

SKRIPSI

**IMPLEMENTASI VISI KOMPUTER UNTUK KLASIFIKASI
KUALITAS BENIH KECAMBAH KELAPA SAWIT
MENGUNAKAN *CONVOLUTIONAL NEURAL NETWORK*
(CNN)**

Disusun dan diajukan oleh:

**MUHAMMAD ILHAM NUR FURQAN
D121201072**



**PROGRAM STUDI SARJANA TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2024**

LEMBAR PENGESAHAN SKRIPSI

IMPLEMENTASI VISI KOMPUTER UNTUK KLASIFIKASI KUALITAS BENIH KECAMBAH KELAPA SAWIT MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK (CNN)*

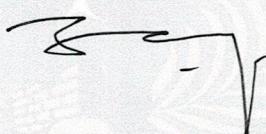
Disusun dan diajukan oleh

Muhammad Ilham Nur Furqan
D121201072

Telah dipertahankan di hadapan Panitia Ujian yang dibentuk dalam rangka Penyelesaian
Studi Program Sarjana Program Studi Teknik Informatika
Fakultas Teknik Universitas Hasanuddin
Pada tanggal 10 Oktober 2024
dan dinyatakan telah memenuhi syarat kelulusan

Menyetujui,

Pembimbing Utama,



Prof. Dr. Ir. Indrabayu, S.T., M.T., M.Bus.Sys., IPM.ASEAN.Eng.
NIP 19750716 200212 1 004

Ketua Program Studi,



Prof. Dr. Ir. Indrabayu, S.T., M.T., M.Bus.Sys., IPM.ASEAN.Eng.
NIP 19750716 200212 1 004

PERNYATAAN KEASLIAN

Yang bertanda tangan dibawah ini:

Nama : Muhammad Ilham Nur Furqan

NIM : D121201072

Program Studi : Teknik Informatika

Jenjang : S1

Menyatakan dengan ini bahwa karya tulisan saya berjudul

Implementasi Visi Komputer Untuk Klasifikasi Kualitas Benih Kecambah Kelapa Sawit Menggunakan *Convolutional Neural Network* (CNN)

Adalah karya tulisan saya sendiri dan bukan merupakan pengambilan alihan tulisan orang lain dan bahwa skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri.

Semua informasi yang ditulis dalam skripsi yang berasal dari penulis lain telah diberi penghargaan, yakni dengan mengutip sumber dan tahun penerbitannya. Oleh karena itu semua tulisan dalam skripsi ini sepenuhnya menjadi tanggung jawab penulis. Apabila ada pihak manapun yang merasa ada kesamaan judul dan atau hasil temuan dalam skripsi ini, maka penulis siap untuk diklarifikasi dan mempertanggungjawabkan segala resiko.

Segala data dan informasi yang diperoleh selama proses pembuatan skripsi, yang akan dipublikasi oleh Penulis di masa depan harus mendapat persetujuan dari Dosen Pembimbing.

Apabila dikemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan isi skripsi ini hasil karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Gowa, 10 Oktober 2024

Yang Menyatakan



Muhammad Ilham Nur Furqan

ABSTRAK

MUHAMMAD ILHAM NUR FURQAN. *Implementasi Visi Komputer Untuk Klasifikasi Kualitas Benih Kecambah Kelapa Sawit Menggunakan Convolutional Neural Network (CNN)* (dibimbing oleh Indrabayu)

Minyak kelapa sawit merupakan salah satu komoditas ekspor terbesar Indonesia yang memainkan peran penting dalam memenuhi kebutuhan dunia akan produk berbasis kelapa sawit. Mengingat pentingnya kualitas benih kecambah kelapa sawit dalam menentukan keberhasilan pertumbuhan tanaman, diperlukan sistem klasifikasi yang akurat dan efisien. Klasifikasi manual yang dilakukan saat ini memiliki kelemahan dalam hal waktu dan akurasi, sehingga diperlukan teknologi otomatis untuk meningkatkan efisiensi dan konsistensi hasil klasifikasi.

Penelitian ini bertujuan untuk mengimplementasikan algoritma *Convolutional Neural Network* (CNN) dalam klasifikasi kualitas benih kecambah kelapa sawit serta menganalisis kinerja model tersebut menggunakan *video processing*. Dua model utama digunakan dalam penelitian ini, yaitu YOLOv5 untuk deteksi objek dan ResNet18 untuk klasifikasi. Data diambil melalui rekaman video benih kecambah kelapa sawit yang berjalan di atas *conveyor*, dengan jumlah total 100 benih kecambah untuk pelatihan dan 50 benih kecambah untuk pengujian.

Hasil penelitian menunjukkan bahwa model YOLOv5 dengan *batch size* 16 dan 50 *epochs* mencapai nilai mAP50 sebesar 0.995. Sementara itu, hasil terbaik untuk model ResNet18 dicapai dengan *batch size* 16, *learning rate* 0.0001, dan *dropout* 0.3, serta kombinasi skenario pengambilan data pada kecepatan *conveyor* 40 RPM dan jarak kamera 10 cm. Model ResNet18 mencapai akurasi sebesar 94%, *precision* 89%, *recall* 100%, dan *F1-Score* 94% pada pengujian.

Penelitian ini menunjukkan bahwa implementasi sistem klasifikasi berbasis CNN dengan *video processing* dapat meningkatkan efisiensi dan akurasi dalam klasifikasi kualitas benih kecambah kelapa sawit, yang diharapkan dapat mendukung peningkatan produktivitas dan kualitas di industri kelapa sawit.

Kata Kunci: Kelapa Sawit, *Convolutional Neural Network*, Klasifikasi, Visi Komputer, *Video Processing*

ABSTRACT

MUHAMMAD ILHAM NUR FURQAN. *Implementation of Computer Vision for Quality Classification of Palm Oil Seed Sprouts Using Convolutional Neural Network (CNN)* (supervised by Indrabayu)

Palm oil is one of Indonesia's largest export commodities, playing a crucial role in meeting global demand for palm oil-based products. Given the importance of the quality of oil palm seed sprouts in determining the success of plant growth, an accurate and efficient classification system is required. The current manual classification process has drawbacks in terms of time and accuracy, necessitating an automated technology to enhance efficiency and consistency in classification results.

This research aims to implement the Convolutional Neural Network (CNN) algorithm for classifying the quality of oil palm seed sprouts and to analyze the performance of the model using video processing. Two main models were used in this study: YOLOv5 for object detection and ResNet18 for classification. Data were collected through video recordings of oil palm seed sprouts moving on a conveyor, with a total of 100 seed sprouts used for training and 50 seed sprouts for testing.

The research results indicate that the YOLOv5 model with a batch size of 16 and 50 epochs achieved an mAP50 of 0.995. The best results for the ResNet18 model were obtained with a batch size of 16, a learning rate of 0.0001, and a dropout of 0.3, along with a data collection scenario of 40 RPM conveyor speed and a camera distance of 10 cm. The ResNet18 model achieved an accuracy of 94%, precision of 89%, recall of 100%, and F1-Score of 94% during testing.

This study shows that implementing a CNN-based classification system with video processing can enhance efficiency and accuracy in the classification of oil palm seed sprouts, which is expected to support increased productivity and quality in the palm oil industry.

Keywords: Palm Oil, Convolutional Neural Network, Classification, Computer Vision, Video Processing

DAFTAR ISI

LEMBAR PENGESAHAN SKRIPSI	i
PERNYATAAN KEASLIAN.....	ii
ABSTRAK	i
ABSTRACT.....	iv
DAFTAR ISI.....	v
DAFTAR GAMBAR.....	vii
DAFTAR TABEL	ix
DAFTAR SINGKATAN DAN ARTI SIMBOL	x
DAFTAR LAMPIRAN	xi
KATA PENGANTAR.....	xii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian/perancangan	3
1.4 Manfaat Penelitian/perancangan	3
1.5 Batasan Masalah.....	3
BAB II TINJAUAN PUSTAKA.....	4
2.1. Kelapa Sawit.....	4
2.2. <i>Artificial Intelligence</i>	6
2.3. Visi Komputer	9
2.4. <i>Video Processing</i>	10
2.5. <i>Convolutional Neural Networks (CNN)</i>	12
2.6. <i>YOLO (You Only Look Once)</i>	14
2.7. <i>ResNet (Residual Network)</i>	15
2.8. <i>Arsitektur Cascaded</i>	17
2.9. <i>Confusion Matrix</i>	19
BAB III METODE PENELITIAN	21
3.1 Waktu dan Lokasi Penelitian.....	21
3.2 Benda Uji dan Alat	21
3.3 Tahapan Penelitian	22

3.4	Teknik Pengambilan Data	24
3.5	Perancangan dan Implementasi Sistem	25
BAB IV HASIL DAN PEMBAHASAN		49
4.1	Hasil Data <i>Preparation</i>	49
4.2	Hasil <i>Training Model</i>	51
4.3	Hasil <i>Testing</i>	60
4.4	Pembahasan	66
BAB V KESIMPULAN DAN SARAN		76
5.1	Kesimpulan.....	76
5.2	Saran	77
DAFTAR PUSTAKA		78
LAMPIRAN.....		82

DAFTAR GAMBAR

Gambar 1. Benih kelapa sawit bermutu/ unggul	5
Gambar 2. (a) radikula dan plumula membentuk sudut 90°; (b) plumula kerdil; (c) akar bercabang; (radikula dan plumula tidak berkembang; (e) radikula tidak berkembang.	6
Gambar 3. Arsitektur Umum <i>Convolutional Neural Network</i>	13
Gambar 4. Arsitektur YOLOv5	14
Gambar 5. <i>Identify Block</i> ResNet.	17
Gambar 6. Lokasi Penelitian	21
Gambar 7. Tahapan Penelitian.....	22
Gambar 8. Ilustrasi Pengambilan Data	24
Gambar 9. Alur Perancangan Sistem.....	25
Gambar 10. Contoh hasil seleksi <i>frame</i> : (a) <i>frame</i> digunakan; (b) <i>frame</i> tidak digunakan.....	26
Gambar 11. <i>Image Annotation</i>	27
Gambar 12. <i>Resize image</i>	27
Gambar 13. (a) Augmentasi <i>flip</i> , (b) Augmentasi 90 <i>rotate</i> dan (c) Augmentasi <i>rotation</i>	28
Gambar 14. Proses Konvolusi	31
Gambar 15. Perhitungan Matriks.....	32
Gambar 16. Hasil SiLU	34
Gambar 17. Ilustrasi Proses <i>Spatial Pyramid Pooling</i>	34
Gambar 18. Preprocessing untuk model CNN	36
Gambar 19. Ilustrasi Arsitektur ReNet18	37
Gambar 20. Proses Konvolusi	41
Gambar 21. Perhitungan matriks 6x6, kernel 3x3	41
Gambar 22. Hasil ReLU	42
Gambar 23. Proses <i>Max Pooling</i>	43
Gambar 24. Memilih <i>board</i> dan <i>port</i>	46
Gambar 25. <i>Source code</i> kecepatan <i>conveyor</i>	46
Gambar 26. Grafik hasil <i>training Learning rate</i> 0,001	53
Gambar 27. Grafik hasil <i>training Learning rate</i> 0,0001	53

Gambar 28. Grafik hasil <i>training</i> <i>Batch size</i> 8	54
Gambar 29. Grafik hasil <i>training</i> <i>Batch size</i> 16	54
Gambar 30. Grafik hasil <i>training</i> <i>Batch size</i> 32	55
Gambar 31. Grafik hasil <i>training</i> <i>Dropout</i> 0,3	56
Gambar 32. Grafik hasil <i>training</i> <i>Dropout</i> 0,5	56
Gambar 33. Grafik hasil <i>training</i> Skenario 1	57
Gambar 34. Grafik hasil <i>training</i> Skenario 2	58
Gambar 35. Grafik hasil <i>training</i> skenario 3	58
Gambar 36. Grafik hasil <i>training</i> skenario 4	59
Gambar 37. Grafik hasil <i>training</i> Skenario 5	59
Gambar 38. Grafik hasil <i>training</i> Skenario 6	60
Gambar 39. <i>heatmap</i> 3 kecambah yang salah klasifikasi: (a) kecambah ke-19, (b) kecambah ke-29 dan (c) kecambah ke-47	73
Gambar 40. Visualisasi PCA dan t-SNE	75

DAFTAR TABEL

Tabel 1. Skenario pengambilan data	25
Tabel 2. Hasil pengambilan data video	49
Tabel 3. Hasil <i>ekstraksi frame</i>	50
Tabel 4. Hasil <i>training</i> model YOLOv5	51
Tabel 5. Hasil <i>testing</i> sistem.....	61
Tabel 6. <i>Confusion Matrix</i>	66
Tabel 7. Hasil pengujian <i>learning rate</i>	68
Tabel 8. Hasil pengujian <i>batch size</i>	69
Tabel 9. Hasil pengujian <i>dropout</i>	69
Tabel 10. Hasil pengujian dari 6 skenario pengambilan data.....	70

DAFTAR SINGKATAN DAN ARTI SIMBOL

Lambang/Singkatan	Arti dan Keterangan
FPS	<i>Frame Per Second</i>
RPM	<i>Revolutions Per Minute</i>
TP	<i>True Positive</i>
TN	<i>True Negative</i>
FP	<i>False Positive</i>
FN	<i>False Negative</i>
YOLO	<i>You Only Look Once</i>
ResNet	<i>Residual Network</i>
ReLU	<i>Rectified Linear Unit</i>
CPO	<i>crude palm oil</i>
PANet	<i>Path Aggregation Network</i>
SPP	<i>Spatial Pyramid Pooling</i>
CSP	<i>Cross Stage Partial</i>
PCA	<i>Principal Component Analysis</i>
t-SNE	<i>t-distributed Stochastic Neighbor Embedding</i>

DAFTAR LAMPIRAN

Lampiran 1. Contoh Data Normal.....	82
Lampiran 2. Contoh Data Abnormal.....	83
Lampiran 3. Contoh <i>source code testing</i>	84
Lampiran 4. Lembar perbaikan skripsi.....	86

KATA PENGANTAR

Alhamdulillah, puji syukur kehadirat Allah SWT atas berkat rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan tugas akhir ini yang berjudul “Implementasi Visi Komputer Untuk Klasifikasi Kualitas Benih Kecambah Kelapa Sawit Menggunakan *Convolutional Neural Network* (CNN)” sebagai salah satu persyaratan yang harus dipenuhi dalam menyelesaikan jenjang Strata-1 pada Departemen Teknik Informatika Fakultas Teknik Universitas Hasanuddin. Sholawat serta salam kepada nabi Muhammad SAW yang telah menunjukkan dan mengajarkan akhlak mulia sehingga didapatkan kenyamanan dan keramahan dalam berhubungan dengan orang di sekitar.

Dengan segala kerendahan hati, penulis menyadari bahwa dalam penyusunan dan penulisan laporan tugas akhir ini tidak lepas dari bantuan, bimbingan serta dukungan dari berbagai pihak, dari masa perkuliahan sampai dengan masa penyusunan tugas akhir ini. Sehingga, pada kesempatan ini penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Allah SWT. Atas semua karunia serta pertolongan-Nya yang tiada batas, yang telah diberikan kepada penulis di setiap langkah dalam penelitian hingga penulisan laporan ini.
2. Kedua orang tua penulis, Bapak Tafsir S.ST, dan Ibu Nuraman yang selalu mendoakan untuk kebaikan penulis, selalu memberikan kasih sayang, cinta, dukungan dan motivasi. Terima kasih Bapak dan Ibu yang selalu sabar dan semangat tiada henti dalam menghadapi dan mendidik penulis.
3. Bapak Prof. Dr. Ir. Indrabayu, S.T., M.T., M.Bus.Sys., IPM., ASEAN.Eng., selaku pembimbing 1 yang senantiasa meluangkan waktu, tenaga dan pikiran serta perhatian yang luar biasa untuk membimbing penulis dalam proses penyelesaian tugas akhir ini.
4. Ibu Elly Warni, S.T., M.T., selaku dosen pendamping akademik yang senantiasa meluangkan waktu, tenaga dan pikiran dalam proses penyelesaian proses kuliah.
5. Segenap Dosen dan Staf Departemen Teknik Informatika Fakultas Teknik Universitas Hasanuddin yang telah memberikan ilmu dan pengetahuan baru, serta bantuan kepada penulis selama menuntut masa perkuliahan.
6. Segenap keluarga AIMP *Research Group* Universitas Hasanuddin, yang telah memberikan banyak bantuan selama penelitian dan teman diskusi terkait progres penyusunan tugas akhir.
7. Teman-Teman REZOLVER yang banyak membantu selama kuliah dan dalam proses menyelesaikan tugas akhir ini.
8. Keluarga besar RESPECT yang telah membantu dari SMA hingga sekarang ini.

9. Serta pihak-pihak lain yang tidak sempat disebutkan dan tanpa sadar telah membantu penulis dalam menyelesaikan tugas akhir.

Dengan rasa syukur dan kerendahan hati, penulis memberikan rasa hormat yang tak terhingga, semoga Allah SWT. membalas semua kebaikan dari semua pihak yang telah banyak membantu penulis dalam menyelesaikan tugas akhir ini. Penulis menyadari tugas akhir ini masih banyak kekurangan dan jauh dari kata sempurna. Oleh karena itu, penulis mengharapkan segala masukan dan saran yang membangun sehingga tugas akhir ini dapat memberi manfaat bagi penulis dan pembaca. Akhir kata, semoga tugas akhir ini dapat dijadikan sebagai sumber ilmu pengetahuan dan bermanfaat bagi penulis dan pembaca pada umumnya.

Makassar, 10 Oktober 2024

Penulis

BAB I

PENDAHULUAN

1.1 Latar Belakang

Minyak kelapa sawit adalah salah satu komoditas ekspor terbesar Indonesia dan memiliki peran besar dalam memenuhi kebutuhan dunia akan berbagai produk yang terbuat dari kelapa sawit, seperti makanan, bahan bakar, dan bahan kimia. Dilansir dari Badan Pusat Statistik (BPS) pada tahun 2021, nilai ekspor minyak kelapa sawit Indonesia mengalami perkembangan hingga 28,7 miliar USD dengan persentase peningkatan sebesar 53,4% jika dibandingkan tahun 2020. Selain itu, perkembangan luas areal dan produksi kelapa sawit juga meningkat signifikan pada tahun 2018 dengan luas areal pekebunan menjadi 14,33 juta hektar. Peningkatan ini membuat kelapa sawit menjadi komoditi pertanian terpenting di Indonesia, baik dilihat dari devisa yang dihasilkan maupun bagi pemenuhan akan kebutuhan minyak nabati di dalam negeri.

Berdasarkan potensi industri kelapa sawit di Indonesia yang begitu besar, perhatian akan mutu dan kualitas kelapa sawit menjadi sangat penting, seiring dengan kebutuhan penduduk dunia akan minyak kelapa sawit, maka diperlukan usaha peningkatan kualitas dan kuantitas produksi kelapa sawit secara tepat agar dapat mencapai sesuai sasaran. Pertumbuhan awal bibit ialah periode kritis yang sangat menentukan keberhasilan tanaman dalam mencapai pertumbuhan yang baik, dipembibitan pertumbuhan dan figur bibit tersebut sangat dipengaruhi oleh kecambah yang ditanam (Andika dkk., 2023). Data dari majalah sawit Indonesia pada tahun 2018 mengatakan permintaan pasar nasional untuk benih kelapa sawit adalah 87,7 juta benih.

Saat ini, klasifikasi benih kecambah kelapa sawit dilakukan secara manual, sehingga membutuhkan waktu yang cukup lama. Berdasarkan uraian Standard Operasional Prosedur (SOP) Manajemen Pembibitan pada tahun 2016 untuk seleksi 12.000 benih kecambah kelapa sawit diperlukan 8-10 hari kerja, dan hasil yang didapatkan kurang akurat karena bergantung pada bias penglihatan petani. Klasifikasi merupakan salah satu proses yang dapat dibantu dengan adanya teknologi. Dalam proses klasifikasi harus dilakukan secara cepat, teliti, tepat dan

dapat dipertanggung jawabkan, hal tersebut menjadi kunci keberhasilan dalam klasifikasi dikemudian hari.

Guna meningkatkan efisiensi dan meminimalisir kesalahan dalam proses klasifikasi, diperlukan sistem ter-standarisasi yang dapat melakukan klasifikasi benih kelapa sawit berdasarkan kecambah awal yang tumbuh secara otomatis dan dalam jumlah besar. Klasifikasi mutu kecambah kelapa sawit berpedoman pada Badan Standarisasi Nasional (BSN) dengan nomor SNI 8211:2015 di mana radikula dan plumula memiliki panjang minimal 0,5 cm, berwarna putih kekuningan, memiliki arah tumbuh berlawanan dan kenampakan dapat dibedakan dengan jelas.

Algoritma *Covolution Neural Network* (CNN) adalah salah satu algoritma yang sering digunakan dalam proses klasifikasi karena kemampuan untuk mengestraksi fitur-fitur penting dari gambar secara hierarkis (Aspiring Youth, 2023). Dari penelitian yang dilakukan oleh Noverina Ika Tama (2023), terkait klasifikasi kecambah benih padi dengan membandingkan algoritma *Supprot Vector Machine* (SVM) dengan *Convolutional Neural Network* (CNN) berbasis citra digital, didapatkan hasil testing algoritma SVM dengan akurasi sebesar 72,50%, sedangkan hasil testing algoritma CNN hasil akurasi sebesar 99,75%.

Penelitian terkait untuk klasifikasi benih kecambah kelapa sawit dilakukan oleh Liao, dkk., (2021) terkait kajian pendahuluan klasifikasi mutu benih kelapa sawit dengan *Convolutional Neural Network* (CNN). Dalam penelitian ini diusulkan 3 metode segmentasi bagian terutama berdasarkan operasi morfologi. Kombinasi *mask* digunakan untuk segmentasi sementara komponen bagian digunakan untuk memandu integrasi domain pengetahuan non-kuantifikasi dalam kualitas. Namun, penelitian ini hanya berfokus untuk mendeteksi benih kecambah kelapa sawit dan hanya menggunakan citra gambar sebagai *input*.

Berdasarkan uraian di atas, penulis mengajukan judul “**Implementasi Visi Komputer untuk Klasifikasi Kualitas Benih Kecambah Kelapa Sawit Menggunakan *Convolutional Neural Network* (CNN)**”, untuk membangun sistem yang dapat melakukan klasifikasi benih kecambah kelapa sawit dengan *computer vision* berbasis *belt conveyor* dan menggunakan algoritma *Convolutional Neural Network* yang mengklasifikasi benih kecambah kelapa sawit normal dan abnormal.

Sehingga sistem ini dapat digunakan untuk membantu efisiensi waktu dan tenaga pekerja, serta hasil klasifikasi yang akurat dan konsisten.

1.2 Rumusan Masalah

1. Bagaimana implementasi algoritma *Convolution Neural Network* dalam klasifikasi benih kecambah kelapa sawit?
2. Bagaimana hasil kinerja model klasifikasi kecambah kelapa sawit menggunakan *video processing*?

1.3 Tujuan Penelitian/perancangan

1. Mengimplementasikan algoritma *Convolution Neural Network* dalam klasifikasi kecambah kelapa sawit
2. Menganalisis kinerja model klasifikasi kecambah kelapa sawit menggunakan *video processing*.

1.4 Manfaat Penelitian/perancangan

Berdasarkan tujuan penelitian sebelumnya, penelitian ini diharapkan dapat memberikan manfaat bagi akademisi dan industri pertanian sebagai berikut:

1. Akademisi:

Diharapkan dapat menjadi referensi bagi akademisi maupun peneliti berikutnya dalam melakukan penelitian yang terkait dengan tema yang penulis teliti.

2. Industri Pertanian:

- Sebagai inovasi yang dapat meningkatkan kualitas dan konsistensi klasifikasi kecambah kelapa sawit.
- Dapat meningkatkan penggunaan teknologi visi komputer pada bidang pertanian.

1.5 Batasan Masalah

Pada penelitian ini akan dibatasi ruang lingkup pembahasannya yaitu:

1. Mengklasifikasi kecambah kelapa sawit berdasarkan bentuk dan ukuran dari radikula dan plumula berdasarkan mutu fisik standarisasi nasional.
2. Kecambah diklasifikasikan dalam 2 kelas yaitu normal dan abnormal
3. Data yang digunakan yaitu data citra berupa video dan gambar.
4. Kamera yang digunakan adalah kamera statis beresolusi tinggi, bukan auto fokus.

BAB II

TINJAUAN PUSTAKA

2.1 Kelapa Sawit

Kelapa sawit *Elaeis guineensis* Jacq., merupakan spesies tanaman famili *Arecaceae* yang dikenal sebagai komoditas utama dalam produksi minyak mentah kelapa sawit atau *crude palm oil* (CPO). CPO sering dimanfaatkan sebagai minyak goreng, sumber biodiesel dan bahan industri obat. Kelapa sawit telah menjadi komoditas unggulan Indonesia yang bernilai tinggi dan memberikan kontribusi besar terhadap pendapatan nasional dan devisa negara (Marpaung dkk., 2022). Permintaan benih kelapa sawit tumbuh mencapai 100-120 juta per tahun, sedangkan akseibilitas benih hanya mampu menghasilkan 60-70 juta bibit kelapa sawit sehingga permintaan pasar tidak akan pernah terpenuhi. Padahal Indonesia memiliki perkebunan kelapa sawit terbesar karena konstruksi tanah dan iklim yang sesuai untuk menanam kelapa sawit (Darmayanti dkk., 2023).

Berdasarkan Surat Keputusan Menteri Pertanian Nomor 833/KPTS/SR.020/M/12/2019, Indonesia memiliki lahan kelapa sawit seluas 16,38 juta hektar yang tersebar di 25 provinsi. Luas perkebunan kelapa sawit yang dikelola oleh rakyat mencakup 6,2 juta hektar. Hasil identifikasi pemerintah menunjukkan bahwa kapasitas sumber daya manusia (SDM) dalam mengelola perkebunan kelapa sawit masih rendah sehingga realisasi produksi perkebunan kelapa sawit dibandingkan potensi produksi lahan tergolong rendah (Satia dkk., 2022).

2.1.1 Budidaya Kelapa Sawit

Komponen penting dalam industri kelapa sawit adalah ketersediaan benih yang unggul. Pemeliharaan kecambah secara optimal dan melalui proses seleksi akan menghasilkan bibit tanaman yang bermutu. Bibit bermutu memiliki ciri morfologi yang normal, bebas hama dan penyakit serta memiliki kemampuan adaptasi lingkungan yang baik. Perkecambahan benih merupakan faktor penentu budidaya kelapa sawit dan langkah awal yang menentukan tingkat keberhasilan penanaman. Kesalahan bibit yang dipelihara akan menimbulkan kerugian selama usia tanaman kelapa sawit yang mencapai 20-25 tahun. Oleh karena itu, peningkatan produksi benih tidak boleh mengabaikan setiap mutu benih untuk menghindari kerugian (Gustrianda dkk., 2021).

2.1.2 Benih Kecambah Kelapa Sawit

Benih kelapa sawit memerlukan waktu relatif lama untuk berkecambah dengan persentase perkecambahan rendah dan tidak seragam (Martine dkk., 2011; Nazario dkk., 2013; Sudsiri dkk., 2016; Groot, 2020; Agustiansyah dkk., 2020) karena benih kelapa sawit mengalami dormansi secara morfologis dan fisiologis. Dormansi pada benih kelapa sawit disebabkan adanya struktur *germpore* yakni *operculum* yang menutupi embrio sehingga radikula dan plumula kesulitan keluar dari cangkang benih (Agustiansyah dkk., 2020). Benih kelapa sawit umumnya berkecambah pada rentang 7-42 hari setelah germinasi. Semakin lama hari yang dibutuhkan untuk perkecambahan maka semakin kecil nilai indeks kecambahanya. Hal tersebut berkaitan dengan viabilitas benih tersebut karena benih yang membutuhkan waktu yang relatif lama untuk berkecambah dapat disebabkan oleh embrio yang masih dorman atau benih sudah mati (Gustrianda dkk., 2021).



Gambar 1. Benih kelapa sawit bermutu/ unggul
(Sumber: Elidar dan Purwati, 2021)

Pemilihan benih sawit yang baik dan benar dilakukan dengan meninjau kriteria standar kecambah kelapa sawit yang berkualitas yaitu; (a) berat biji 0,8 g, (b) panjang plumula dan radikula sekitar 2 cm, (c) plumula dan radikula memiliki arah tumbuh yang berlawanan, (d) plumula dan radikula berwarna putih agak kekuningan dan tidak lunak, (e) plumula dan radikula dapat dibedakan secara jelas (Elidar dan Purwati, 2021). Produsen benih umumnya memberikan perlakuan yang sama terhadap semua benih pada proses produksi. Misalnya pada tahap *chopping*, produsen tidak memisahkan antara buah matang dan belum matang, padahal tingkat kematangan buah kelapa sawit berbeda jika ditinjau dari letak buah. Kaida dan Zulkifli (1992) menyebutkan bahwa buah sawit memiliki waktu kematangan yang berbeda, bagian yang matang lebih dahulu adalah bagian ujung (*apical*) lalu bagian tengah tandan (*equatorial*) dan terakhir bagian bawah (*basal*). Selain itu, pada

proses perendaman, keseluruhan benih direndam pada selama durasi yang sama sehingga dapat diasumsikan terdapat benih yang proses imbibisinya tidak optimal. Perbedaan mutu benih tersebut mengakibatkan tidak semua benih bermutu tinggi karena dapat muncul benih abnormal dengan persentase dapat mencapai 30% dalam satu tandan benih. Berikut adalah beberapa tipe kecambah abnormal pada kelapa sawit (Gustrianda dkk., 2021).



Gambar 2. (a) radikula dan plumula membentuk sudut 90°; (b) plumula kerdil; (c) akar bercabang; (d) radikula dan plumula tidak berkembang; (e) radikula tidak berkembang.

(Sumber: Gustrianda dkk., 2021)

2.2 *Artificial Intelligence*

Artificial Intelligence (AI) dapat didefinisikan sebagai cabang ilmu yang berhubungan dengan pembangunan sistem komputer yang mampu menunjukkan kecerdasan dalam berbagai aspek. AI melibatkan kemampuan sistem untuk melakukan tugas-tugas yang sebelumnya hanya mampu dilakukan manusia mencakup keahlian analisis, pengolahan informasi *visual* dan *auditif*, kemampuan berbicara, dan berbagai keterampilan lainnya. Proses pembelajaran pada AI disebut dengan *learning*. Pada cabang AI, terdapat proses pembelajaran rinci yang disebut *Deep Learning*. Implementasi *Artificial Intelligence* sering melibatkan penggunaan algoritma tertentu yang mendukung sistem AI dalam menganalisis dan memproses data serta memahami pola data tersebut dengan cepat dan efisien (Sevia dkk., 2023).

Revolusi Industri 4.0 dengan *Artificial Intelligence* telah mendorong pertanian presisi ke tingkat lebih lanjut (*next generation precision farming*). Salah satu fokus dalam penerapan pertanian presisi adalah pemanfaatan teknologi yang dapat mengklasifikasi (*clasification*), mengelompokkan (*clustering*), mengestimasi (*estimation*), dan memprediksi (*forecasting*) segala komponen dalam bidang pertanian (Syarovy dkk., 2023).

2.2.1. Machine Learning

Machine Learning (ML) adalah cabang dari *Artificial Intelligence* (AI) yang memungkinkan sistem komputer untuk belajar dari data dan membuat keputusan atau prediksi tanpa perlu diprogram secara eksplisit. ML berfokus pada pengembangan algoritma dan model yang mampu mengenali pola dalam data dan meningkatkan kinerja berdasarkan pengalaman. Proses pembelajaran dalam ML biasanya melibatkan data *training* berlabel, di mana model dilatih untuk mempelajari hubungan antara *input* dan *output* (Sukarna dkk., 2024).

ML dapat dibagi menjadi tiga kategori utama: *supervised learning*, *unsupervised learning*, dan *reinforcement learning* (Alzubaidi dkk., 2021). Dalam *supervised learning*, model dilatih menggunakan data berlabel, yang berarti setiap *input* memiliki *output* yang sesuai. Metode ini sering digunakan dalam tugas-tugas seperti klasifikasi dan regresi. *Unsupervised learning*, di sisi lain, bekerja dengan data yang tidak berlabel, dan algoritma mencoba menemukan struktur atau pola tersembunyi dalam data. *Clustering* dan *dimensionality reduction* adalah contoh aplikasi dari *unsupervised learning*. *Reinforcement learning* melibatkan pembelajaran berdasarkan umpan balik dari lingkungan, di mana agen belajar untuk membuat keputusan yang memaksimalkan imbalan kumulatif (Li, 2017).

Salah satu cabang dari *artificial intelligence* adalah *machine learning* yang berkaitan dengan pengembangan algoritma dan model komputer yang mampu belajar dan meningkatkan kinerja dari data tanpa diprogram secara eksplisit. *Machine learning* memungkinkan komputer untuk mengidentifikasi pola, mengambil keputusan, dan memprediksi berdasarkan data yang tersedia menggunakan metode statistik (Rahmadani dkk., 2023). Aplikasi utama dari *machine learning* adalah klasifikasi dan prediksi. Ciri khas dari *machine learning* adalah adanya proses pelatihan atau data *training* yang menyebabkan *machine*

learning membutuhkan data untuk dipelajari. Salah satu algoritma yang banyak digunakan untuk mengolah data citra dua dimensi dengan *machine learning* adalah *Convolutional Neural Network* (CNN). *Machine learning* dapat dimanfaatkan dalam *computer vision* untuk melakukan *object detection* dan *image classification* dengan menggunakan algoritma *Convolutional Neural Network* (CNN) (Asrianda dkk., 2021).

Seiring dengan perkembangan teknologi dan ketersediaan data yang semakin besar, ML telah diterapkan di berbagai bidang, termasuk pengenalan gambar, pemrosesan bahasa alami, diagnosis medis, dan kendaraan otonom (Zou dkk., 2019). Dalam penelitian ini, ML digunakan untuk klasifikasi kualitas benih kecambah kelapa sawit dengan menggunakan algoritma CNN, yang merupakan salah satu algoritma yang sangat populer dalam pengolahan citra.

2.2.2. Deep Learning

Deep learning merupakan sub-bagian dari *machine learning* yang menggunakan algoritma berbasis matematika dan bekerja menyerupai sistem otak manusia melalui *neural networks* yang dalam (Zulkarnain dkk., 2023). Algoritma *deep learning* dirancang untuk mengekstraksi fitur-fitur penting dari data dalam jumlah besar secara otomatis, yang menjadikannya sangat efektif dalam menangani masalah-masalah kompleks, terutama dalam pengolahan citra digital (*image processing*). *Deep learning* mampu mengenali dan mengklasifikasikan objek dengan efisiensi tinggi dan mampu memproses data dalam jumlah besar secara bersamaan (Maulana dan Rochmawati, 2019).

Sebagai bagian dari *machine learning*, *deep learning* menggunakan *deep neural networks* (DNN), yang merupakan jaringan neural dengan banyak lapisan tersembunyi (*hidden layers*). Jaringan ini memungkinkan pemodelan relasi yang lebih kompleks antara *input* dan *output*, menjadikan *deep learning* sebagai metode yang sangat kuat dalam pengenalan pola, klasifikasi, dan prediksi (Luchman dkk., 2022). Pada umumnya, performa *deep learning* sangat bergantung pada kualitas data, jumlah data, pemilihan *hyperparameter*, dan teknik akuisisi data yang digunakan. Dengan jumlah data yang besar dan variatif, *deep learning* dapat mencapai akurasi tinggi dan mengurangi risiko *overfitting*, sebuah masalah umum dalam pemodelan *machine learning* (Chen dkk., 2020).

Dalam beberapa tahun terakhir, perkembangan *deep learning* telah memberikan dampak signifikan dalam berbagai aplikasi, termasuk pengenalan gambar, deteksi objek, analisis video, dan pengolahan bahasa alami (Nwankpa dkk., 2018). Dengan kemampuan untuk mempelajari fitur secara hierarkis dari data yang tidak terstruktur, *deep learning* menjadi pilihan utama untuk berbagai tugas pengenalan pola dan klasifikasi di bidang industri dan akademik.

2.3 Visi Komputer

Visi komputer adalah bidang ilmu yang menggabungkan teknologi kecerdasan buatan (AI), pembelajaran mesin (*Machine Learning*), pembelajaran mendalam (*Deep Learning*), dan *Convolutional Neural Networks* (CNN) untuk memungkinkan komputer "melihat" dunia, menganalisis data visual, dan membuat keputusan berdasarkan informasi tersebut (Ananto dkk., 2023). Pada intinya, visi komputer mencoba meniru cara kerja sistem visual manusia (*human vision*), di mana mata manusia memproses informasi visual dengan baik melalui jaringan saraf yang kompleks.

Proses visi komputer umumnya bersifat berulang dan dimulai dengan memasukkan data visual (*scene*) yang kemudian mengalami peningkatan kualitas melalui teknik *pre-processing* seperti penyesuaian kontras, peningkatan kecerahan, dan pengurangan *noise*. Tahap ini bertujuan untuk mempersiapkan data visual agar lebih mudah diproses pada tahap selanjutnya. Setelah itu, fitur-fitur dari data tersebut diekstraksi melalui langkah *feature extraction* untuk memperoleh informasi yang relevan, seperti tepi, sudut, tekstur, dan bentuk, yang penting untuk identifikasi objek (Li, 2022).

Hasil dari ekstraksi fitur ini kemudian diinterpretasikan melalui berbagai algoritma untuk membantu mengidentifikasi dan mengklasifikasikan objek yang terdapat dalam gambar. Interpretasi fitur ini membantu dalam membedakan kelas-kelas objek berdasarkan karakteristik visual yang telah diekstraksi. *Output* akhir dari visi komputer bisa berupa model dua dimensi (2D) atau tiga dimensi (3D). Model 2D digunakan dalam aplikasi seperti pengenalan wajah atau plat nomor kendaraan, di mana gambar diproses hanya dalam dua sumbu, yaitu x dan y. Sebaliknya, model 3D digunakan dalam aplikasi yang membutuhkan informasi tentang kedalaman atau jarak antara objek dalam suatu lingkungan, seperti dalam

robotika, pemetaan lingkungan, atau realitas virtual, yang melibatkan sumbu x, y, dan z untuk memberikan representasi ruang yang lebih lengkap (Yoshikai Shiari, 1987; Wang dkk., 2023).

Dengan demikian, visi komputer tidak hanya menjadi salah satu penelitian menarik dalam bidang kecerdasan buatan, tetapi juga memiliki penerapan luas dalam berbagai bidang teknologi modern, seperti pengawasan keamanan, sistem kendaraan otonom, dan aplikasi *augmented reality* (Krishna, 2017). Dalam konteks penerapan di sektor pertanian, visi komputer memungkinkan deteksi dan klasifikasi objek seperti tanaman, membantu dalam pemantauan pertumbuhan dan mendeteksi hama atau penyakit tanaman, yang kemudian dapat memandu intervensi yang lebih tepat untuk mengurangi kerugian (Ananto dkk., 2023).

Selain itu, konsep menganalisis citra pada visi komputer mencakup beberapa proses seperti akuisisi citra, pra-pemrosesan, ekstraksi fitur, dan pengenalan objek. Akuisisi merupakan proses pengumpulan data citra menggunakan perangkat atau media seperti kamera, sensor, dan perangkat lain yang dapat mengumpulkan data visual. Kualitas data citra sangat mempengaruhi hasil analisis, sehingga penting untuk memastikan kualitas data visual melalui proses pra-pemrosesan, seperti normalisasi intensitas, perbaikan kontras, dan pengurangan *noise*, untuk menghilangkan data yang tidak sesuai dengan kriteria yang ditentukan. Ekstraksi fitur merupakan proses mengekstraksi pola atau fitur dari citra, seperti tepi, warna, tekstur, yang berguna dalam mengklasifikasikan objek dalam citra tersebut. Pengenalan objek kemudian melibatkan klasifikasi objek atau pola dari fitur-fitur yang diekstraksi sebelumnya menggunakan model pembelajaran mesin seperti *neural network* dan algoritma klasifikasi.

2.4 Video Processing

Video processing, atau pemrosesan video, merupakan proses manipulasi, analisis, dan transformasi sinyal video digital yang bertujuan untuk meningkatkan kualitas video, mendeteksi objek, menganalisis gerakan, hingga mengenali pola dalam video. Dalam penerapannya, *video processing* memungkinkan ekstraksi informasi penting dari data video sehingga menghasilkan *output* yang lebih informatif dan bermakna. Beberapa tahapan utama dalam *video processing* meliputi

preprocessing, segmentation, feature extraction, object detection and recognition, motion analysis, compression, dan post-processing.

Tahap *preprocessing* bertujuan untuk meningkatkan kualitas video melalui penghapusan noise, penyesuaian kontras, koreksi warna, dan peningkatan ketajaman gambar (Bovik, 2010). *Segmentation*, sebagai tahap berikutnya, berfungsi untuk memisahkan objek atau area penting dari latar belakang, menggunakan teknik seperti *thresholding* dan *edge detection* (Gonzalez dan Woods, 2008). Selanjutnya, pada tahap *feature extraction*, fitur-fitur penting dari objek atau area yang telah disegmentasi, seperti bentuk, tekstur, dan gerakan, diekstraksi untuk mendukung proses pengenalan pola dan klasifikasi objek (Sonka dkk., 2014).

Proses *object detection and recognition* melibatkan deteksi objek tertentu dalam video serta pengenalan dan klasifikasi objek tersebut. Teknik *deep learning* seperti *Convolutional Neural Network* (CNN) sering digunakan dalam proses ini karena kemampuannya yang tinggi dalam belajar dari data (Goodfellow, Bengio, dan Courville, 2016). Pada *motion analysis*, analisis gerakan objek dilakukan untuk mendeteksi dan melacak pergerakan serta menganalisis jalur gerak objek dalam video, menggunakan teknik seperti optical flow (Trucco dan Verri, 1998). Proses *compression* bertujuan untuk mengurangi ukuran file video guna menghemat ruang penyimpanan atau mempercepat transmisi data, dengan menggunakan teknik kompresi seperti MPEG, H.264, dan HEVC (Richardson, 2010). Terakhir, tahap *post-processing* digunakan untuk menyempurnakan hasil pemrosesan, seperti peningkatan kualitas gambar hasil kompresi dan penambahan efek visual (Brandi dan Dufaux, 2016).

Video processing memiliki berbagai aplikasi yang signifikan di berbagai bidang, termasuk pengawasan keamanan, sistem otomotif, kesehatan, multimedia, dan olahraga. Misalnya, dalam sistem pengawasan keamanan, *video processing* digunakan untuk mendeteksi perilaku mencurigakan dan melacak pergerakan orang atau objek. Dalam industri otomotif, teknologi ini digunakan dalam *Advanced Driver Assistance System* (ADAS) untuk mendeteksi rambu lalu lintas, pejalan kaki, dan kendaraan lain. Di bidang kesehatan, *video processing* diterapkan dalam endoskopi dan radiologi untuk mendeteksi dan menganalisis kelainan medis. Selain

itu, kompresi video sangat penting untuk memungkinkan streaming video berkualitas tinggi di internet, seperti pada platform YouTube dan Netflix. Dalam dunia olahraga, analisis video digunakan untuk melacak dan menganalisis kinerja atlet selama pertandingan atau latihan.

Dengan kemajuan teknologi seperti *deep learning* dan komputasi paralel, *video processing* telah berkembang menjadi alat yang sangat penting dalam berbagai aplikasi industri dan penelitian, menjadikannya topik yang relevan dan signifikan dalam konteks akademik dan profesional.

2.5 *Convolutional Neural Network (CNN)*

Convolutional Neural Network (CNN) adalah jenis *deep learning* yang dirancang khusus untuk pemrosesan data dua dimensi, seperti gambar. CNN telah terbukti sangat efektif dalam berbagai aplikasi pengenalan gambar dan objek karena kemampuannya dalam mengekstraksi fitur-fitur penting dari gambar secara hierarkis. Model CNN terdiri dari beberapa lapisan utama, yaitu *Convolutional Layer*, *Activation Function*, *Pooling Layer*, dan *Fully Connected Layer*, yang bekerja bersama-sama untuk mendeteksi dan mengenali objek dalam gambar (Asrianda dkk., 2021).

Convolutional Layer adalah lapisan pertama dalam arsitektur CNN yang berfungsi sebagai penerima *input* berupa matriks dua dimensi, seperti gambar. Pada lapisan ini, filter (atau kernel) digunakan untuk melakukan operasi konvolusi terhadap matriks *input*, menghasilkan peta fitur (*feature map*) yang mengekstraksi fitur-fitur lokal seperti tepi, sudut, dan tekstur. *Stride*, yang merupakan jumlah pergeseran filter selama konvolusi, dapat diatur untuk menentukan seberapa jauh filter bergerak dalam matriks *input*. *Padding* digunakan untuk menjaga ukuran piksel tetap konsisten dengan menambahkan nilai 0 di sekitar tepi *input* (Imaduddin & Suharsono, 2023).

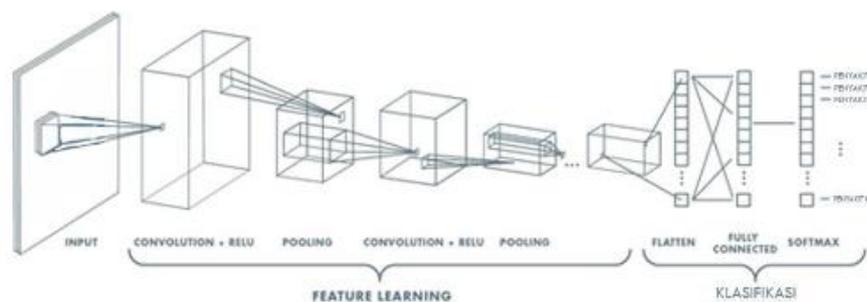
Setelah peta fitur dihasilkan oleh *convolutional layer*, fungsi aktivasi diterapkan untuk menambahkan non-linearitas ke model, memungkinkan jaringan untuk belajar pola yang lebih kompleks. Salah satu fungsi aktivasi yang paling umum digunakan adalah *Rectified Linear Unit (ReLU)*, yang menggantikan nilai negatif pada peta fitur dengan nilai nol, sehingga meningkatkan kecepatan dan efisiensi proses pelatihan. Selain ReLU, terdapat juga fungsi aktivasi seperti

softmax, yang digunakan di lapisan akhir CNN untuk mengubah *output* menjadi probabilitas yang dapat digunakan untuk klasifikasi (Triyogi dkk., 2023).

Pooling Layer adalah lapisan yang digunakan untuk mengurangi dimensi peta fitur yang dihasilkan oleh *convolutional layer*. Proses ini dikenal sebagai *downsampling*, yang bertujuan untuk mengurangi jumlah parameter dan mempercepat komputasi dalam jaringan. Metode *pooling* yang sering digunakan adalah *max pooling*, di mana nilai tertinggi dalam lingkup matriks yang diatur dipilih, dan *average pooling*, di mana nilai rata-rata dari matriks yang diatur dikalkulasi. *Pooling* membantu dalam mengurangi kemungkinan *overfitting* dan mempertahankan informasi penting dari peta fitur (Imaduddin & Suharsono, 2023).

Setelah melalui serangkaian *convolutional*, *activation*, dan *pooling layer*, peta fitur diratakan menjadi vektor satu dimensi yang kemudian diumpungkan ke *fully connected layer*. Lapisan ini terdiri dari beberapa neuron yang saling terhubung, yang bertugas untuk mengintegrasikan informasi yang diekstraksi oleh lapisan-lapisan sebelumnya dan menghasilkan *output* akhir berupa probabilitas untuk setiap kelas dalam tugas klasifikasi. *Output* dari *fully connected layer* ini kemudian diteruskan ke lapisan *softmax* untuk menentukan kelas objek berdasarkan probabilitas tertinggi (Imaduddin & Suharsono, 2023).

Mengingat efektivitasnya, CNN digunakan dalam penelitian ini untuk mengklasifikasikan kualitas benih kecambah kelapa sawit, di mana CNN mengekstraksi fitur dari *frame* video yang direkam selama proses. Arsitektur model CNN ini disesuaikan dengan mengatur *hyperparameter* seperti ukuran kernel, *strides*, *padding*, dan jenis *pooling* untuk mencapai performa optimal (Asrianda dkk., 2021).



Gambar 3. Arsitektur Umum *Convolutional Neural Network*
(Sumber: Asrianda dkk., 2021)

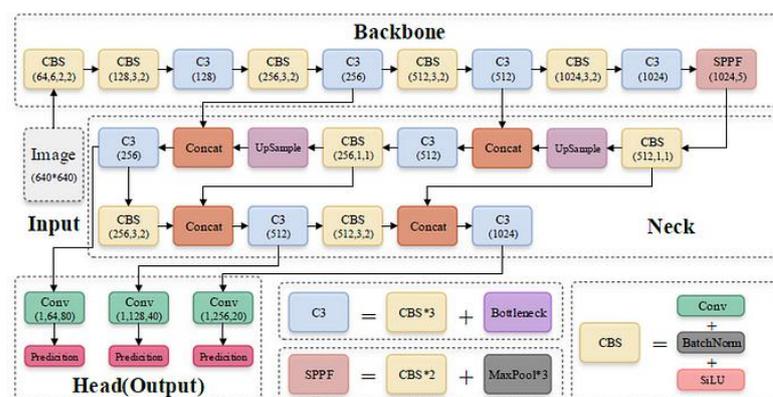
CNN telah banyak digunakan dalam berbagai penelitian dan aplikasi, salah satunya adalah deteksi penyakit pada tanaman jagung yang menunjukkan tingkat akurasi sebesar 99% (Hidayat, Darusalam, & Irmawati, 2019). Keunggulan utama CNN adalah kemampuannya untuk mengatasi perubahan gambar *input* seperti rotasi, translasi, dan skala, serta efisiensinya dalam mengurangi jumlah parameter bebas (Anggraeni dkk., 2022).

2.6 YOLO (You Only Look Once)

2.6.1. Arsitektur YOLO

YOLO (*You Only Look Once*) adalah arsitektur *Convolutional Neural Network* (CNN) yang dirancang khusus untuk deteksi objek secara *real-time*. Berbeda dengan pendekatan deteksi objek tradisional yang biasanya memerlukan dua langkah terpisah (*region proposal* dan klasifikasi), YOLO menggabungkan kedua langkah tersebut menjadi satu, di mana gambar *input* dibagi menjadi *grid*, dan setiap *grid cell* memprediksi *bounding box*, *confidence score*, dan kelas objek sekaligus (Redmon dkk., 2016).

Arsitektur YOLO telah mengalami beberapa iterasi dan perbaikan sejak pertama kali diperkenalkan. YOLOv5, sebagai versi terbaru yang dikembangkan oleh Ultralytics, memperkenalkan berbagai optimasi seperti penggunaan *Cross Stage Partial Networks* (CSP), *Path Aggregation Network* (PANet), dan *Spatial Pyramid Pooling* (SPP). CSP bertujuan untuk mengurangi jumlah parameter tanpa mengorbankan akurasi, PANet digunakan untuk meningkatkan penggabungan fitur dari berbagai level, dan SPP berfungsi untuk menangkap informasi dari berbagai skala pada gambar (Jocher, 2020).



Gambar 4. Arsitektur YOLOv5
(Sumber: Sik Ho Tsang (2023)).

Gambar di atas ini menunjukkan arsitektur lengkap dari YOLOv5, yang dimulai dari pengolahan *input* melalui beberapa lapisan konvolusi, kemudian disaring melalui blok CSP dan SPP untuk menangkap detail pada berbagai skala. PANet kemudian digunakan untuk menggabungkan fitur dari berbagai level jaringan sebelum hasil akhirnya diberikan ke *detection head* untuk memprediksi *bounding boxes* dan kelas objek.

2.6.1. Penerapan YOLO dalam Deteksi Objek

YOLO telah digunakan dalam berbagai aplikasi deteksi objek di banyak bidang, termasuk keamanan, transportasi, dan pertanian. Di Indonesia, penerapan YOLO juga semakin berkembang, terutama dalam bidang pertanian untuk mendeteksi dan mengklasifikasikan berbagai jenis tanaman dan produk pertanian.

Dalam konteks penelitian ini, YOLO digunakan untuk mendeteksi benih kecambah kelapa sawit. Model YOLOv5 dilatih untuk mengenali benih kelapa sawit yang normal dan abnormal dari video yang direkam selama proses di atas *conveyor*. Setelah deteksi, gambar yang mengandung benih kemudian diproses lebih lanjut menggunakan model ResNet18 untuk klasifikasi lebih mendetail. Kecepatan dan akurasi YOLO dalam mendeteksi objek secara *real-time* membuatnya sangat cocok untuk aplikasi ini, di mana setiap frame dari video diproses untuk memastikan setiap benih diklasifikasikan dengan benar (Putra dkk., 2022).

2.7 ResNet (*Residual Network*)

Residual Network (ResNet) adalah arsitektur desain *Convolutional Neural Network* (CNN) yang diperkenalkan oleh He dkk pada tahun 2016. Arsitektur ini dirancang untuk mengatasi masalah *vanishing gradient* yang sering terjadi pada jaringan yang sangat dalam, terutama saat pelatihan *deep learning* yang memakan waktu cukup lama dan terbatas pada jumlah lapisan tertentu.

2.7.1 Arsitektur ResNet

Arsitektur ResNet hadir dengan konsep dasar yang sederhana namun efektif: setiap lapisan mempelajari *residual* atau selisih antara *output* yang diinginkan dan *output* dari lapisan sebelumnya. Hal ini memungkinkan pelatihan jaringan yang lebih dalam tanpa mengalami masalah seperti *vanishing gradient* yang biasanya muncul dalam jaringan tradisional.

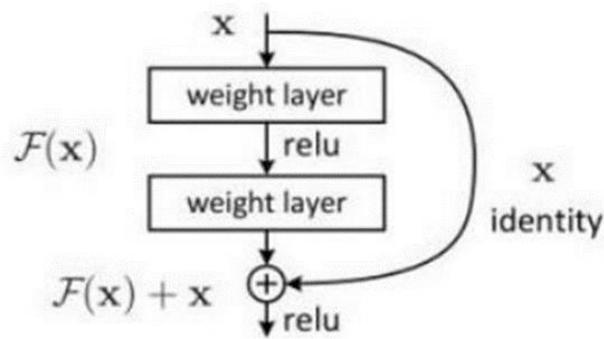
Arsitektur ResNet memiliki ciri khas pada implementasi *skip connection* atau *shortcut*, yang memungkinkan *input* awal dilewatkan langsung ke lapisan berikutnya tanpa mengalami perubahan. *Skip connection* ini berfungsi untuk menjaga informasi penting tetap tersedia saat jaringan semakin dalam, sehingga pelatihan tidak jenuh dan menghindari kesalahan yang cukup tinggi. Desain jaringan ini terdapat pada lapisan identitas atau *identity block* ResNet (Sujatmiko dkk., 2022).

ResNet terdiri dari beberapa varian yang dibedakan berdasarkan jumlah lapisan yang digunakan, seperti ResNet-18, ResNet-34, ResNet-50, ResNet-101, dan ResNet-152. Dua lapisan awal dari arsitektur ResNet menyerupai GoogleNet dengan melakukan *convolution* 7×7 dan *max pooling* berukuran 3×3 . Salah satu keunggulan utama dari ResNet dibandingkan dengan arsitektur CNN lainnya adalah kinerjanya yang tidak menurun meskipun arsitekturnya semakin dalam. Selain itu, ResNet juga memiliki perhitungan komputasi yang lebih ringan dan kemampuan untuk melatih jaringan dengan lebih baik (Sujatmiko dkk., 2022).

2.7.2 *Skip Connections*

Skip connections, juga dikenal sebagai *shortcut connections*, adalah fitur utama yang membedakan ResNet dari arsitektur neural network lainnya. *Skip connections* memungkinkan *input* awal dilewatkan langsung ke lapisan berikutnya tanpa mengalami perubahan, dengan tujuan menjaga informasi penting tetap tersedia saat jaringan semakin dalam.

Fungsi dari *skip connections* adalah untuk mengatasi masalah *vanishing gradient* dengan menjaga aliran informasi tetap stabil, bahkan saat jaringan bertambah dalam. Dengan cara ini, *skip connections* membantu mencegah jaringan dari menjadi jenuh, sebuah kondisi di mana penambahan lapisan tidak lagi meningkatkan kinerja jaringan. Implementasi *skip connections* pada ResNet ditunjukkan pada gambar 5, yang mengilustrasikan sebuah *identity block* dengan dua lapisan konvolusi dan aktivasi ReLU.



Gambar 5. *Identify Block* ResNet.
(Sujatmiko dkk., 2022)

Dalam praktiknya, *skip connections* memungkinkan ResNet untuk mencapai performa yang lebih baik pada berbagai tugas, termasuk klasifikasi citra, dengan jaringan yang sangat dalam.

2.7.3 Penerapan ResNet dalam Klasifikasi

ResNet telah diterapkan secara luas dalam berbagai tugas klasifikasi citra, baik dalam konteks akademis maupun industri. Di Indonesia, penggunaan ResNet telah berkembang pesat, terutama dalam bidang pertanian, kesehatan, dan teknologi. Sebagai contoh, penelitian oleh Nugroho dkk. (2021) menunjukkan bahwa ResNet dapat digunakan untuk klasifikasi citra penyakit tanaman dengan akurasi yang tinggi.

Dalam konteks penelitian ini, ResNet-18 digunakan untuk klasifikasi kualitas benih kecambah kelapa sawit setelah deteksi awal dilakukan menggunakan YOLOv5. ResNet-18 dipilih karena kombinasi antara kedalaman yang moderat dan kinerja yang efisien, menjadikannya pilihan yang ideal untuk tugas-tugas klasifikasi yang memerlukan akurasi tinggi dengan sumber daya komputasi yang terbatas.

2.8 Arsitektur *Cascaded*

Arsitektur *cascaded* adalah pendekatan yang menggabungkan kekuatan dua model atau lebih dalam suatu sistem untuk mencapai hasil yang lebih baik dalam tugas-tugas seperti deteksi objek dan klasifikasi. Dalam penelitian ini, arsitektur *cascaded* yang digunakan melibatkan model YOLO (*You Only Look Once*) untuk deteksi objek dan ResNet (*Residual Network*) untuk klasifikasi lebih lanjut. Kombinasi kedua model ini memungkinkan sistem untuk mendeteksi dan

mengklasifikasikan objek dengan akurasi tinggi, yang sangat penting dalam aplikasi seperti pengenalan kualitas benih kecambah kelapa sawit.

2.8.1 Konsep Arsitektur *Cascaded*

Arsitektur *cascaded* adalah pendekatan di mana dua model atau lebih digunakan secara berurutan untuk menyelesaikan tugas yang kompleks. Dalam konteks ini, model YOLO digunakan pertama kali untuk mendeteksi objek dalam gambar atau video, dan hasil deteksi ini kemudian diteruskan ke model ResNet untuk klasifikasi lebih lanjut. Konsep ini memanfaatkan keunggulan YOLO dalam deteksi objek *real-time* dan keakuratan ResNet dalam klasifikasi citra. Penelitian oleh Maulana dan Rochmawati (2021) menunjukkan efektivitas arsitektur *cascaded* ini dalam aplikasi deteksi dan klasifikasi berbagai jenis produk pertanian.

2.8.2 Implementasi YOLO untuk Deteksi Objek

YOLO (*You Only Look Once*) adalah model deteksi objek yang sangat populer karena kemampuannya dalam mendeteksi objek secara *real-time* dengan akurasi yang tinggi. Dalam arsitektur *cascaded* ini, YOLO digunakan untuk mendeteksi objek yang menjadi target klasifikasi, yaitu benih kecambah kelapa sawit. Model YOLOv5 dipilih karena optimasinya yang lebih baik dalam hal kecepatan dan akurasi dibandingkan versi YOLO sebelumnya (Jocher, 2020).

YOLO membagi gambar atau video *input* menjadi *grid* dan melakukan prediksi *bounding box*, *confidence score*, dan kelas objek secara bersamaan. Dalam penelitian ini, YOLO dilatih untuk mendeteksi benih kecambah kelapa sawit dalam berbagai kondisi, seperti perbedaan pencahayaan dan posisi kamera. Hasil deteksi YOLO yang berupa *bounding box* kemudian digunakan sebagai *input* untuk model ResNet, yang akan melakukan klasifikasi lebih lanjut terhadap objek yang terdeteksi (Putra dkk., 2022).

2.8.3 Penggunaan ResNet untuk Klasifikasi Lebih Lanjut

Setelah objek berhasil dideteksi oleh YOLO, langkah selanjutnya dalam arsitektur *cascaded* ini adalah melakukan klasifikasi lebih lanjut menggunakan ResNet (*Residual Network*). ResNet dikenal karena kemampuannya dalam mengatasi masalah *vanishing gradient* dan tetap menjaga kinerja jaringan yang dalam (He dkk., 2016). ResNet menggunakan *skip connections* yang

memungkinkan *input* dari satu lapisan diteruskan langsung ke lapisan berikutnya tanpa perubahan, menjaga informasi penting tetap utuh selama proses pelatihan.

Pada tahap ini, *frame* atau gambar yang mengandung objek yang terdeteksi oleh YOLO diproses oleh ResNet untuk mengklasifikasikan objek tersebut sebagai benih kecambah kelapa sawit normal atau abnormal. ResNet yang digunakan dalam penelitian ini adalah ResNet-18, yang merupakan salah satu varian ResNet dengan arsitektur yang lebih ringan namun tetap mempertahankan akurasi tinggi. Penggunaan ResNet dalam arsitektur *cascaded* ini meningkatkan akurasi sistem secara keseluruhan, memastikan bahwa setiap benih kecambah diklasifikasikan dengan tepat berdasarkan fitur-fitur yang diekstraksi oleh jaringan (Sujatmiko, Wahyudi, & Gunawan, 2022).

2.9 Confusion Matrix

Confusion Matrix merupakan komponen yang berfungsi untuk mengukur performa model atau tingkat akurasi dari suatu model klasifikasi terhadap masing-masing kelas yang diberikan. *Confusion matrix* memiliki baris sebagai kelas prediksi dan kolom sebagai kelas sebenarnya. Beberapa nilai yang dihasilkan pada proses berikut mencakup akurasi, *precision*, *recall* dan *f1-score* (Triyogi dkk., 2023).

2.9.1 Akurasi

Accuracy menggambarkan seberapa akurat model dapat mengklasifikasikan dengan benar. Maka, *Accuracy* merupakan rasio prediksi benar (positif dan negatif) dengan keseluruhan data. Dengan Kata lain, *Accuracy* merupakan tingkat kedekatan nilai prediksi dengan nilai aktual (Kurniawan dkk., 2023). Nilai *accuracy* dapat diperoleh dengan persamaan berikut.

$$\text{accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

2.9.2 Presisi

Precision menggambarkan tingkat keakuratan antara data yang diminta dengan hasil prediksi yang diberikan oleh model. Maka, *precision* merupakan rasio prediksi *True Positive* dibandingkan dengan keseluruhan hasil yang diprediksi positif. Dari semua kelas positif yang telah di prediksi dengan benar, berapa banyak

data yang benar-benar positif (Triyogi dkk., 2023). Nilai *precision* dapat diperoleh dengan persamaan berikut.

$$\text{accuracy} = \frac{TP}{TP+FP}$$

2.9.3 *Recall*

Recall adalah indikator uji yang menentukan keberhasilan jenis citra yang sudah diidentifikasi. Nilai *recall* didapat dari membandingkan nilai *True Positive* (TP) dengan banyaknya data yang sebenarnya positif (Kurniawan dkk., 2023). Nilai *recall* dapat diperoleh dengan persamaan berikut.

$$\text{recall} = \frac{TP}{TP+FN}$$

2.9.4 *F1-Score*

F-1 Score menggambarkan perbandingan rata-rata *precision* dan *recall* yang dibobotkan. *Accuracy* tepat kita gunakan sebagai acuan performansi algoritma jika dataset memiliki jumlah dataset data *false negative* dan *false positive* yang sangat mendekati. Maka sebaiknya kita menggunakan *F-1 Score* sebagai acuan (Kurniawan dkk., 2023).

$$F1 - \text{score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} = \frac{2TP}{2TP+FP+FN}$$