yang dapat dilihat pada gambar ini, filter konvolusi meluncur di atas seluruh data masukan untuk mengekstrak fitur. Dalam operasi konvolusi, pertama-tama volusi, pertama-tama kernel dan filter konvolusi, dan hasil dari operasi ini ditambahkan ke sebuah bias term. Operasi matematika ini operasi matematika

ini selesai ketika fitur yang lengkap fitur yang lengkap telah tercapai. Persamaan (2) dan (3) menunjukkan operasi konvolusi dalam jaringan artififikasi


$$recall = \left(\frac{total\ benar}{total\ data}\right).....(2)$$

$$f - measure = \left(\frac{2 \times presisi \times recall}{presisi + recall}\right).....(3)$$

CNN memanfaatkan teknik perhatian visual untuk kelapa sawit dan klasifikasi kematangan buah. Penelitian ini berfokus pada pengembangan model dengan arsitektur CNN yang telah dilatih sebelumnya, khususnya sigmoid DenseNet untuk mengkategorikan tingkat kematangan buah kelapa sawit (Suharjito et al., 2023)

2.4 MobileNetV2

MobileNetV2 adalah Arsitektur yang dikembangkan untuk lingkungan mobile dan sumber daya terbatas. Tujuan utama untuk mengadopsi jenis arsitektur ini terletak pada kekuatannya dalam hal mengurangi penggunaan memori, biaya komputasi, dan kesesuaian desainnya untuk lebih fokus pada aplikasi seluler. Penting untuk dicatat bahwa arsitektur tersebut pada awalnya memiliki sekitar seribu node di lapisan klasifikasinya. Namun demikian, untuk membuatnya sesuai dengan masalah tersebut, penting untuk memperbaiki jumlah node di lapisan klasifikasi. Untuk meningkatkan akurasi, sebuah kepala yang disesuaikan, yang berisi lima lapisan berbeda dipasang pada model dasar MobileNet V2 dengan mengganti lapisan klasifikasi (Gulzar, 2023)



Gambar 2.3 TF-MobileNet V2

Sumber: Yonis Gulzar

2.5 TensorFlow

TensorFlow merupakan suatu framework dan perpustakaan untuk kecerdasan buatan dan analisis data yang bersifat open source, dikembangkan oleh tim peneliti dari Google. TensorFlow dapat diaplikasikan dalam berbagai bidang. Dalam konteks deteksi objek, terdapat TensorFlow Object Detection API, sebuah alat yang mempermudah proses konstruksi, pelatihan, dan penerapan model deteksi objek. TensorFlow Object Detection API menyajikan model deteksi objek yang telah di-pretrain kepada pengguna, sambil memberikan opsi untuk menggunakan model deteksi objek lainnya, seperti Faster R-CNN, SSD, Retinanet, Resnet50, dan lainnya (Sitorus H, 2022)

2.6 Kematangan buah sawit

Tingkat kematangan buah kelapa sawit ditentukan dari warna dan jumlah buah yang membrondol dari tandan buah sawit. Buah muda (mentah) berwarna ungu kehitaman atau hijau karena dipengaruhi pigmen klofil, buah setengah matang berwarna ungu kejinggaan dan buah matang berwarna merah akibat pengaruh pigmen beta karoten. Buah yang membrondol adalah buah yang jatuh

dari tandan buah kelapa sawit. Bila buah yang membrondol berjumlah 5 atau lebih dalam satu tandan dianggap buah kelapa sawit sudah siap untuk dipanen. Jika tanaman buah kelapa sawit berumur kurang lebih 10 tahun buah dianggap matang bila jumlah brondolan ± 10 butir, jika umur tanaman lebih dari 10 tahun, jumlah brondolan 15-20 butir Kriteria tingkat kematangan buah sawit dapat dilihat pada tabel 2.1.

Tabel 2.1 Kriteria kematangan buah sawit berdasarkan fraksi panen
Sumber: Krisdiarto, 2017

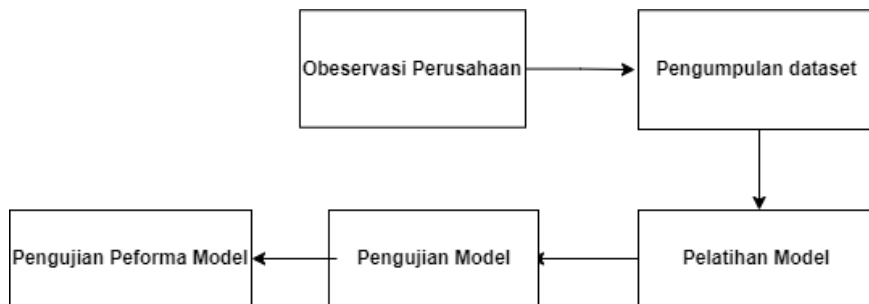
Kriteria Matang Panen			
Fraksi Panen	Jumlah Buah Luar Membrondol(%)	Warna Buah	Derajat Kematangan
OO	0	Hiatm Pekat	Sangat mentah
0	1-12,5	Kemerahan Cerah	Mentah
1	12,5-25	Kemerahan Merah	Kurang Mentah
2	25-50	Merah mengkilat	Matang
3	50-75	Orange	Matang
4	75-100	Dominan Orange	Lewat matang
5	100(Bagian buah dalam ikut brondol)	Merah	Lewat matang

BAB III

METODOLOGI PENELITIAN

3.1 Alur Penelitian

Dalam pelaksanaan Penelitian ini, ada serangkaian langkah yang akan diambil untuk mencapai kesimpulan dari penelitian ini. Rinciannya mengenai langkah-langkah penelitian dapat ditemukan dalam diagram berikut:



Gambar 3.1 Alur Penelitian

Dalam penelitian ini perlu mengikuti tahapan agar tujuan dari penelitian ini dapat tercapai, tahapan dari penelitian ini antara lain.

3.2.1 Observasi Perusahaan

Penulis melakukan pengamatan di PT. Anugera Makmur Jaya dan menemukan masalah terkait proses penyortiran kematangan buah sawit. Masalah yang dihadapi adalah kesalahan yang sering terjadi saat pemisahan antara buah sawit yang sudah matang dan yang belum matang, sehingga kedua jenis buah sawit tersebut sering tercampur.

Dalam konteks PT. Anugera Makmur Jaya, terdapat masalah serius terkait proses penyortiran kematangan buah sawit. Kesalahan sering terjadi saat petani memisahkan buah sawit yang sudah matang dan yang belum matang, sehingga buah-buah tersebut sering tercampur. Hal ini mengakibatkan penurunan

kualitas hasil produksi, karena buah sawit yang belum matang cenderung menghasilkan minyak yang kurang berkualitas.



Gambar 3.2 Observasi pertama

Masalah ini menimbulkan dampak yang cukup signifikan, baik dari segi ekonomi maupun operasional. Secara ekonomi, penurunan kualitas minyak kelapa sawit dapat berdampak pada harga jual produk, sementara dari segi operasional, kesalahan dalam penyortiran buah sawit dapat memperlambat proses produksi dan meningkatkan biaya produksi secara keseluruhan.



Gambar 3.3 Observasi kedua

Oleh karena itu, diperlukan solusi yang efektif untuk meningkatkan efisiensi dan akurasi proses penyortiran kematangan buah sawit di PT. Anugera Makmur Jaya. Solusi tersebut harus dapat mengurangi kesalahan pemisahan antara buah sawit yang sudah matang dan yang belum matang, sehingga dapat meningkatkan kualitas dan produktivitas produksi minyak kelapa sawit

3.2.2 Pengumpulan Dataset

Tahap pemerolehan data ini merupakan bagian integral dari penelitian ini. Dataset yang digunakan untuk melatih dan mengevaluasi model terdiri dari sawit matang dan tidak matang yang diperoleh dari pengumpulan saat observasi di lapangan. Data yang digunakan dalam penelitian ini terklasifikasi ke dalam 2 kategori, melibatkan kelas sawit matang, sawit tidak matang.

Penelitian ini bertujuan untuk mengetahui performa model Deep Learning MobileNetV2 dalam deteksi dan klasifikasi jenis sawit, maka dalam penerapannya, MobileNetV2 seperti halnya model Deep Learning lainnya memerlukan adanya dataset yang berupa citra citra beserta labelnya untuk digunakan dalam proses pelatihan/training atau pada kasus MobileNetV2 merupakan proses transfer learning. 500 Dataset yang diperlukan untuk pelatihan model MobileNetV2 dalam penelitian ini merupakan kumpulan citra atau gambar sawit matang atau sawit tidak matang dengan label yang sesuai untuk masing-masing citra dengan format label MobileNetV2.



Gambar 3.4 Sawit Matang



Gambar 3.5 Sawit Tidak Matang

3.2.3 Pelatihan Model

Setelah proses pra-pemrosesan dataset selesai dilakukan, maka proses pelatihan model MobileNetV2 dapat dilakukan. Dikarenakan model MobileNetV2 merupakan model pra terlatih / pretrained, proses pelatihan ini merupakan proses transfer learning yang hanya melatih lapisan akhir untuk menyesuaikan model untuk mendeteksi kelas-kelas dalam dataset yang diberikan 20. Sebelum proses pelatihan ini dilakukan, perlu dilakukan sedikit konfigurasi terhadap model MobileNetV2 yang akan digunakan, seperti direktori dataset, ukuran citra input dan kedalaman citra lalu mengatur konfigurasi pelatihan seperti jumlah epoch, batch size, dan callback untuk angka akurasi target. Setelah konfigurasi selesai dilakukan dan sesuai dengan model, maka proses pelatihan dapat berlangsung. Model akan melakukan proses pelatihan terhadap dataset sebanyak jumlah epoch yang diberikan atau hingga angka akurasi yang diberikan pada callback. Setelah proses pelatihan selesai dilakukan, maka model secara otomatis di ekspor dalam bentuk h.5 dan dapat digunakan untuk prediksi gambar.

```
Epoch 7/50
4/4 [=====] - 1s 415ms/step - loss: 0.1299 - accuracy: 0.9350 - val_loss: 0.8069 - val_accuracy: 0.6
358
Epoch 8/50
4/4 [=====] - 1s 420ms/step - loss: 0.0961 - accuracy: 0.9512 - val_loss: 0.9269 - val_accuracy: 0.6
755
Epoch 9/50
4/4 [=====] - 2s 681ms/step - loss: 0.0709 - accuracy: 0.9837 - val_loss: 0.9182 - val_accuracy: 0.6
424
Epoch 10/50
4/4 [=====] - 2s 539ms/step - loss: 0.0507 - accuracy: 0.9919 - val_loss: 1.0043 - val_accuracy: 0.6
556
Epoch 11/50
4/4 [=====] - 1s 423ms/step - loss: 0.0520 - accuracy: 0.9756 - val_loss: 0.9941 - val_accuracy: 0.6
291
Epoch 12/50
4/4 [=====] - 1s 440ms/step - loss: 0.0555 - accuracy: 0.9919 - val_loss: 1.0054 - val_accuracy: 0.6
225
Epoch 13/50
4/4 [=====] - 2s 458ms/step - loss: 0.0399 - accuracy: 0.9919 - val_loss: 1.0750 - val_accuracy: 0.6
291
```

Gambar 3.6 Pelatihan Model

3.2.4 Pengujian Model

Setelah model berhasil dilatih dan menghasilkan akurasi pelatihan yang memuaskan, maka selanjutnya dapat dilakukan evaluasi performa model terhadap gambar sawit matang dan tidak matang.

Dalam proses evaluasi dilakukan prediksi terhadap kelompok gambar yang memiliki label untuk mengetahui hasil aslinya dan kelompok gambar ini harus tidak pernah digunakan dalam proses pelatihan untuk memastikan integritas hasil evaluasi. Proses evaluasi dilakukan dengan melakukan prediksi pada direktori yang mengandung kelompok dataset evaluasi, dan menghasilkan angka angka evaluasi yang akan dilakukan analisa pada proses selanjutnya.

3.2.5 Pengujian peforma model

Langkah selanjutnya adalah mengintegrasikan model ke dalam aplikasi yang akan digunakan untuk klasifikasi kematangan buah sawit secara praktis. ini melibatkan pengembangan antarmuka pengguna yang ramah pengguna, yang memungkinkan pengguna untuk mengambil gambar foto kematangan buah sawit dan mendapatkan klasifikasi tingkat kematangan dari model MobileNetV2 dan tahapan terakhir adalah pengujian performa model yang diimplementasikan pada aplikasi yang dikembangkan. Ini melibatkan uji coba aplikasi dengan pengguna yang sesungguhnya atau dengan data yang relevan untuk mengevaluasi seberapa baik model MobileNetV2 berkinerja dalam mengklasifikasikan kematangan buah sawit yoga dalam penyortiran.

3.2 Kebutuhan Hardware & Software

3.3.1 Kebutuhan Hardware

Dalam pengimplementasian penelitian ini , diperlukan beberapa perangkat keras yang menggunakan arsitektur x64 dengan spesifikasi minimal tertentu. Spesifikasi ini menjadi kebutuhan kritis untuk menjalankan model dan memberikan landasan evaluasi kinerja kecepatan model dalam konteks penelitian ini.

Tabel 3.1 Kebutuhan Hardware

No	Hardware	Spesifikasi
1	<i>Processor</i>	Intel Core i7-7700HQ
2	<i>RAM</i>	16 GB
3	<i>GPU</i>	Geforce GTX 1050 Ram 16Gb
4	Penyimpanan	1 <i>Terabyte</i>
5	Sistem Operasi	<i>Windows 10 / Windows 11</i>

Dalam konteks pelaksanaan penelitian, dapat dipilih untuk menggunakan sistem yang memiliki spesifikasi seperti yang telah dijelaskan sebelumnya atau memanfaatkan komputasi awan melalui platform seperti Google Collab atau layanan cloud lainnya untuk menjalankan model

3.3.2 Kebutuhan Software

Pada perancangan sistem ini dibutuhkan beberapa perangkat lunak (*Software*) sebagai pendukung untuk melakukan penelitian ini. Ada dua *software* yang akan digunakan diantaranya yaitu *Android Studio*, dan Google Colaboratory. Pada perancangan ini peneliti menggunakan *Android Studio* sebagai *software IDE* untuk merancang *Mobile App* yang akan dikembangkan, Dan peneliti menggunakan Google Colaboratory sebagai tempat untuk merancang logika dari *Machine*

Learning yang akan digunakan peneliti untuk membuat Sistem Klasifikasi Deteksi kematangan buah sawit.

Tabel 3.2 Kebutuhan Software

No	Kebutuhan	Versi
1.	<i>Python</i>	3.8.6
2.	<i>Ultralytics</i>	8.0.141
3.	<i>PyTorch</i>	2.0.1
4.	<i>TorchVision</i>	0.15.2
5.	<i>Pillow</i>	10.0.0

BAB IV

HASIL DAN PEMBAHASAN

4.1 Data Training dan Validation

Pada penelitian ini dataset yang telah diperoleh dikumpulkan secara langsung dari PT. Anugrah Makmur Jaya, Roboflow dan platform kaggle. Dataset ini terdiri dari 1557 data training dan 707 data validasi, yang terdiri dari 2 kategori yaitu sawit matang(ripe) dan sawit tidak matang(unripe). Berikut rincian data dari masing-masing kematangan buah sawit:

Tabel 4.1 Jumlah Data Training Setiap Kelas

Kelas	Jumlah Data
Matang	769
Tidak Matang	788

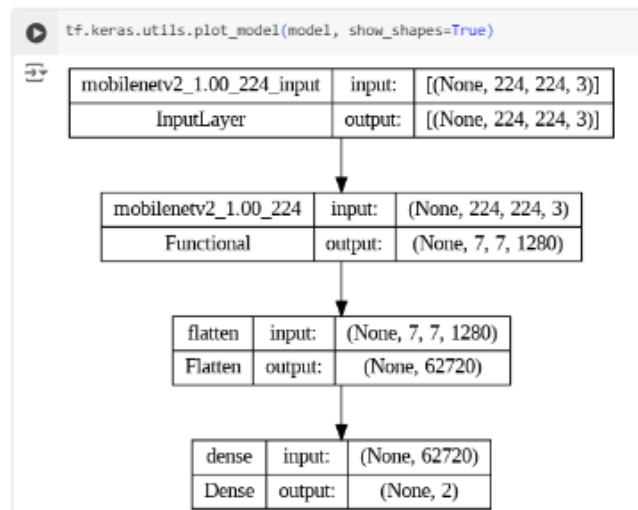
Tabel 4.2 Jumlah Data Validasi Setiap Kelas

Kelas	Jumlah Data
Matang	354
Tidak Matang	353

Total dari keseluruhan dataset tersebut adalah 2264. Selanjutnya, seluruh dataset tersebut dimasukkan ke dalam Google Drive untuk mempermudah dalam pemanggilan direktori pada saat proses pelatihan model. Setelah seluruh dataset berhasil diupload ke dalam Google Drive, langkah selanjutnya yaitu memanggil direktori penyimpanan file dataset di Google Drive dengan menggunakan bantuan Python dan Google Collab.

4.2 Pembangunan Model CNN

Pada proses pembuatan model dengan algoritma *Convolutional Neural Network* (CNN), Berbagai lapisan Keras akan diterapkan yaitu *MobileNetV2*, *sequential*, *flatten*, *dense*, *dropout*, dan *optimizer adam*.



Gambar 4.1 Model CNN dan MobileNetV2

Pada penelitian ini menggunakan 4 lapisan di dalam arsitektur model yaitu input layer yang menunjukkan bahwa input berupa gambar dengan ukuran 224x224 piksel dan memiliki 3 saluran warna (RGB). MobileNet layer menunjukkan lapisan ini menggunakan arsitektur MobileNetV2 yang telah dilatih sebelumnya, tetapi outputnya sudah diubah menjadi fitur-fitur dengan ukuran 7x7 dan 1280 saluran fitur. Flatten layer menunjukkan bahwa lapisan ini mengubah (flatten) fitur-fitur 7x7x1280 menjadi vektor 1 dimensi dengan panjang 62720, yang akan diteruskan ke lapisan berikutnya. Dense layer (fully connected) yang menghubungkan semua neuron dari lapisan sebelumnya ke 2 neuron di lapisan ini. 2 neuron ini akan menunjukkan bahwa model ini digunakan untuk klasifikasi ke dalam 2 kelas yang berbeda.

4.3 Testing Model MobileNetV2

Pelatihan model menggunakan Google Collab dengan tipe akselerator hardware T4 GPU sebanyak 50 kali training atau epoch 50. Dalam melakukan proses testing dilakukan perbandingan antara dataset yang telah di augmentasi dan dataset awal sebelum augmentasi untuk melihat perbandingan akurasi yang dihasilkan.

```
Epoch 1/50
49/49 [=====] - 228s 5s/step - loss: 0.6822 - accuracy: 0.6994 - val_loss: 0.6989 - val_accuracy: 0.6147
Epoch 2/50
49/49 [=====] - 103s 2s/step - loss: 0.5106 - accuracy: 0.7649 - val_loss: 7.3281 - val_accuracy: 0.4759
Epoch 3/50
49/49 [=====] - 119s 2s/step - loss: 0.4114 - accuracy: 0.8202 - val_loss: 5.0918 - val_accuracy: 0.4759
Epoch 4/50
49/49 [=====] - 119s 2s/step - loss: 0.3497 - accuracy: 0.8606 - val_loss: 7.5977 - val_accuracy: 0.4759
Epoch 5/50
49/49 [=====] - 108s 2s/step - loss: 0.2846 - accuracy: 0.8895 - val_loss: 12.6341 - val_accuracy: 0.4759
Epoch 6/50
49/49 [=====] - 103s 2s/step - loss: 0.2501 - accuracy: 0.8972 - val_loss: 18.7598 - val_accuracy: 0.4759
Epoch 7/50
49/49 [=====] - 121s 2s/step - loss: 0.2284 - accuracy: 0.9069 - val_loss: 12.7516 - val_accuracy: 0.4759
Epoch 8/50
49/49 [=====] - 133s 3s/step - loss: 0.2035 - accuracy: 0.9165 - val_loss: 16.6179 - val_accuracy: 0.4759
Epoch 9/50
49/49 [=====] - 111s 2s/step - loss: 0.1938 - accuracy: 0.9223 - val_loss: 8.8906 - val_accuracy: 0.4929
Epoch 10/50
49/49 [=====] - 127s 3s/step - loss: 0.1384 - accuracy: 0.9396 - val_loss: 8.9886 - val_accuracy: 0.5326
Epoch 11/50
49/49 [=====] - 115s 2s/step - loss: 0.1946 - accuracy: 0.9326 - val_loss: 13.5231 - val_accuracy: 0.4816
Epoch 12/50
49/49 [=====] - 136s 3s/step - loss: 0.1231 - accuracy: 0.9563 - val_loss: 22.6878 - val_accuracy: 0.4759
Epoch 13/50
49/49 [=====] - 112s 2s/step - loss: 0.1047 - accuracy: 0.9634 - val_loss: 24.8856 - val_accuracy: 0.4759
Epoch 14/50
49/49 [=====] - 109s 2s/step - loss: 0.0918 - accuracy: 0.9660 - val_loss: 22.8858 - val_accuracy: 0.4788
```


Gambar 4.2 Akurasi Dataset Sebelum Augmentasi

```
Epoch 15/50
50/50 [=====] - 128s 3s/step - loss: 0.4384 - accuracy: 0.8356 - val_loss: 0.5100 - val_accuracy: 0.8475 - lr: 1.0000e-04
Epoch 16/50
50/50 [=====] - 126s 3s/step - loss: 0.3829 - accuracy: 0.8620 - val_loss: 0.5881 - val_accuracy: 0.8350 - lr: 1.0000e-04
Epoch 17/50
50/50 [=====] - 134s 3s/step - loss: 0.3680 - accuracy: 0.8532 - val_loss: 0.5955 - val_accuracy: 0.8275 - lr: 1.0000e-04
Epoch 18/50
50/50 [=====] - 127s 3s/step - loss: 0.3838 - accuracy: 0.8557 - val_loss: 0.4779 - val_accuracy: 0.8475 - lr: 1.0000e-04
Epoch 19/50
50/50 [=====] - 126s 3s/step - loss: 0.3492 - accuracy: 0.8670 - val_loss: 0.5814 - val_accuracy: 0.8200 - lr: 1.0000e-04
Epoch 20/50
50/50 [=====] - 126s 3s/step - loss: 0.3833 - accuracy: 0.8507 - val_loss: 0.5671 - val_accuracy: 0.8200 - lr: 1.0000e-04
Epoch 21/50
50/50 [=====] - 126s 3s/step - loss: 0.3488 - accuracy: 0.8695 - val_loss: 0.5384 - val_accuracy: 0.8350 - lr: 1.0000e-04
Epoch 22/50
50/50 [=====] - 131s 3s/step - loss: 0.3866 - accuracy: 0.8595 - val_loss: 0.5602 - val_accuracy: 0.8350 - lr: 1.0000e-04
Epoch 23/50
50/50 [=====] - 126s 3s/step - loss: 0.3765 - accuracy: 0.8601 - val_loss: 0.5617 - val_accuracy: 0.8050 - lr: 1.0000e-04
Epoch 24/50
50/50 [=====] - 125s 3s/step - loss: 0.3428 - accuracy: 0.8676 - val_loss: 0.5546 - val_accuracy: 0.8100 - lr: 2.0000e-05
Epoch 25/50
50/50 [=====] - 146s 3s/step - loss: 0.2883 - accuracy: 0.8833 - val_loss: 0.5578 - val_accuracy: 0.8425 - lr: 2.0000e-05
Epoch 26/50
50/50 [=====] - 124s 2s/step - loss: 0.2938 - accuracy: 0.8852 - val_loss: 0.5180 - val_accuracy: 0.8225 - lr: 2.0000e-05
Epoch 27/50
50/50 [=====] - 124s 2s/step - loss: 0.2961 - accuracy: 0.8864 - val_loss: 0.5092 - val_accuracy: 0.8300 - lr: 2.0000e-05
Epoch 28/50
50/50 [=====] - 125s 3s/step - loss: 0.2878 - accuracy: 0.8852 - val_loss: 0.5315 - val_accuracy: 0.8450 - lr: 2.0000e-05
Epoch 29/50
50/50 [=====] - 125s 2s/step - loss: 0.3017 - accuracy: 0.8770 - val_loss: 0.5193 - val_accuracy: 0.8350 - lr: 2.0000e-05
Epoch 30/50
50/50 [=====] - 145s 3s/step - loss: 0.2918 - accuracy: 0.8877 - val_loss: 0.5403 - val_accuracy: 0.8375 - lr: 2.0000e-05
```


Gambar 4.3 Akurasi Dataset Setelah Augmentasi

Pada gambar 4.2 dan gambar 4.3 terlihat perbedaan akurasi yang cukup signifikan, dataset yang tidak augmentasi mendapatkan val akurasi sebesar 47% dan dataset augmentasi mendapatkan val akurasi sebesar 83%. Keduanya

mengalami proses epoch yang berhenti pada saat proses ke 14 untuk dataset sebelum augmentasi dan 50 untuk dataset setelah augmentasi dikarenakan menggunakan *early stop* dan *callback* jika proses mengalami akurasi berulang maka akan otomatis berhenti. Terdapat perbedaan hasil akurasi yang cukup signifikan, untuk itu penulis memilih menggunakan dataset yang telah di augmentasi dalam penelitian ini dikarenakan hasil akurasi yang didapatkan lebih besar. Perkembangan setiap epoch nya dapat dilihat pada *model accuracy* dan *model loss*.



Gambar 4.4 Akurasi dan Loss Dataset Sebelum Augmentasi



Gambar 4.5 Akurasi dan Loss Dataset Setelah Augmentasi

Pada grafik *model accuracy* dan *model loss* terdapat dua garis, yaitu garis biru untuk data pelatihan (train) dan garis kuning untuk data test (val). Garis data pelatihan menunjukkan akurasi model pada data yang digunakan untuk melatih model. Garis data test menunjukkan akurasi model pada data yang tidak digunakan untuk melatih model, tetapi digunakan untuk mengevaluasi performa model.

Pada grafik akurasi dataset augmentasi menunjukkan akurasi model train meningkat secara bertahap dari 0,65 pada epoch pertama menjadi 0,96 pada epoch 20. Tetapi akurasi model val menunjukkan tren penurunan, mencapai 0,47 pada epoch 14. Sedangkan pada grafik akurasi setelah augmentasi menunjukkan akurasi model train secara umum lebih rendah daripada sebelum augmentasi. Akurasi train mencapai 0,66 pada epoch pertama dan stabil di sekitar 0,88 pada epoch selanjutnya. Akurasi model val juga lebih tinggi, mencapai 0,83 pada epoch 50.

Pada grafik loss dataset sebelum augmentasi menunjukkan loss dataset train menurun secara bertahap dari 10 pada epoch pertama menjadi 0 pada epoch 14. Loss dataset val juga menunjukkan tren penurunan, mencapai 0.5 pada epoch 14. Sedangkan pada grafik loss dataset setelah augmentasi menunjukkan loss dataset train secara umum lebih rendah daripada sebelum augmentasi. Loss train mencapai 0 pada epoch pertama dan stabil di sekitar 0,2 pada epoch selanjutnya. Loss dataset val juga lebih rendah, mencapai 1 pada epoch 20.

Setelah melihat perbandingan hasil grafik akurasi dan loss pada kedua dataset dapat disimpulkan bahwa augmentasi data meningkatkan akurasi model train dan val secara signifikan dan augmentasi data menurunkan loss dataset train dan val secara signifikan. Sehingga kesimpulannya yaitu augmentasi data merupakan teknik yang efektif untuk meningkatkan performa model deep learning.

4.4 Evaluasi Kinerja Model CNN

Tahap evaluasi dilakukan untuk mengevaluasi langkah sebelumnya, yakni tahap pelatihan, dengan maksud menyesuaikan model yang telah ditetapkan agar sesuai dengan kebutuhan yang telah ditetapkan. Pada tahap ini, CNN dan akan diuji hasil akurasi menggunakan teknik *confusion matrix*. Selanjutnya, melihat pengukuran *accuracy*, *precision*, *recall* dan *f-1 score* untuk mendapatkan keseluruhan tingkat akurasi.

```
04 from sklearn.metrics import confusion_matrix, accuracy_score

y_test = ts_df['Class']
print(classification_report(y_test, pred2))
print("Accuracy of the Model:", "{:.1f}%".format(accuracy_score(y_test, pred2)*100))
```

	precision	recall	f1-score	support
ripe	0.60	0.30	0.40	186
unripe	0.50	0.77	0.61	168
accuracy			0.53	354
macro avg	0.55	0.54	0.50	354
weighted avg	0.55	0.53	0.50	354

Accuracy of the Model: 52.5%

Gambar 4.6 Perhitungan Hasil Akurasi Dataset Setelah Augmentasi

```
from sklearn.metrics import classification_report, accuracy_score
import numpy as np

# Get true labels and predicted classes
true_labels = validation_generator.classes
predictions = model.predict(validation_generator)
predicted_classes = np.argmax(predictions, axis=1)

# Generate classification report
report = classification_report(true_labels, predicted_classes, target_names=labels)
print(report)

# Print the accuracy score
accuracy = accuracy_score(true_labels, predicted_classes)
print(f"Accuracy of the Model: {accuracy*100:.1f}%")
```

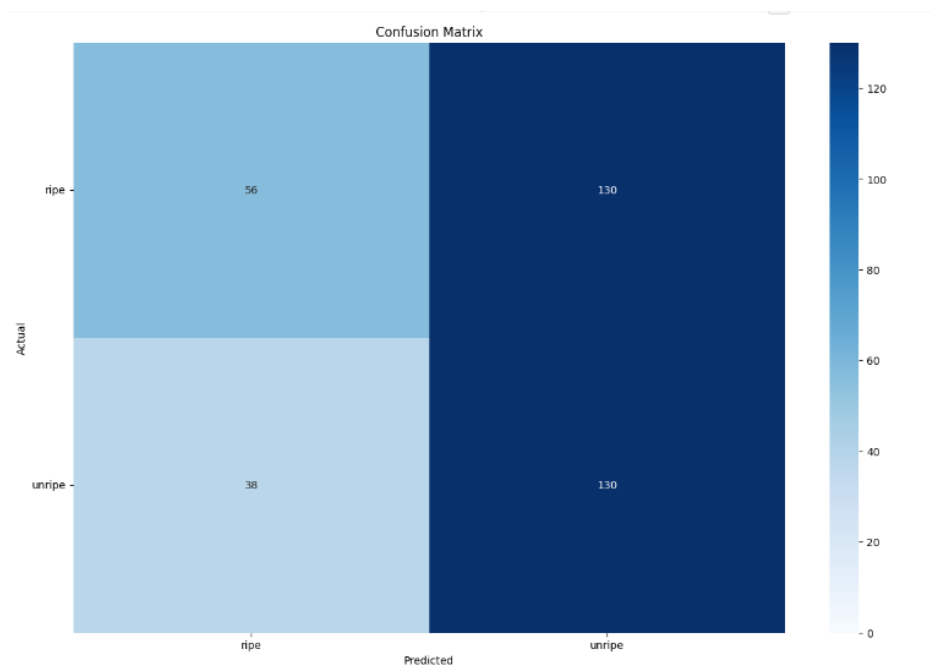
```
13/13 [=====] - 23s 2s/step
precision recall f1-score support
ripe      0.83    0.88    0.85    202
unripe    0.87    0.81    0.84    198
accuracy          0.85    0.85    0.85    400
macro avg    0.85    0.85    0.85    400
weighted avg 0.85    0.85    0.85    400

Accuracy of the Model: 84.8%
```

Gambar 4.7 Perhitungan Hasil Akurasi Dataset Sebelum Augmentasi

Dari hasil evaluasi ini, dapat disimpulkan bahwa model klasifikasi memiliki kinerja yang sangat baik dengan akurasi keseluruhan sebesar 84.8 Model ini menunjukkan kemampuan yang kuat dalam mengklasifikasikan berbagai kondisi kematangan sawit, dengan nilai f1-score tertinggi pada kelas "*ripe*" (0.85) dan nilai f1-score terendah pada kelas "*unripe*" (0.81). Evaluasi ini memberikan keyakinan bahwa model dapat diandalkan untuk mendeteksi dan mengklasifikasikan kondisi kematangan dengan tingkat akurasi yang tinggi.

Augmentasi data secara umum meningkatkan akurasi per kelas. Hal ini menunjukkan bahwa augmentasi data dapat membantu model untuk belajar lebih baik dari data yang tersedia dan menghasilkan prediksi yang lebih akurat untuk semua kelas sawit.



Gambar 4.8 *Confusion Matrix* Dataset Sebelum Augmentasi

Confusion matrix dataset sebelum augmentasi terlihat pada gambar 4.8 menggambarkan performa model klasifikasi untuk memprediksi tingkat kematangan buah sawit. Berikut perincian dari gambar 4.8:

1. True Positives (TP): Jumlah data yang benar-benar matang dan diprediksi sebagai matang, yaitu 56.
2. True Negatives (TN): Jumlah data yang benar-benar tidak matang dan diprediksi sebagai tidak matang, yaitu 130.
3. False Positives (FP): Jumlah data yang tidak matang tetapi diprediksi sebagai matang, yaitu 38.
4. False Negatives (FN): Jumlah data yang matang tetapi diprediksi sebagai tidak matang, yaitu 130.


$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{56 + 130}{56 + 130 + 38 + 130} = \frac{186}{354} = 0.5254 \text{ atau } 52.54\%$$

$$\text{Presisi untuk kelas 'matang'} = \frac{TP}{TP + FP} = \frac{56}{56 + 38} = \frac{56}{94} = 0.5957 \text{ atau } 59.57\%$$

$$\text{Presisi untuk kelas 'tidak matang'} = \frac{TN}{TN + FN} = \frac{130}{130 + 130} = \frac{130}{260} = 0.5 \text{ atau } 50\%$$

$$\text{Recall untuk kelas 'matang'} = \frac{TP}{TP + FN} = \frac{56}{56 + 130} = \frac{56}{186} = 0.3011 \text{ atau } 30.11\%$$

$$\text{Recall untuk kelas 'tidak matang'} = \frac{TN}{TN + FP} = \frac{130}{130 + 38} = \frac{130}{168} = 0.7738 \text{ atau } 77.38\%$$



Gambar 4.9 *Confusion Matrix* Setelah Augmentasi

Sedangkan diagram *confusion matrix* dataset setelah augmentasi dapat dilihat pada gambar 4.9 menggambarkan performa model klasifikasi untuk memprediksi tingkat kematangan buah sawit. Berikut perincian dari gambar 4.9:

1. True Positives (TP): Jumlah data yang benar-benar matang dan diprediksi sebagai matang, yaitu 178.
2. True Negatives (TN): Jumlah data yang benar-benar tidak matang dan diprediksi sebagai tidak matang, yaitu 161.
3. False Positives (FP): Jumlah data yang tidak matang tetapi diprediksi sebagai matang, yaitu 37.
4. False Negatives (FN): Jumlah data yang matang tetapi diprediksi sebagai tidak matang, yaitu 24

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{178 + 161}{178 + 161 + 37 + 24} = \frac{339}{400} = 0.8475 \text{ atau } 84.75\%$$

$$\text{Presisi untuk kelas 'matang'} = \frac{TP}{TP + FP} = \frac{178}{178 + 37} = \frac{178}{215} = 0.8279 \text{ atau } 82.79\%$$

$$\text{Presisi untuk kelas 'tidak matang'} = \frac{TN}{TN + FN} = \frac{161}{161 + 24} = \frac{161}{185} = 0.8703 \text{ atau } 87.03\%$$

$$\text{Recall untuk kelas 'matang'} = \frac{TP}{TP + FN} = \frac{178}{178 + 24} = \frac{178}{202} = 0.8812 \text{ atau } 88.12\%$$

$$\text{Recall untuk kelas 'tidak matang'} = \frac{TN}{TN + FP} = \frac{161}{161 + 37} = \frac{161}{198} = 0.8131 \text{ atau } 81.31\%$$

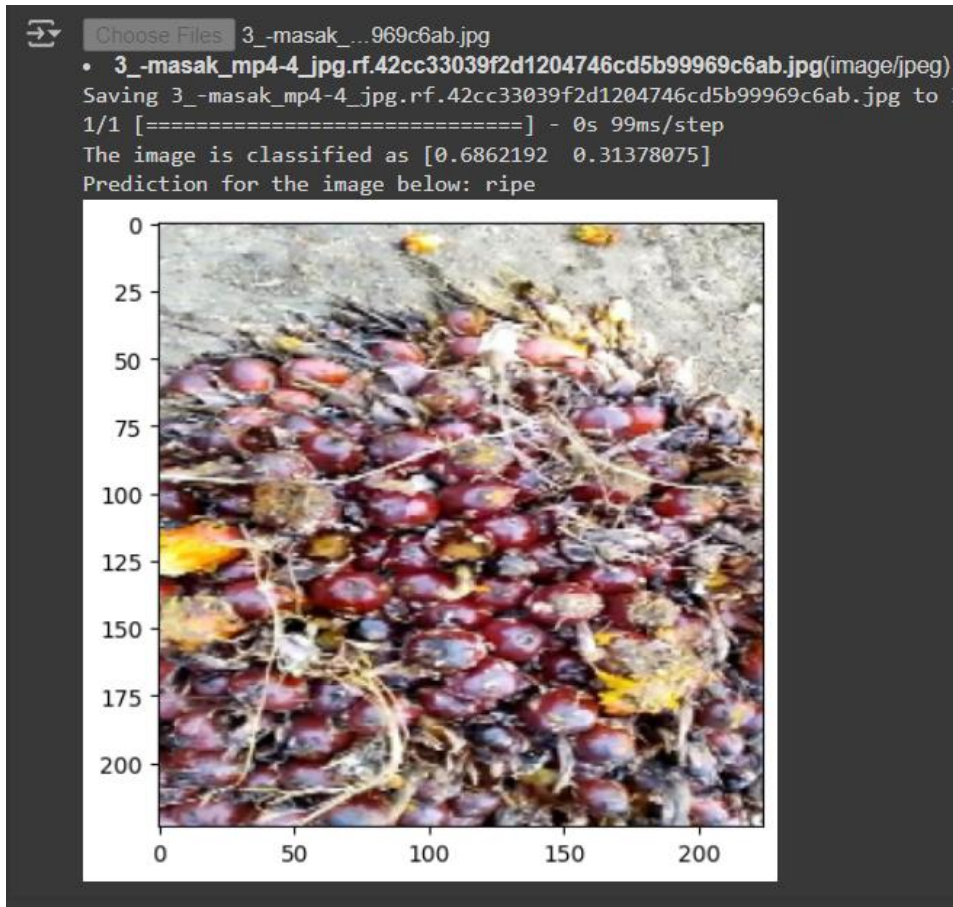
Hasil akurasi tersebut diperoleh dari jumlah sampel data yang teridentifikasi benar dibagi dengan total data test. Hasil 84% merupakan hasil yang baik dari mengimplementasikan CNN untuk mengklasifikasi kematangan sawit. Dari pembahasan topik penelitian ini dapat dilihat bahwa penelitian ini menggunakan 2 kelas kematangan sawit dengan dataset yang digunakan sebanyak 2264 gambar dengan hasil akurasi sebesar 84%.

4.5 Pengujian Model

Pada tahap *testation* program atau testing ,akan memberikan perintah untuk menginput file gambar sawit dalam bentuk jpg. Selanjutnya jika sudah menginput file, program akan membaca file tersebut dan langsung mengeluarkan hasil prediksi dari gambar penyakit yang telah di input. Untuk melihat hasil prediksi dari masing-masing kelas sawit dapat dilihat pada point berikut ini:

4.5.1 Matang Tandan buah segar (*Ripe*)

Pengujian pada salah satu buah sawit yang matang untuk tandan buah segar menunjukkan hasil prediksi yang tepat.

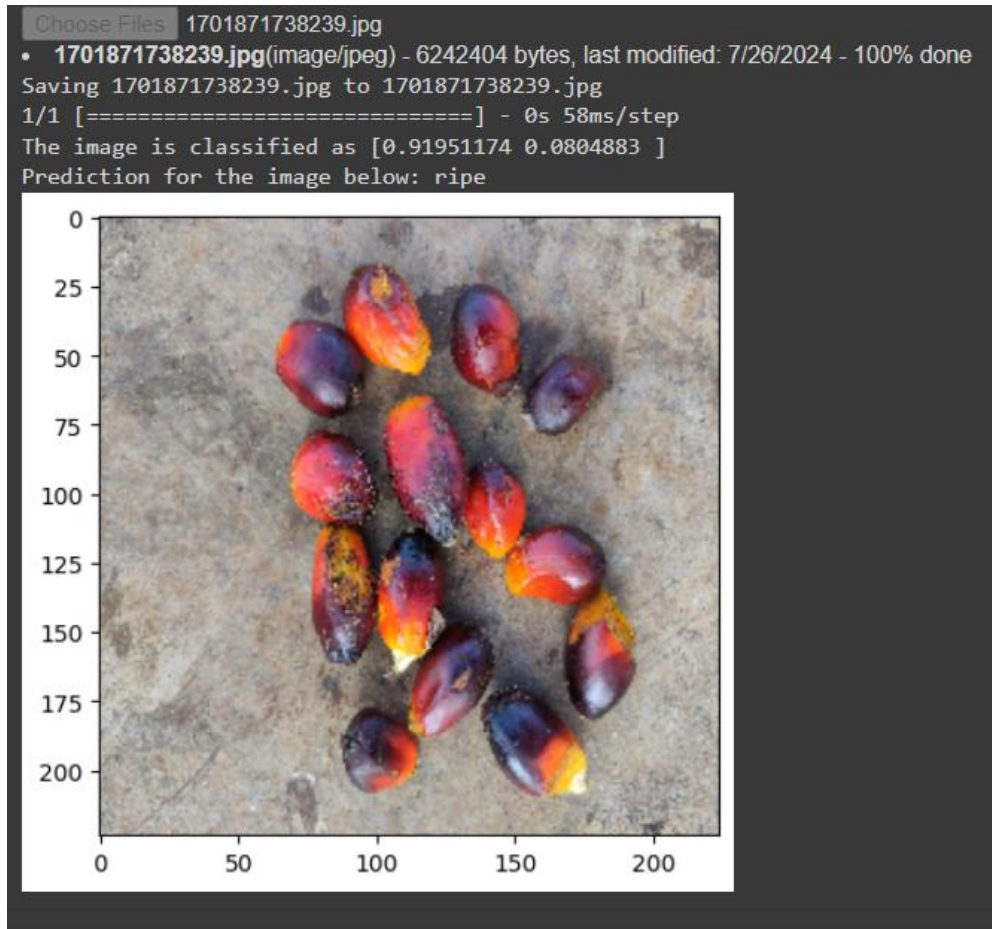


Gambar 4.10 Hasil Prediksi Sawit Matang tandan buah segar

Hasil Prediksi Probabilitas: Model CNN memberikan probabilitas 0.6862192 (68.62%) bahwa gambar tersebut termasuk dalam kelas "*ripe*"(matang) dan 0.31378075 (31.38%) bahwa gambar tersebut termasuk dalam kelas "*unripe*" (tidak matang). Klasifikasi Akhir: Berdasarkan probabilitas yang lebih tinggi, model mengklasifikasikan gambar ini sebagai "*ripe*" (**matang**).

4.5.2 Matang Buah brondolan (*Ripe*)

Pengujian pada salah satu buah sawit yang matang untuk buah brondolan menunjukkan hasil prediksi yang tepat.

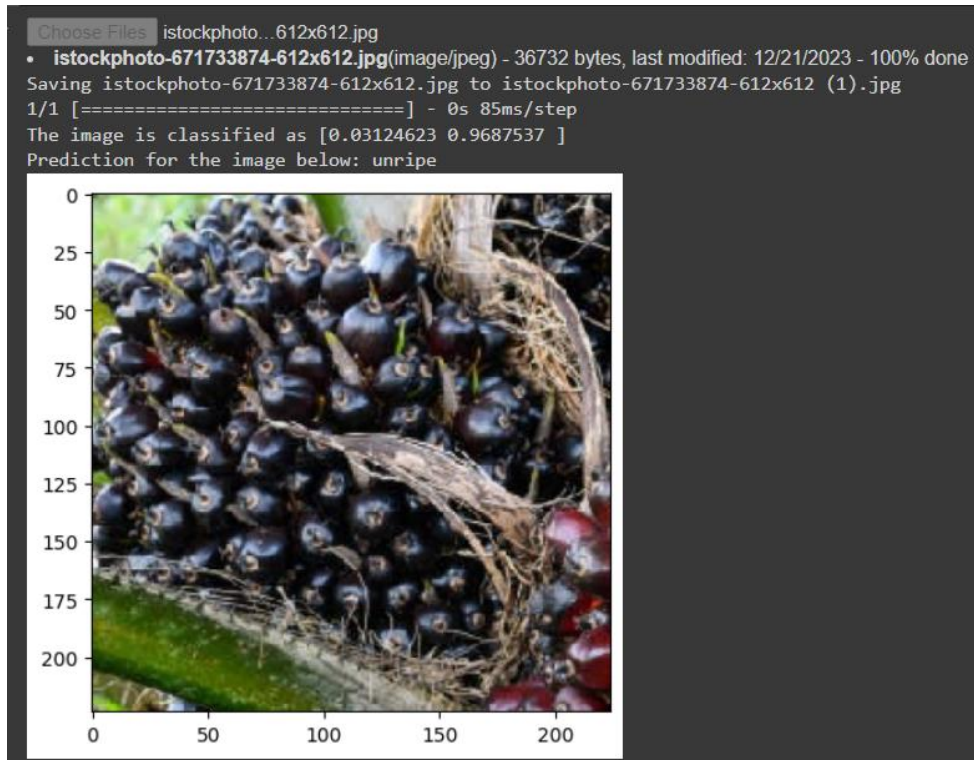


Gambar 4.11 Hasil Prediksi Sawit matang brondolan

Hasil Prediksi Probabilitas: Model CNN memberikan probabilitas 0.91951174 (91.95%) bahwa gambar tersebut termasuk dalam kelas "*ripe*"(matang) dan 0.0804883 (31.38%) bahwa gambar tersebut termasuk dalam kelas "*unripe*" (tidak matang). Klasifikasi Akhir: Berdasarkan probabilitas yang lebih tinggi, model mengklasifikasikan gambar ini sebagai "*ripe*" (**matang**).

4.5.3 Tidak matang Tandan buah segar (*Unripe*)

Pengujian pada salah satu buah sawit yang tidak matang untuk tandan buah segar menunjukkan hasil prediksi yang tepat.

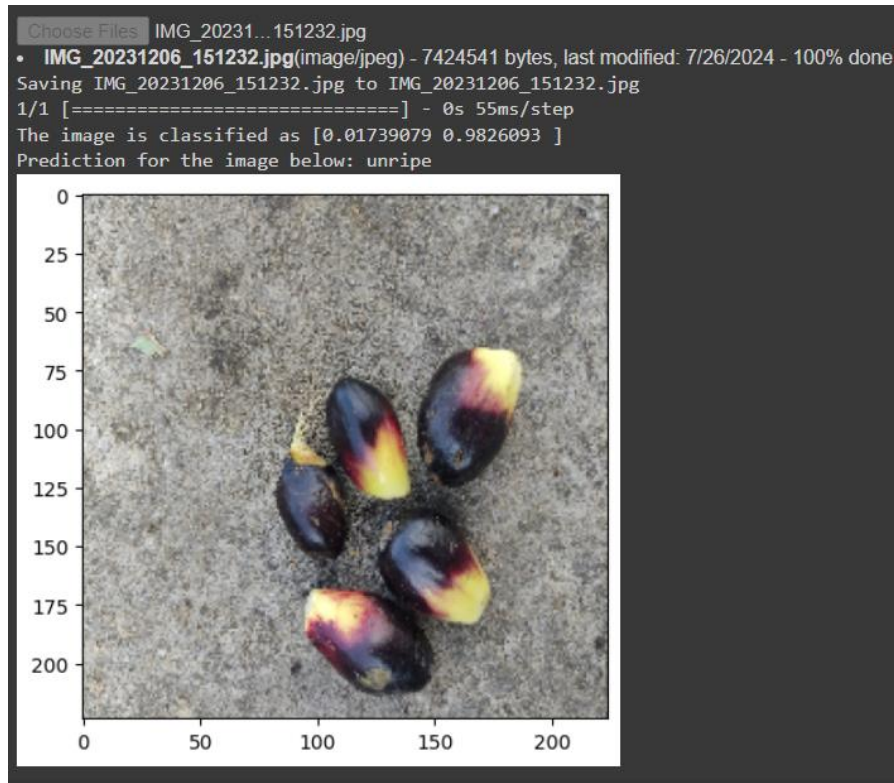


Gambar 4.12 Hasil Prediksi Tandan buah segar tidak matang

Hasil Prediksi Probabilitas: Model CNN memberikan probabilitas 0.03124623 (3.124%) bahwa gambar tersebut termasuk dalam kelas "*ripe*"(matang) dan 0.9687537 (96.87%) bahwa gambar tersebut termasuk dalam kelas "*unripe*" (tidak matang). Klasifikasi Akhir: Berdasarkan probabilitas yang lebih tinggi, model mengklasifikasikan gambar ini sebagai "*unripe*" (**tidak matang**).

4.5.4 Tidak Matang Buah brondolan (*Unripe*)

Pengujian pada salah satu buah sawit yang tidak matang untuk buah brondolan menunjukkan hasil prediksi yang tepat.



Gambar 4.13 Hasil Prediksi Sawit matang brondolan

Hasil Prediksi Probabilitas: Model CNN memberikan probabilitas 0.01739079 (01.73%) bahwa gambar tersebut termasuk dalam kelas "*ripe*"(matang) dan 0.9826093 (98.26%) bahwa gambar tersebut termasuk dalam kelas "*unripe*" (tidak matang). Klasifikasi Akhir: Berdasarkan probabilitas yang lebih tinggi, model mengklasifikasikan gambar ini sebagai "*unripe*" (**tidak matang**).

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

1. Penelitian ini berhasil mengimplementasikan model deteksi menggunakan algoritma Convolutional Neural Network (CNN) untuk mengklasifikasikan kematangan buah sawit. Model ini mampu mengenali pola-pola visual yang terkait dengan tingkat kematangan buah sawit, seperti warna dan tekstur, yang menjadi indikator utama dalam klasifikasi.
2. Model deteksi yang diimplementasikan menghasilkan akurasi 84,75% yang cukup tinggi dalam klasifikasi kematangan buah sawit dengan penggunaan dataset 2264 data. Hal ini menunjukkan bahwa algoritma CNN efektif dalam memproses citra buah sawit dan menghasilkan prediksi yang akurat mengenai tingkat kematangannya. Akurasi yang diperoleh membuktikan bahwa model CNN memiliki potensi besar untuk diterapkan dalam industri perkebunan kelapa sawit.

5.2 Saran

Saran untuk penelitian selanjutnya yang akan menggunakan topik yang sama yaitu melakukan perbandingan dengan metode algoritma CNN lainnya untuk mendapatkan hasil yang lebih baik. Namun harus ada pertimbangan pada *transfer learning* yang ingin digunakan, setiap waktunya ada *update* pada *library* untuk penggunaan model. Dataset yang bagus akan membentuk model arsitektur yang bagus pula karena model belajar dari dataset yang dilabel. Penambahan kelas pada label dataset untuk lebih spesifik pada jenis sawit. Pengenalan pada objek harus

terlihat terang dan pencahayaan yang cukup karena potret yang jelas akan membantu prediksi lebih akurat. Dataset yang duplikat membuat model overfit.

DAFTAR PUSTAKA

- Bowo, T. A., Syaputra, H., & Akbar, M. (2020). Penerapan Algoritma Convolutional Neural Network Untuk Klasifikasi Motif Citra Batik Solo. In *Journal of Software Engineering Ampera* (Vol. 1, Issue 2). <https://journal-computing.org/index.php/journal-sea/index>
- Charli, Fino, et al. "Implementasi Metode Faster Region Convolutional Neural Network (Faster R-CNN) Untuk Pengenalan Jenis Burung Lovebird." *Journal of Information Technology Ampera* 1.3 (2020): 185-197.
- Farsi, B., Amayri, M., Bouguila, N., & Eicker, U. (2021a). On short-term load forecasting using machine learning techniques and a novel parallel deep LSTM-CNN approach. *IEEE Access*, 9, 31191–31212. <https://doi.org/10.1109/ACCESS.2021.3060290>
- Gulzar, Y. (2023). Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique. *Sustainability (Switzerland)*, 15(3). <https://doi.org/10.3390/su15031906>
- Hajar, S., Novany, A. A., Windarto, A. P., Wanto, A., & Irawan, E. (n.d.). *Seminar Nasional Teknologi Komputer & Sains (SAINTEKS) Penerapan K-Means Clustering Pada Ekspor Minyak Kelapa Sawit Menurut Negara Tujuan*.
- Hasibuan, Hasrul Abdi. "Penentuan rendemen, mutu dan komposisi kimia minyak sawit dan minyak inti sawit tandan buah segar bervariasi kematangan sebagai dasar untuk penetapan standar kematangan panen." *Jurnal Penelitian Kelapa Sawit* 28.3 (2020): 123-132.
- Husna, I. N., Ulum, M., Saputro, A. K., & Laksono, D. T. (2022). Rancang Bangun Sistem Deteksi Dan Perhitungan Jumlah Orang Menggunakan Metode Convolutional Neural Network (CNN). *SinarFe7*, 5(1), 1-6.
- Islamiah Saubatul. (2020). Studi Pengaruh Tingkat Kematangan Buah Kelapa Sawit Terhadap Kandungan Asam Lemak Melalui Metode Maserasi. *Rafflesia Journal of Natural and Applied Science*.
- Krisdiarto, Andreas Wahyu, Lilik Sutiarto, and Kuncoro Harto Widodo. "Optimasi kualitas tandan buah segar kelapa sawit dalam proses panen-angkut menggunakan model dinamis." *Agritech* 37.1 (2017): 102-108.
- Mahesh, B. (2018). Machine Learning Algorithms-A Review. *International Journal of Science and Research*. <https://doi.org/10.21275/ART20203995>
- Purna Irawan, Y., Susilawati, I., & Kunci, K. (n.d.). *Klasifikasi Jenis Aglaonema Berdasarkan Citra Daun Menggunakan Convolutional Neural Network (CNN)*.
- Prasvita, Desta Sandya, et al. "Klasifikasi Pohon Kelapa Sawit Pada Data Fusi Citra Lidar Dan Foto Udara Menggunakan Convolutional Neural Network." *JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)* 6.2 (2021): 406-415.
- Rasywir, Errissya, Rudolf Sinaga, and Yovi Pratama. "Analisis dan Implementasi Diagnosis Penyakit Sawit dengan Metode Convolutional Neural Network (CNN)." *Jurnal Khatulistiwa Informatika* 22.2 (2020): 117-123.
- Suharjito, Asrol, M., Utama, D. N., Junior, F. A., & Marimin. (2023). Real-Time Oil Palm Fruit Grading System Using Smartphone and Modified YOLOv4. *IEEE Access*, 11, 59758–59773. <https://doi.org/10.1109/ACCESS.2023.3285537>
- Salambue, R., & Shiddiq, M. (2019, November). Klasifikasi kematangan buah sawit menggunakan model warna RGB. In *SEMILAR NASIONAL APTIKOM (SEMNASITIK) 2019* (pp. 434-440).
- Sitorus, Mastarida LF, et al. "Peningkatan Produksi Crude Palm Oil Melalui Kriteria Matang Panen Tandan Buah Segar untuk Optimalisasi Pendapatan Perusahaan." *AGRISAINS: Jurnal Ilmiah Magister Agribisnis* 2.1 (2020): 26-32.

- Supriadi, Joko, Gunawan Tabrani, and Isnaini Isnaini. "KRITERIA TINGKAT KEMATANGAN BUAH KELAPA SAWIT (*Elaeis guineensis* Jacq.) SEBAGAI INDIKATOR SIAP PANEN DITINJAU DARI KARAKTERISTIK MORFOLOGIS." *Jurnal Online Mahasiswa (JOM) Bidang Pertanian* 6: 1-9.
- Samuel, Samuel, et al. "Metode Deteksi Pokok Pohon Secara Otomatis pada Citra Perkebunan Sawit Menggunakan Model Convolutional Neural Network (CNN) pada Perangkat Lunak Sistem Informasi Geografis." *Jurnal Teknologi Informasi dan Ilmu Komputer* 9.7 (2022): 1689-1698.
- Satia, Gusti Ashari Wira, Erick Firmansyah, and Arif Umami. "Perancangan sistem identifikasi penyakit pada daun kelapa sawit (*Elaeis guineensis* Jacq.) dengan algoritma deep learning convolutional neural networks." *Jurnal Ilmiah Pertanian* 19.1 (2022): 1-10.
- Teknik Elektro, J., & Wega Intyanto, G. (n.d.). *Klasifikasi Citra Bunga dengan Menggunakan Deep Learning: CNN (Convolution Neural Network)*.

LAMPIRAN



Nomor : 052/AMJ-UMSU/VII/2024
Lamp : -
Hal : **Surat Balasan Izin Riset Pendahuluan**

Kepada YTH,
Bapak Dekan Fakultas Ilmu Komputer & Teknologi
Universitas Muhammadiyah Sumatera Utara
Di

TEMPAT

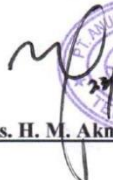
Dengan Hormat,

Sehubungan dengan surat No.593/II.3-AU/UMSU-09/F/2024 tanggal 16 Juli 2024, perihal permohonan izin riset pendahuluan untuk penyusunan skripsi mahasiswa atas nama "Muhammad Rizky Pratama Siregar", dengan judul "Deteksi Kematangan Buah Sawit dengan Menggunakan Algoritma Convolution Neural Network", maka dengan ini kami sampaikan :

1. Memberikan Izin pelaksanaan penelitian tersebut di PT. Anugerah Makmur Jaya Tebing Tinggi.
2. Izin penelitian diberikan hanya untuk keperluan akademik.

Demikian lah surat balasan ini kami sampaikan, atas perhatian nya kami ucapkan terima kasih.

Tebing Tinggi, 23 Juli 2024
Hormat Kami


Drs. H. M. Akmal



PABRIK MINYAK KELAPA SAWIT

Alamat : Jl. Kutilang, Kel. Bulian Kec. Bajeris
Kota Tebing Tinggi
Sumatera Utara