

**KLASIFIKASI CITRA DAUN MANGGA IMPOR MENGGUNAKAN
ALGORITMA *YOU ONLY LOOK ONCE* VERSION 4 (YOLOV4)**

(SKRIPSI)

Oleh

**MITA ANGGRAENI
1917051040**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

**KLASIFIKASI CITRA DAUN MANGGA IMPOR MENGGUNAKAN
ALGORITMA *YOU ONLY LOOK ONCE* VERSION 4 (YOLOV4)**

Oleh

MITA ANGGRAENI

Skripsi

Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA KOMPUTER

Pada

Jurusan Ilmu Komputer
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

ABSTRAK

KLASIFIKASI CITRA DAUN MANGGA IMPOR MENGGUNAKAN ALGORITMA *YOU ONLY LOOK ONCE VERSION 4 (YOLOV4)*

Oleh

MITA ANGGRAENI

Mangga (*Mangifera indica L.*) merupakan salah satu jenis tanaman buah yang berasal dari India dan menyebar sampai ke Indonesia. Mangga memiliki banyak varietas mulai dari mangga lokal maupun mangga impor. Saat ini, mangga lokal dianggap lebih rentan terhadap hama penyakit, sehingga masyarakat Indonesia banyak yang mencari dan menanam bibit mangga impor. Untuk membedakan setiap varietas mangga dapat dilakukan dengan memperhatikan karakteristik daun dari setiap jenisnya. Sebagian masyarakat masih sulit membedakan setiap varietas mangga karena bentuk daun setiap mangga yang hampir sama. Oleh karena itu, diperlukan teknologi yang dapat mempermudah dalam membedakan jenis mangga berdasarkan karakteristik daun setiap mangga. Proses klasifikasi varietas mangga impor berdasarkan citra daun dapat diterapkan dalam teknologi dengan menggunakan algoritma *You Only Look Once version 4 (YOLOv4)*. Varietas daun mangga impor yang digunakan adalah daun mangga irwin dan daun mangga okyong. Data citra daun mangga impor yang digunakan sebagai *dataset* sebanyak 1000 data, yang terdiri dari 500 data citra setiap varietasnya. *Dataset* dibagi menjadi 2 bagian, yaitu 80% data latih dan 20% data uji. Proses pelatihan model YOLOv4 menggunakan data latih dengan *5-fold cross validation* memperoleh nilai rata-rata akurasi *mean Average Precision (mAP)* 99.05%, *accuracy* 0.917, *precision* 0.918, *recall* 0.980, dan *f1-score* 0.947. Pada pengujian model menggunakan data uji memperoleh *mAP* 98.48%, *accuracy* 0.895, *precision* 0.894, *recall* 0.975, dan *f1-score* 0.933.

Kata kunci: varietas mangga, *You Only Look Once version 4 (YOLOv4)*, klasifikasi, daun mangga impor.

ABSTRACT

IMAGE CLASSIFICATION OF IMPORTED MANGO LEAVES USING THE YOU ONLY LOOK ONCE VERSION 4 (YOLOV4) ALGORITHM

By

MITA ANGGRAENI

Mango (Mangifera indica L.) is a type of fruit plant that originates from India and spread to India. Mangoes have many varieties ranging from local mangoes to imported mangoes. Currently, local mangoes are considered more susceptible to pests and diseases, so many Indonesians are looking for and planting imported mango seeds. To differentiate each mango variety, you can pay attention to the characteristics of the leaves of each type. Some people still find it difficult to differentiate each mango variety because the shape of the leaves of each mango is almost the same. Therefore, technology is needed that can make it easier to distinguish types of mangoes based on the characteristics of each mango's leaves. The process of classifying imported mango varieties based on leaf images can be applied in technology using the You Only Look Once version 4 (YOLOv4) algorithm. The imported mango leaf varieties used are Irwin mango leaves and Okyong mango leaves. The imported mango leaf image data used as a dataset is 1000 data, consisting of 500 image data for each variety. The dataset is divided into 2 parts, namely 80% training data and 20% test data. The YOLOv4 model training process using training data with 5-fold cross validation obtained an average accuracy value of mean Average Precision (mAP) 99.05%, accuracy 0.917, precision 0.918, recall 0.980, and f1-score 0.947. In testing the model using test data, an mAP 98.48%, accuracy of 0.895, precision of 0.894, recall of 0.975, and f1-score of 0.933 were obtained.

Keywords: *mango varieties, You Only Look Once version 4 (YOLOv4), classification, imported mango leaves.*

Judul Skripsi : **KLASIFIKASI CITRA DAUN MANGGA
IMPOR MENGGUNAKAN ALGORITMA
YOU ONLY LOOK ONCE VERSION 4
(YOLOV4)**

Nama Mahasiswa : *Mita Anggraeni*

Nomor Pokok Mahasiswa : 1917051040

Program Studi : S1 Ilmu Komputer

Fakultas : Matematika dan Ilmu Pengetahuan Alam



1. Komisi Pembimbing

Rizky Prabowo
Rizky Prabowo, S.Kom, M.Kom.
NIP. 19880807 201903 1 011

Dewi Asiah Shofiana
Dewi Asiah Shofiana, S.Komp, M.Kom.
NIP. 19950929 202012 2 030

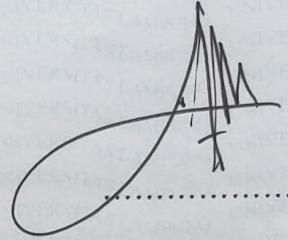
2. Ketua Jurusan Ilmu Komputer

Dwi Sakethi
Dwi Sakethi, S.Si., M.Kom.
NIP. 19680611 199802 1 001

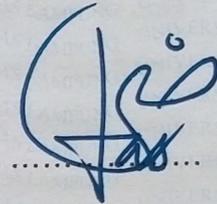
MENGESAHKAN

1. Tim Penguji

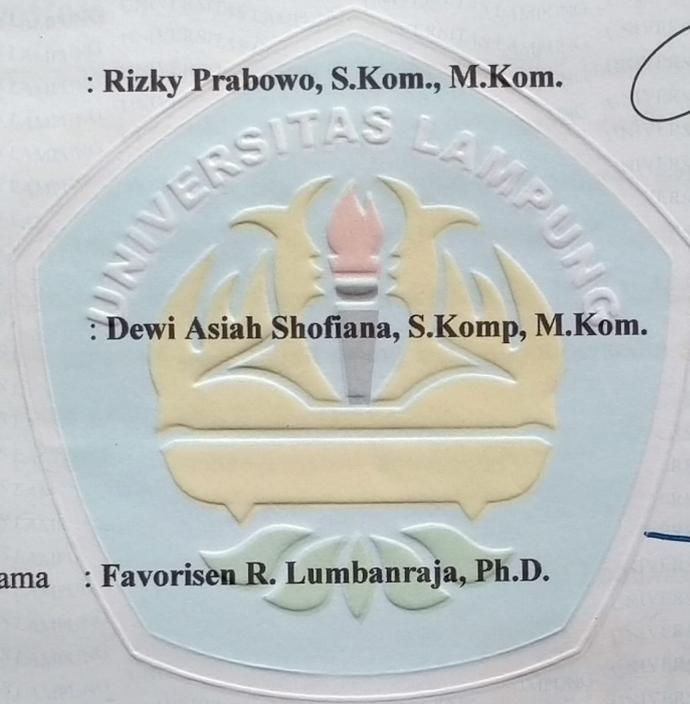
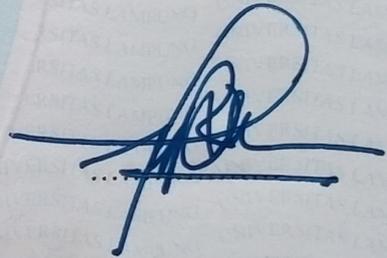
Ketua : Rizky Prabowo, S.Kom., M.Kom.



Sekretaris : Dewi Asiah Shofiana, S.Komp, M.Kom.



Penguji Utama : Favorisen R. Lumbanraja, Ph.D.



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.
NIP. 19711001 200501 1 002

Tanggal Lulus Ujian Skripsi: 06 Juni 2024

PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Mita Anggraeni

NPM : 1917051040

Dengan ini menyatakan bahwa skripsi saya yang berjudul "**Klasifikasi Citra Daun Mangga Impor Menggunakan Algoritma *You Only Look Once* version 4 (YOLOv4)**" merupakan karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertuang dalam skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila di kemudian hari terbukti skripsi saya merupakan hasil jiplakan atau dibuat orang lain, maka bersedia menerima sanksi berupa pencabutan gelar yang telah saya terima.

Bandar Lampung, 06 Juni 2024



Mita Anggraeni
NPM. 1917051040

RIWAYAT HIDUP



Penulis dilahirkan di Waringinsari pada tanggal 28 Mei 2002, sebagai anak kedua dari tiga bersaudara dari pasangan Bapak Pawit Ardian dan Ibu Riswati. Penulis menyelesaikan pendidikan formal di TK Tarbiatul Aulad pada tahun 2007, kemudian melanjutkan pendidikan dasar di SDN 2 Bandung Baru yang diselesaikan pada tahun 2013. Kemudian melanjutkan pendidikan menengah pertama di SMPN 1 Sukoharjo yang diselesaikan pada tahun 2016, dan melanjutkan ke pendidikan menengah akhir di SMAN 1 Sukoharjo yang diselesaikan pada tahun 2019.

Pada tahun 2019, penulis terdaftar menjadi mahasiswa di Program Studi S1 Ilmu Komputer, Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung melalui jalur Seleksi Bersama Masuk Perguruan Tinggi Negeri (SBMPTN). Selama menjadi mahasiswa, penulis melakukan beberapa kegiatan, diantaranya sebagai berikut:

1. Mengikuti rangkaian kegiatan Pengenalan Kehidupan Kampus bagi Mahasiswa Baru (PKKMB) Universitas Lampung, PKKMB Fakultas Matematika dan Ilmu Pengetahuan Alam, Pengenalan Jurusan Ilmu Komputer (PRINTER) dan Program Orientasi Perguruan Tinggi Jurusan Ilmu Komputer (PROPTI) Jurusan Ilmu Komputer pada tahun 2019.
2. Menjadi Anggota Muda Jurusan Ilmu Komputer (Adapter) Himpunan Mahasiswa Jurusan Ilmu Komputer pada periode 2019/2020.

3. Mengikuti kegiatan Karya Wisata Ilmiah (KWI) XXX Fakultas Matematika dan Ilmu Pengetahuan Alam di Desa Tambah Dadi, Kecamatan Purbolingo, Kabupaten Lampung Timur pada tahun 2019.
4. Menjadi anggota Biro Kesekretariatan Himpunan Mahasiswa Jurusan Ilmu Komputer pada periode 2020/2021.
5. Menjadi Asisten Dosen mata kuliah Logika di Jurusan Ilmu Komputer pada tahun 2020.
6. Menjadi anggota Bidang Internal Himpunan Mahasiswa Jurusan Ilmu Komputer pada periode 2021/2022.
7. Menjadi Sekretaris Koordinator divisi Humas Publikasi Desain dan Dokumentasi (HPDD) pada Kegiatan Kompetisi Olahraga Jurusan Ilmu Komputer (KOKOM) tahun 2021.
8. Melaksanakan Kuliah Kerja Nyata (KKN) periode I di Desa Bumi Ratu, Kecamatan Pagelaran, Kabupaten Pringsewu pada pada bulan Januari sampai dengan bulan Februari tahun 2022.
9. Melaksanakan Kerja Praktik di Badan Pusat Statistik (BPS) Kabupaten Pringsewu pada bulan Juni sampai dengan bulan Agustus tahun 2022.

MOTTO

لَا يُكَلِّفُ اللَّهُ نَفْسًا إِلَّا وُسْعَهَا

“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya”

(QS. Al-Baqarah : 286)

فَإِنَّ مَعَ الْعُسْرِ يُسْرًا

“Karena sesungguhnya sesudah kesulitan itu ada kemudahan”

(QS. Al-Insyirah : 5)

إِنَّ اللَّهَ لَا يُغَيِّرُ مَا بِقَوْمٍ حَتَّى يُغَيِّرُوا مَا بِأَنْفُسِهِمْ

“Sesungguhnya Allah tidak akan mengubah keadaan suatu kaum sebelum mereka mengubah keadaan diri mereka sendiri”

(Ar-Ra'd : 11)

خَيْرُ النَّاسِ أَنْفَعُهُمْ لِلنَّاسِ

“Sebaik-baik manusia adalah yang paling bermanfaat bagi manusia (lainnya)”

(HR. Ahmad)

“Hadiah terbaik adalah apa yang kamu miliki, dan takdir terbaik adalah apa yang sedang kamu jalani”

(Ustad Agam Fahrul)

PERSEMBAHAN

Alhamdulillahillobbilamin

Puji syukur kehadiran Allah Subhanahu Wa Ta'ala yang telah memberikan rahmat dan karunia-Nya sehingga saya dapat menyelesaikan skripsi ini. Shalawat serta salam saya sanjungkan kepada Nabi Muhammad Shalallahu 'Alaihi Wasallam.

Ku persembahkan karya ini kepada:

Kedua Orang Tuaku Tercinta

Yang senantiasa memberikan yang terbaik, dan melantunkan doa yang selalu menyertaiku. Ku ucapkan pula terima kasih sebesar-besarnya karena telah mendidik dan membesarkanku dengan penuh kasih sayang, dukungan, dan pengorbanan yang belum bisa terbalaskan.

Kepada Kakak dan Adikku serta Keluarga Besar

Yang selalu memberikan doa, semangat, dan dukungan.

Seluruh Keluarga Besar Ilmu Komputer 2019

Yang selalu memberikan semangat dan dukungan.

Almamater Tercinta, Universitas Lampung dan Jurusan Ilmu Komputer

Tempat bernaung mengemban semua ilmu untuk menjadi bekal hidup.

SANWACANA

Puji syukur kehadirat Allah Subhanahu Wa Ta'ala yang telah memberikan berkah, rahmat, hidayah-Nya, serta shalawat dan salam yang selalu tercurah kepada Nabi Muhammad Sholallahu 'Alaihi Wasallam, sehingga penulis dapat menyelesaikan skripsi yang berjudul "**Klasifikasi Citra Daun Mangga Impor Menggunakan Algoritma *You Only Look Once version 4 (YOLOv4)***" dengan baik.

Selama proses pengerjaan dan penulisan skripsi ini tidak terlepas dari dukungan banyak pihak, yang telah membimbing, membantu dan memberikan semangat, sehingga pada kesempatan ini penulis ingin menyampaikan ungkapan terima kasih kepada:

1. Kedua orang tua tercinta, Bapak Pawit Ardian dan Ibu Riswati yang selalu memberikan doa, dukungan moral dan material, motivasi, serta semangat dalam keadaan apapun. Semoga Allah Subhanahu Wa Ta'ala selalu menjaga, melindungi, memberikan kesehatan, rezeki serta kebahagiaan yang berlimpah.
2. Kakak dan adik tersayang, Mega Kunaria dan Masna Niswa Aini yang selalu memberikan dukungan, menghibur, dan menyemangati dalam setiap keadaan.
3. Bapak Rizky Prabowo, S.Kom., M.Kom. selaku dosen pembimbing utama yang telah meluangkan banyak waktu dan dengan memberikan bimbingan, arahan, ide, kritik, saran dan motivasi kepada penulis sehingga dapat menyelesaikan skripsi ini dengan baik.
4. Ibu Dewi Asiah Shofiana, S.Komp., M.Kom. selaku dosen pembimbing kedua yang telah meluangkan banyak waktu dan dengan memberikan bimbingan, arahan, ide, kritik, saran dan motivasi kepada penulis sehingga dapat menyelesaikan skripsi ini dengan baik.

5. Bapak Favorisen R. Lumbanraja, Ph.D. selaku dosen pembahas yang telah memberikan kritik, saran dan masukan yang sangat bermanfaat dalam perbaikan skripsi ini.
6. Ibu Yohana Tri Utami, M.Kom. selaku dosen Pembimbing Akademik yang telah memberikan dukungan, semangat, ilmu dan arahan selama menjalani perkuliahan hingga skripsi ini dapat diselesaikan.
7. Bapak Abdurrahman Sayuti selaku pemilik tempat penjualan bibit buah yang telah senantiasa membantu penulis dalam memperoleh data untuk skripsi ini.
8. Bapak Dwi Sakethi, S.Si., M.Kom. selaku Ketua Jurusan Ilmu Komputer Universitas Lampung.
9. Ibu Anie Rose Irawati, S.T. M.Cs. selaku Sekretaris Jurusan Ilmu Komputer Universitas Lampung.
10. Seluruh karyawan Fakultas MIPA Universitas Lampung, Ibu Ade Nora Maela, Bang Zainuddin, Mas Syam, Mas Nofal, dan lainnya yang tidak dapat disebutkan satu per satu, yang telah membantu segala urusan administrasi penulis.
11. Bapak dan Ibu Dosen Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan bimbingan, ilmu, dan pengalaman selama menjadi mahasiswa FMIPA Universitas Lampung.
12. Laboratorium Komputasi Dasar FMIPA Universitas Lampung yang telah menyediakan peralatan pendukung penelitian.
13. Viny Silvia, Della Hayu Enggarini, dan Fista Dwi Septiana selaku sahabat saya yang telah memberikan banyak dukungan, semangat, segala bentuk bantuan selama masa perkuliahan.
14. Teman-teman Jurusan Ilmu Komputer 2019 yang menjadi keluarga satu angkatan selama menjalankan masa studi di Jurusan Ilmu Komputer Universitas Lampung.
15. Almamater tercinta, Universitas Lampung yang telah memberikan banyak wawasan dan pengalaman berharga.

Penulis menyadari dalam penulisan skripsi ini masih banyak kekurangan yang disebabkan oleh keterbatasan pengetahuan, kemampuan serta pengalaman. Oleh karena itu, masukan dan saran sangat diharapkan sebagai evaluasi dan pembelajaran ke depannya. Semoga skripsi ini dapat menambah ilmu dan bermanfaat bagi semua pihak.

Bandar Lampung, 06 Juni 2024
Penulis

Mita Anggraeni
NPM. 1917051040

DAFTAR ISI

	Halaman
DAFTAR ISI	iv
DAFTAR TABEL	vi
DAFTAR GAMBAR	vii
DAFTAR KODE PROGRAM	ix
I. PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Rumusan Masalah	4
1.3. Batasan Masalah.....	4
1.4. Tujuan Penelitian.....	5
1.5. Manfaat Penelitian.....	5
II. TINJAUAN PUSTAKA	6
2.1. Penelitian Terdahulu.....	6
2.2. Citra Digital	9
2.3. Klasifikasi Citra.....	10
2.4. Mangga.....	10
2.5. <i>Machine Learning</i>	12
2.6. <i>Deep Learning</i>	14
2.7. <i>Convolutional Neural Network (CNN)</i>	15
2.8. <i>You Only Look Once (YOLO)</i>	17
2.9. <i>You Only Look Once v4 (YOLOv4)</i>	20

2.10. <i>Confusion Matrix</i>	22
2.11. <i>Intersection over Union (IoU)</i>	24
2.12. <i>Average Precision (AP) dan Mean Average Precision (mAP)</i>	25
2.13. <i>Konfigurasi Hyperparameter</i>	26
2.14. <i>K-Fold Cross validation</i>	29
2.15. <i>Python</i>	30
III. METODOLOGI PENELITIAN	32
3.1. <i>Tempat dan Waktu Penelitian</i>	32
3.2. <i>Data dan Alat Pendukung</i>	34
3.3. <i>Alur Kerja Penelitian</i>	37
IV. HASIL DAN PEMBAHASAN	42
4.1. <i>Pre-processing Data</i>	42
4.2. <i>Anotasi Data</i>	43
4.3. <i>Pembagian Data</i>	45
4.4. <i>Instalasi YOLO</i>	46
4.5. <i>Konfigurasi Hyperparameter</i>	47
4.6. <i>Pelatihan Data pada Model YOLOv4</i>	52
4.7. <i>Pembahasan Hasil Training Model YOLOv4</i>	56
4.8. <i>Hasil Uji dan Evaluasi Model YOLOv4</i>	59
V. PENUTUP	68
5.1. <i>Simpulan</i>	68
5.2. <i>Saran</i>	68
DAFTAR PUSTAKA	70
LAMPIRAN	75

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu	6
2. <i>Confusion Matrix</i>	23
3. <i>Timeline</i> Penelitian.....	33
4. <i>Hyperparameter</i> Pelatihan Model YOLOv4.....	47
5. Hasil <i>Average Precision</i> Pelatihan Model	55
6. <i>Accuracy, Precision, Recall, F-1 Score</i> , dan mAP Pelatihan Model.....	55
7. Contoh Hasil Pengujian Model YOLOv4 yang Tidak Sesuai	59
8. <i>Confusion Matrix</i> Hasil Pengujian Model YOLOv4	60
9. Hasil Pengujian Model YOLOv4.....	61

DAFTAR GAMBAR

Gambar	Halaman
1. Daun Mangga Irwin.	12
2. Daun Mangga Okyong.	12
3. Arsitektur CNN (O'Shea & Nash, 2015).	15
4. Ilustrasi Konvolusi Matrix 6 x 6 (Rohim dkk., 2019).	16
5. <i>ReLU Activation</i> (O'Shea & Nash, 2015).	16
6. <i>Max Pooling</i> (O'Shea & Nash, 2015).	17
7. Proses Sistem Deteksi YOLO (Redmon, dkk., 2016).	18
8. Model Deteksi Menggunakan <i>Bounding Box</i> (Redmon, dkk., 2016).	19
9. Arsitektur <i>You Only Look Once</i> (Redmon dkk., 2016).	20
10. Perbandingan YOLOv4 dengan Detektor Objek Lain	21
11. Tahapan Detektor Objek (Bochkovski dkk., 2020).	22
12. <i>Intersection over Union</i> (Shianto dkk., 2019).	24
13. <i>5-Fold Cross Validation</i> (Phung & Rhee, 2019).	29
14. <i>Dataset</i> Daun Mangga Irwin Australia.	34
15. <i>Dataset</i> Daun Mangga Okyong Thailand.	35
16. Alur Penelitian.	38
17. Tampilan <i>File</i> obj.names.	43
18. Tampilan <i>File</i> obj.data.	43
19. Anotasi Data di Yolo_mark.	44
20. Tampilan <i>File</i> txt Hasil Anotasi Data.	44
21. Format <i>File</i> txt Hasil Anotasi.	44
22. Perbandingan <i>Accuracy, Precision, Recall, dan F1-Score</i>	56
23. Perbandingan mAP Setiap <i>Cross Validation</i>	58
24. Pengujian Model YOLOv4 pada Citra Daun Mangga Irwin.	63
25. Pengujian Model YOLOv4 pada Citra Daun Mangga Okyong.	64

26. Hasil Pengujian yang Tidak Sesuai.....	64
27. Citra yang Diprediksi Sebagai Daun Mangga Irwin dan Okyong.	65
28. Hasil Pengujian Dua Objek Daun.	66
29. Pengujian Model YOLOv4 pada Citra Daun Lain.....	66

DAFTAR KODE PROGRAM

Kode Program	Halaman
1. <i>Resize</i> Data Citra.....	42
2. Implementasi Pembagian Data Latih dan Data Uji.....	45
3. <i>Cloning</i> pada YOLO.....	46
4. Konfigurasi <i>Makefile</i>	47
5. Konfigurasi <i>Hyperparameter</i>	48
6. <i>Backbone</i> YOLOv4.....	50
7. <i>Neck</i> YOLOv4.....	51
8. <i>Head</i> YOLOv4.....	52
9. <i>K-Fold Cross Validation</i>	53
10. <i>Training</i> YOLOv4 Menggunakan <i>Pre-trained Weights</i>	53
11. Melanjutkan <i>Training</i> Model dari <i>File Weights</i> Terakhir.....	54
12. Mengukur Kinerja Model.....	54

I. PENDAHULUAN

1.1. Latar Belakang

Mangga (*Mangifera indica L.*) merupakan tanaman buah yang berasal dari India dan kemudian menyebar ke beberapa negara di Asia Tenggara, termasuk Indonesia (Hidayat, 2022). Mangga mulai ditanam pertama kali di Kepulauan Maluku pada tahun 1665. Mangga okulasi baru diimpor dari India pada tahun 1911. Mangga memiliki kandungan gizi yang tinggi, termasuk vitamin A dan C yang berfungsi meningkatkan daya tahan tubuh, mencegah kerusakan mata dan sariawan, mencegah risiko jantung, menjaga kesehatan jantung, dan masih banyak lagi manfaat yang didapatkan apabila mengonsumsi buah mangga (Rahayu dkk., 2016).

Dengan berbagai manfaat yang dapat diperoleh dari buah mangga, menjadikan bibit mangga banyak ditanam oleh masyarakat Indonesia untuk dijadikan bisnis ataupun untuk dibudidayakan dan dikonsumsi secara pribadi (Rahayu dkk., 2016). Setiap varietas mangga memiliki ciri khas pada daun-daun dari segi bentuk, ukuran, warna, dan tekstur, yang memudahkan identifikasi jenis tanaman. Daun merupakan salah satu bagian tumbuhan yang penting untuk mengidentifikasi dan mengenali jenis dari suatu tanaman, salah satunya yaitu varietas tanaman mangga. Menurut Kamus Besar Bahasa Indonesia (KBBI), varietas adalah kelompok tanaman dalam jenis atau spesies tertentu yang dapat dibedakan dengan kelompok yang lain berdasarkan sifat tertentu dari tanaman tersebut. Beberapa varietas mangga di Indonesia yaitu mangga arumanis, mangga apel, mangga manalagi, mangga golek, mangga indramayu, mangga madu, dan sebagainya (Hidayat, 2022).

Selain varietas mangga lokal, di Indonesia juga terdapat beberapa varietas mangga impor. Mangga impor adalah jenis mangga yang berasal dari luar negeri, di antaranya yaitu mangga irwin dari Australia, mangga yuwen dari Taiwan, mangga chokanan dari Thailand, mangga okyong dari Thailand, dan sebagainya. Setiap varietas mangga memiliki kandungan nutrisi dan manfaat yang berbeda. Saat ini, mangga lokal dianggap lebih rentan terhadap hama penyakit, sehingga masyarakat Indonesia banyak yang mencari dan menanam bibit mangga impor. Selain itu, varietas mangga impor memiliki beberapa keunggulan lainnya, diantaranya yaitu warna buah yang menarik, rasa dan tekstur buah yang khas, bentuk buah yang lebih besar, serta bentuk tajuk yang relatif sama (Gunastri, 2012). Dari beberapa keunggulan yang dimiliki mangga impor, mengakibatkan produksi bibit mangga impor di Indonesia saat ini mengalami peningkatan (Gunastri, 2012).

Dengan banyaknya jenis mangga di Indonesia, mengakibatkan sebagian masyarakat mengalami kesulitan dalam membedakan varietas bibit mangga karena kesamaan bentuk daun dan fisik tanaman di setiap varietas. Sebagian masyarakat baru dapat mengenali varietas mangga ketika mangga sudah berbuah sehingga membutuhkan waktu yang cukup lama yaitu minimal selama 6 bulan untuk menunggu tanaman mangga berbuah (Wibowo, 2017). Hal tersebut mengakibatkan banyak masyarakat Indonesia mengalami kesalahan dalam pemilihan bibit mangga yang hendak ditanam. Menurut Suhendri (2017), kesalahan penanaman jenis mangga dapat menjadi masalah serius, terutama pada penanaman berskala besar. Penanaman jenis mangga yang berbeda dalam satu lahan dapat mempengaruhi kualitas buah yang dihasilkan.

Menurut (Suhendri dkk., 2017), untuk mencegah kesalahan penanaman jenis mangga agar dapat memaksimalkan kualitas dari produk yang dihasilkan, maka perlu dilakukan penyesuaian dan pemilihan bibit pohon mangga yang akan ditanam. Pemilihan bibit mangga berdasarkan jenisnya dapat dilakukan dengan meneliti daun bibit mangga. Karakteristik daun dapat dilihat dari pola

setiap daun yaitu dengan memperhatikan bentuk, warna, maupun tekstur dari daun tersebut sehingga dapat diklasifikasikan sesuai dengan jenisnya (Wibowo, 2017).

Menurut Purwanto & Lukiawan (2019), klasifikasi adalah proses pengelompokan piksel ke dalam kategori atau kelas yang telah ditentukan berdasarkan nilai kecerahan piksel tersebut. Tujuan dari klasifikasi citra adalah untuk menghasilkan gambaran atau peta tematik yang menunjukkan bagian-bagian yang mengidentifikasi jenis objek. Dalam klasifikasi digital, piksel-piksel dengan karakteristik spektral yang serupa dianggap sebagai bagian dari kelas yang sama. Proses ini memungkinkan pemisahan antar objek dilakukan dengan akurasi dan presisi yang tinggi.

Salah satu penelitian sebelumnya dilakukan oleh (Fitrianingsih & Rodiah, 2021) mengenai klasifikasi citra daun mangga menggunakan *Convolutional Neural Network* (CNN). Penelitian tersebut berfokus pada pembuatan model CNN untuk mengklasifikasikan citra daun mangga. Citra daun mangga yang digunakan pada penelitian ini terdiri dari tiga jenis mangga, yaitu mangga golek, mangga harum manis, dan mangga manalagi. Hasil klasifikasi menggunakan model CNN pada *training set* memperoleh nilai akurasi sebesar 97.72%, sedangkan nilai akurasi yang diperoleh pada *validation set* sebesar 89.20%.

Berdasarkan dari penelitian yang terkait mengenai klasifikasi citra daun mangga, belum ada suatu penggunaan metode yang melibatkan algoritma *You Only Look Once* (YOLO). Algoritma *You Only Look Once* (YOLO) merupakan bagian algoritma dari *machine learning* yang berbasis *Convolutional Neural Network* (CNN) yang berfungsi sebagai *object detection* pada citra yang banyak (Redmon dkk., 2016). Algoritma YOLO merupakan metode yang lebih efisien dibandingkan dengan algoritma *detection object* pada *machine learning* lainnya (Bochkovskiy dkk., 2020).

Maka dari itu, diusulkan penelitian mengenai klasifikasi citra daun mangga impor dengan menggunakan algoritma YOLOv4 untuk mengklasifikasikan citra daun mangga impor. Penelitian ini akan berfokus pada varietas mangga irwin dan mangga okyong.

1.2. Rumusan Masalah

Berdasarkan uraian latar belakang sebelumnya, maka rumusan masalah dalam penelitian ini sebagai berikut:

1. Bagaimana mengklasifikasikan daun mangga impor dengan menggunakan algoritma *You Only Look Once* v4 (YOLOv4)?
2. Bagaimana *performance* yang dihasilkan algoritma *You Only Look Once* v4 (YOLOv4) dalam mengklasifikasi citra daun mangga impor?

1.3. Batasan Masalah

Batasan masalah dalam penelitian ini sebagai berikut:

1. Penelitian ini menggunakan algoritma *You Only Look Once* v4 (YOLOv4) untuk mengklasifikasikan varietas mangga impor pada suatu citra.
2. Algoritma *You Only Look Once* v4 (YOLO) dibuat dengan menggunakan bahasa pemrograman Python.
3. Varietas bibit mangga impor yang digunakan dalam penelitian ini adalah dua jenis mangga yaitu mangga irwin dan mangga okyong.
4. Data citra daun mangga impor didapatkan dari pengambilan gambar secara langsung dengan menggunakan kamera *smartphone* dengan jumlah data sebanyak 500 citra daun mangga okyong dan 500 citra daun mangga irwin.
5. Pengambilan gambar dilakukan di luar ruangan dengan intensitas cahaya sebesar 4000 LUX - 8000 LUX dan tanpa pengaturan cahaya tambahan.

1.4. Tujuan Penelitian

Tujuan penelitian ini adalah sebagai berikut:

1. Melakukan proses identifikasi dan klasifikasi citra daun mangga impor menggunakan algoritma *You Only Look Once* v4 (YOLOv4).
2. Mengetahui *performance* yang diperoleh pada klasifikasi citra daun mangga impor menggunakan algoritma *You Only Look Once* v4 (YOLOv4).

1.5. Manfaat Penelitian

Manfaat dari penelitian ini sebagai berikut:

1. Mengetahui *performance* yang dihasilkan algoritma klasifikasi *You Only Look Once* v4(YOLOv4) dalam mengklasifikasikan citra daun mangga impor.
2. Penelitian ini dapat dijadikan sebagai informasi bagi penelitian selanjutnya mengenai klasifikasi citra daun mangga impor.

II. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Dalam melakukan penelitian ini, tidak terlepas dari beberapa penelitian terdahulu yang telah dilakukan. Beberapa ringkasan dari penelitian terdahulu dapat dilihat pada Tabel 1.

Tabel 1. Penelitian Terdahulu

Peneliti	Data	Algoritma	Hasil
(Fitriani gsih & Rodiah, 2021)	<i>Dataset</i> terdiri dari tiga jenis daun mangga, yaitu mangga golek, harum manis, dan manalagi. Jumlah <i>dataset</i> yang digunakan sebanyak 1761 citra yang dibagi menjadi 90% data <i>training</i> dan 10% data <i>validation</i> .	CNN	Akurasi model mencapai 97.72% pada tahap pelatihan dan 89.20% pada tahap validasi.
(Yuan, 2023)	<i>Dataset</i> terdiri dari 4 tahap pertumbuhan kuncup, yaitu <i>tight cluster</i> , <i>pink</i> , <i>bloom</i> , dan <i>petall fall</i> .	YOLOv4 dan YOLOv7	Nilai mAP pada pengujian dengan kualitas anotasi 100% sebesar 78% pada YOLOv4 dan 80% YOLOv7.
(Oktilas dkk., 2023)	<i>Dataset</i> yang digunakan berjumlah 4.224 gambar yang terdiri dari kelas sepeda motor dan mobil. Pembagian data <i>training</i> 80% dan <i>testing</i> 20%.	YOLOv4	Pengujian model mendapatkan hasil mAP sebesar 80.12%.

Tabel 1 (lanjutan)

Peneliti	Data	Algoritma	Hasil
(Setyaningih & Edy, 2022)	<i>Dataset</i> terbagi menjadi dua jenis karung, yaitu karung tebal dan karung tipis. Jumlah <i>dataset</i> sebanyak 800 gambar yang terbagi menjadi 700 data <i>training</i> dan 100 data <i>testing</i> .	YOLOv4 dan <i>Mask R-CNN</i>	YOLOv4 mencapai nilai <i>mean average precision</i> sebesar 98.60% , sedangkan <i>Mask R-CNN</i> memberikan performa sebesar 65.78%.
(Yang, 2021)	<i>Dataset</i> berupa bentuk dan bahan setiap objek. Bentuk: kotak, piring, nampan, sampah, peralatan makan, botol, kaleng, gelas, dan plastik. Bahan: kaca, kertas, logam, dan plastik.	YOLOv4	Akurasi pengujian mencapai 77.78%.

Pada penelitian yang dilakukan oleh (Fitrianingsih & Rodiah, 2021) yang berjudul “Klasifikasi Jenis Citra Daun Mangga Menggunakan *Convolutional Neural Network*”. Penelitian ini bertujuan untuk mendeteksi dan mengenali objek dari sebuah citra dengan melakukan *training* pada 3 jenis citra daun mangga. Citra daun mangga yang digunakan sebanyak 1761 citra yang terdiri dari 510 citra daun mangga golek, 588 citra daun mangga harum manis, dan 663 citra daun mangga manalagi. Pembagian *dataset* terdiri dari *dataset* pelatihan dan validasi dengan rasio 9:1. Nilai akurasi dari model dalam mengidentifikasi *training set* secara total mencapai 97.72%, sedangkan dalam mengidentifikasi *validation set* secara total mencapai 89.20%

Selanjutnya penelitian yang dilakukan oleh (Yuan, 2023) yang berjudul “*Accuracy Comparison of YOLOv7 and YOLOv4 Regarding Image Annotation Quality for Apple Flower Bud Classification*” bertujuan untuk membandingkan kinerja algoritma YOLOv7 dengan YOLOv4 untuk klasifikasi kuncup bunga apel menggunakan kumpulan data dengan kualitas anotasi gambar yang dimanipulasi secara artifisial dari 100% hingga 5%. *Dataset* terdiri dari 4 tahap pertumbuhan kuncup, yaitu *tight cluster* (tandan

rapat), *pink* (merah jambu), *bloom* (mekar), dan *petall fall* (kelopak gugur). Berdasarkan kumpulan data pengujian yang sama, YOLOv7 mengungguli YOLOv4 untuk semua tahap pertumbuhan di semua tingkat kualitas anotasi gambar pelatihan. Nilai mAP 0,80 atau 80% dicapai oleh YOLOv7 dengan kualitas anotasi gambar pelatihan 100%, sedangkan mAP 0,63 dicapai dengan kualitas anotasi gambar pelatihan hanya 5%. Nilai mAP yang diperoleh YOLOv4 dengan kualitas anotasi 100% adalah sebesar 0.78 atau 78%.

Selanjutnya penelitian yang dilakukan oleh (Okililas dkk., 2023) yang berjudul “Akurasi Pengujian Model Hasil *Training* Menggunakan YOLOv4 untuk Pengenalan Kendaraan di Jalan Raya” bertujuan untuk mendeteksi dan mengklasifikasikan kendaraan di jalan raya karena sering terjadi kemacetan lalu lintas di kota-kota besar. Data yang digunakan pada penelitian ini terdiri dari dua objek kendaraan yaitu gambar mobil dan gambar motor yang diambil secara manual. Total *dataset* yang digunakan berjumlah 4.224 *dataset file* gambar. Data yang digunakan dibagi menjadi data *training* 80% dan *testing* 20%. Pengujian model YOLOv4 mendapatkan hasil *mean Average Precision* (mAP) sebesar 80.12%. Dalam pengujian video untuk mendeteksi motor dan mobil mendapatkan total akurasi kendaraan sebesar 70.6% dan pada Tingkat keyakinan kendaraan sebesar 78.7%.

Pada penelitian yang dilakukan oleh (Setyaningsih & Edy, 2022) yang berjudul “YOLOv4 dan *Mask R-CNN* untuk Deteksi Kerusakan Pada Karung Komoditi” bertujuan untuk membantu permasalahan di bidang industri pertanian dalam mendeteksi objek berupa lubang kerusakan pada kemasan karung beras dengan menggunakan algoritma deteksi objek *You Only Look Once v4* (YOLOv4) dan *Mask R-CNN*. *Dataset* yang digunakan diambil melalui kamera digital sebanyak 800 gambar yang terdiri dari 700 gambar data *training* dan 100 gambar data *testing*. *Dataset* terbagi menjadi dua jenis karung yaitu karung tebal dan karung tipis. Serangkaian variasi data pengujian pada penelitian ini menjelaskan bahwa performa deteksi YOLOv4 lebih baik untuk diterapkan sebagai deteksi objek dibandingkan dengan model *Mask R-*

CNN. YOLOv4 mampu mencapai nilai *mean average precision* sebesar 98,60% sedangkan *Mask R-CNN* menghasilkan performa sebesar 65,78%.

Selanjutnya penelitian yang dilakukan oleh (Yang, 2021) dengan judul penelitian “*Waste Classification Based on YOLOv4*”, yang mengusulkan algoritma YOLOv4 untuk mengklasifikasikan limbah daur ulang restoran. *Dataset* yang digunakan terdiri dari gambar baki makanan yang diperoleh dari berbagai tempat, seperti pusat perbelanjaan, kantin, atau rumah. Pada penelitian ini dibuat kumpulan data sampah daur ulang berdasarkan lingkungan restoran, dan jenis daur ulang diklasifikasikan menurut bentuk dan bahan benda. Bahan dapat dibagi menjadi kaca, kertas, logam, dan plastik. Menurut klasifikasi bentuknya dapat dibedakan menjadi kotak, piring, nampan, sampah, peralatan makan, botol, kaleng, gelas, kertas, dan plastik. Hasil pengujian YOLOv4 memperoleh akurasi sebesar 77.78%.

2.2. Citra Digital

Citra merupakan suatu representasi atau gambaran yang menyerupai atau meniru suatu objek, yang dihasilkan sebagai keluaran dari sistem perekaman data. Citra ini dapat berupa gambar optik seperti foto, sinyal analog seperti video yang tampil di layar televisi, atau data digital yang dapat langsung disimpan dalam media penyimpanan (Wahyuni & Sulaeman, 2022). Citra digital sendiri merupakan sekumpulan data dalam bentuk *array* yang berisi nilai-nilai *real* maupun kompleks yang direpresentasikan dalam bentuk bit yang diproses secara langsung oleh komputer (Suhendri dkk., 2017). Citra digital merupakan citra yang berupa diskrit, baik koordinat ruang maupun intensitas cahayanya, yang sebelumnya berupa citra kontinu. Citra digital dinyatakan dalam matriks 2 dimensi $f(x,y)$, di mana ‘ x ’ dan ‘ y ’ adalah koordinat *pixel* dalam matriks, serta ‘ f ’ adalah derajat intensitas *pixel* tersebut (Paturrahman & Wijaya, 2021).

2.3. Klasifikasi Citra

Menurut Purwanto & Lukiawan (2019), klasifikasi adalah proses mengelompokkan piksel ke dalam kategori atau kelas yang telah ditentukan berdasarkan nilai kecerahan piksel tersebut. Tujuan dari klasifikasi citra adalah untuk membagi citra menjadi bagian-bagian yang menverminkan jenis objek yang ada. Setiap objek dalam gambar memiliki karakteristik unik yang dapat digunakan untuk identifikasi. Dalam klasifikasi digital, piksel dengan karakteristik warna dan tingkat kecerahan yang serupa dianggap sebagai kelas yang sama. Proses ini memastikan pemisahan yang akurat antara setiap objek. Menurut Amrozi dkk. (2022), terdapat beberapa langkah yang digunakan dalam proses pengklasifikasian data yaitu langkah *training* dan langkah klasifikasi. Pada langkah *training*, data latih dianalisis untuk menghasilkan model klasifikasi. Kemudian pada langkah klasifikasi, model yang telah dibuat digunakan untuk memprediksi kelas data *testing* untuk menguji apakah model yang telah dilatih memperoleh hasil kinerja yang baik atau tidak.

2.4. Mangga

Mangga (*Mangifera indica L.*) merupakan tanaman buah yang berasal dari India dan kemudian menyebar ke Asia Tenggara, termasuk Malaysia dan Indonesia. Buah mangga memiliki banyak manfaat karena kandungan gizinya yang tinggi dan banyak vitamin. Mengonsumsi mangga dapat membantu meningkatkan daya tahan tubuh, mencegah kerusakan mata, mengatasi sariawan, mengurangi risiko penyakit jantung, serta menjaga kesehatan jantung, dan masih banyak manfaat lainnya (Hidayat, 2022).

Di Indonesia, mangga dapat tumbuh optimal di daerah rendah dengan cuaca panas serta di dataran tinggi dengan cuaca sedang. Pohon mangga memiliki batang yang tegak, bercabang banyak, dan daun yang hijau sepanjang tahun. Tinggi pohon mangga dewasa bisa mencapai antara 10 hingga 40 meter, dan umur pohon dapat lebih dari 100 tahun. Morfologi pohon mangga mencakup

akar, batang, daun, dan bunga (Jamaludin dkk., 2021). Mangga memiliki berbagai variasi yang ditunjukkan melalui perbedaan bentuk, struktur tulang daun, ukuran, dan warna buah, yang menunjukkan keragaman genetik yang cukup luas (Rahayu dkk., 2016). Pemilihan bibit mangga berdasarkan jenisnya dapat dilakukan dengan meneliti daun bibit mangga. Karakteristik daun dapat dilihat dari pola setiap daun yaitu dengan memperhatikan bentuk, warna, maupun tekstur dari daun tersebut sehingga dapat diklasifikasikan sesuai dengan jenisnya (Suhendri dkk., 2017).

Di Indonesia terdapat banyak macam varietas mangga lokal maupun varietas mangga impor yang berasal dari luar negeri. Varietas mangga impor yang digunakan pada penelitian ini adalah varietas mangga irwin dan varietas mangga okyong. Penelitian ini menggunakan citra daun mangga pada setiap varietasnya yang akan digunakan untuk mengklasifikasikan varietas mangga tersebut.

2.4.1. Mangga Irwin

Mangga irwin merupakan jenis atau varietas mangga yang berasal dari Australia. Mangga irwin termasuk jenis mangga yang tahan terhadap penyakit (Agromedia, 2011). Ketika masih muda, mangga irwin menampilkan warna ungu pada pangkal buahnya, dan warna hijau pada ujungnya. Ketika buah sudah tua atau matang, pangkal buah berwarna merah dan ujungnya berwarna kuning (Gunastri, 2012). Karakteristik daun mangga irwin yaitu bentuk daun yang lonjong dan pendek, ujung daun yang runcing, daun berwarna hijau tua, tulang daun yang sedikit menonjol dan kasar, dan bentuk daun melengkung. Daun mangga irwin dapat dilihat pada Gambar 1.



Gambar 1. Daun Mangga Irwin.

2.4.2. Mangga Okyong

Mangga okyong merupakan jenis mangga dari Thailand yang cukup populer. Mangga okyong memiliki pertumbuhan tanaman yang cepat, berbuah sepanjang musim, dan tahan terhadap serangan hama penyakit (Agromedia, 2011). Mangga okyong memiliki karakteristik daun yang runcing dan kaku, daun berwarna hijau tua, jarak antar tulang daun yang lebih lebar, dan tepi daun yang bergelombang. Daun mangga okyong dapat dilihat pada Gambar 2.



Gambar 2. Daun Mangga Okyong.

2.5. *Machine Learning*

Machine Learning (ML) atau mesin pembelajar adalah cabang dari *Artificial Intelligence* (AI) yang fokus belajar dari data (*learn from data*), yaitu fokus terhadap pengembangan sistem yang dapat belajar secara mandiri tanpa harus berulang kali diprogram oleh manusia (Alfarizi dkk., 2023). *Machine learning*

bekerja apabila terdapat data yang dijadikan sebagai *input* untuk menganalisis suatu kumpulan data besar (*big data*) sehingga dapat menemukan pola tertentu. *Machine learning* terbagi menjadi beberapa algoritma yang berbeda, dan setiap algoritma memiliki fungsi dan tujuannya masing-masing. Di dalam *machine learning* terdapat data *training* dan data *testing*. Data *training* digunakan untuk melatih algoritma, sedangkan data *testing* digunakan untuk mengetahui performa dari algoritma dalam *machine learning* yang telah dilatih yaitu ketika menemukan data baru yang belum pernah diberikan dalam data *training* (Retnoningsih & Pramudita, 2020).

Machine learning menggunakan teknik untuk menangani *big data* dengan cara yang cerdas untuk mendapatkan hasil yang tepat. Berdasarkan teknik pembelajarannya, *machine learning* terdiri dari beberapa jenis, yaitu *supervised learning* dan *unsupervised learning*. *Supervised learning* merupakan salah satu teknik *machine learning* yang menggunakan *dataset* (*data training*) yang sudah berlabel (*labeled data*) untuk melakukan pembelajaran pada mesin, sehingga dapat mengidentifikasi label *input* dengan menggunakan fitur yang dimiliki untuk melakukan prediksi dan klasifikasi pada tahap selanjutnya. Algoritma yang termasuk ke dalam teknik *supervised learning* di antaranya *Decision Tree*, *K-Nearest Neighbor* (KNN), *Naïve Bayes*, dan *Support Vector Machine* (Retnoningsih & Pramudita, 2020).

Unsupervised learning merupakan teknik yang dilakukan dengan cara menarik kesimpulan berdasarkan *dataset* yang merupakan *input data labeled response* (Retnoningsih & Pramudita, 2020). Umumnya *unsupervised learning* digunakan untuk pengelompokan, estimasi kepadatan, pembelajaran fitur, mengurangi dimensi, menemukan aturan asosiasi, dan lain-lain. Beberapa algoritma dalam *unsupervised learning* adalah *Latent Dirichlet Allocation* (LDA), DBSCAN, *K-Means*, *Fuzzy C-Means*, dan *Self Organizing Map* (Sarker, 2021).

2.6. *Deep Learning*

Deep learning adalah konsep *machine learning* yang didasarkan pada jaringan saraf tiruan. Di banyak aplikasi, model *deep learning* mengungguli model *machine learning* dan pendekatan analisis data tradisional (Sharma & Chaudhary, 2023). *Deep learning* memungkinkan model komputasi beberapa lapisan pemrosesan untuk mempelajari dan merepresentasikan data dengan berbagai tingkat abstraksi yang meniru cara otak merasakan dan memahami informasi multi model, sehingga secara implisit menangkap struktur rumit dari data berskala besar. *Deep learning* adalah rangkaian metode yang kaya, mencakup jaringan saraf, model *probabilistic* hierarkis, dan berbagai algoritma pembelajaran *unsupervised* dan *supervised future* (Voulodimos dkk., 2018).

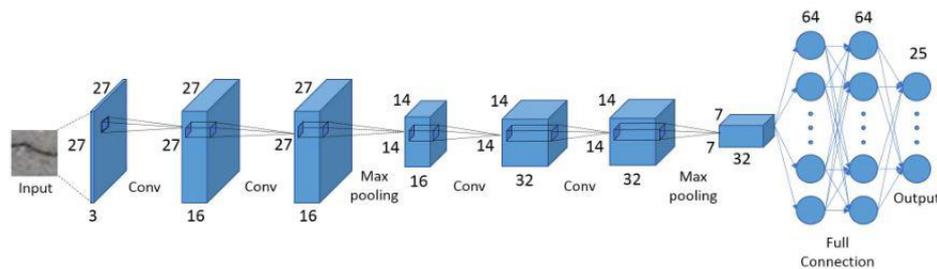
Deep learning adalah salah satu bidang *machine learning* yang memanfaatkan banyak *layer* pengolahan informasi non-linier untuk melakukan ekstraksi fitur, pengenalan pola, dan klasifikasi (Deng & Yu, 2013). Menurut (Goodfellow dkk., 2016), *deep learning* adalah sebuah pendekatan dalam penyelesaian masalah pada sistem pembelajaran komputer yang menggunakan konsep hierarki. Konsep hierarki membuat komputer mampu mempelajari konsep yang kompleks dengan menggabungkan dari konsep-konsep yang lebih sederhana. *Deep learning* adalah teknik yang terdapat pada *neural network* dengan menggunakan teknik tertentu yakni seperti *Restricted Boltzmann Machine* (RBM) untuk meningkatkan kecepatan proses pembelajaran pada *neural network* yang menggunakan *layer* yang banyak atau lebih dari 7 *layer* (Abu, 2017).

Peningkatan dari *deep learning* adalah munculnya kumpulan data berskala besar, berkualitas tinggi, dan tersedia untuk umum. Selain itu, *deep learning* juga meningkatkan pemberdayaan komputasi GPU paralel, yang diaktifkan transisi dari berbasis CPU ke berbasis GPU, sehingga memungkinkan percepatan yang signifikan dalam pelatihan model *deep learning*. *Deep*

learning telah mendorong kemajuan besar dalam berbagai permasalahan komputer, seperti deteksi objek, pelacakan gerak, pengenalan tindakan, estimasi pose manusia, dan semantik segmentasi (Voulodimos dkk., 2018).

2.7. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu jenis algoritma *deep learning* yang digunakan pada *computer vision* untuk menyelesaikan suatu permasalahan seperti mengklasifikasi dan mendeteksi suatu objek pada gambar atau video. CNN adalah variasi dari *Multi Layer Perceptron* (MLP) yang terinspirasi dari jaringan saraf pada manusia. CNN memiliki ciri khas berupa susunan *neuron* 3D yang terdiri dari tinggi, lebar, dan kedalaman. Lebar dan tinggi mengacu pada ukuran *layer*, sedangkan kedalaman mengacu pada jumlah *layer* yang ada (Rahim dkk., 2020).



Gambar 3. Arsitektur CNN (O'Shea & Nash, 2015).

Arsitektur CNN dapat dilihat pada Gambar 3. CNN terdiri dari tiga jenis *layer*, yaitu *convolutional layer* (Conv), *pooling layer* (Max pooling), dan *fully-connected layer* (Full Connection). Fungsi dasar dari CNN dibagi menjadi empat area utama, yaitu:

1. *Input layer*. *Layer* ini akan menyimpan nilai piksel dari citra masukan. Pada Gambar 3, ukuran citra *input* adalah $27 \times 27 \times 3$, yang berarti ukuran 27×27 menunjukkan dimensi piksel citra, sedangkan angka 3 menunjukkan jumlah *channel* citra, yaitu *Red*, *Green*, dan *Blue* (O'Shea & Nash, 2015).

2. *Convolutional layer*. *Convolutional* atau konvolusi adalah proses manipulasi citra dengan menggunakan eksternal *mask* atau sub windows untuk menghasilkan citra baru. Secara matematis, konvolusi didefinisikan sebagai jumlah total dari hasil perkalian elemen-elemen yang bersesuaian (memiliki koordinat yang sama) dalam dua matriks atau dua vektor (Rohim dkk., 2019). Contoh ilustrasi konvolusi dapat dilihat pada Gambar 4.

3	0	1	2	7	4
1	5	8	9	3	1
2	7	2	5	1	3
0	1	3	1	7	8
4	2	1	6	2	8
2	4	5	2	3	9

6 x 6

*

1	0	-1
1	0	-1
1	0	-1

3 x 3

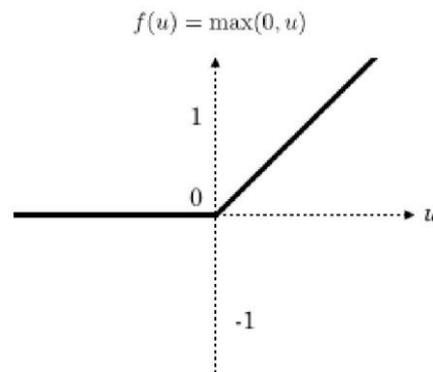
=

-5	-4	0	8
-10	-2	-2	3
0	-2	-4	-7
-3	-2	-3	-16

4 x 4

Gambar 4. Ilustrasi Konvolusi Matrix 6 x 6 (Rohim dkk., 2019).

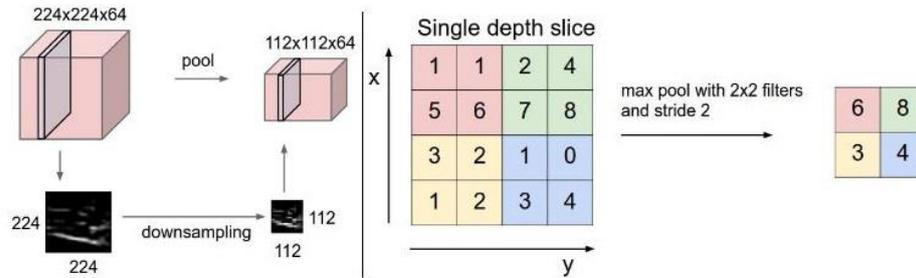
Dalam proses konvolusi, *Rectified Linear Unit* (ReLU) juga digunakan untuk menerapkan fungsi aktivasi secara *elementwise*, seperti fungsi sigmoid pada *output* aktivasi yang dihasilkan oleh lapisan sebelumnya. Grafik ReLU dapat dilihat pada Gambar 5



Gambar 5. ReLU Activation (O'Shea & Nash, 2015).

3. *Pooling layer*. Layer ini melakukan *down sampling* sepanjang dimensi spasial dari *input* yang diberikan, yang kemudian akan mengurangi jumlah parameter dalam aktivasi tersebut. *Pooling layer* bekerja dengan mengoperasikan peta aktivasi ke seluruh *input*, dan menggunakan fungsi "MAX". Pada sebagian besar CNN, *max-pooling layer* menggunakan

kernel berukuran 2×2 dengan *stride* 2 sepanjang dimensi spasial *input*, yang berarti kernelnya berpindah sebanyak 2 langkah setiap kali. Hal ini mengakibatkan ukuran *input* turun sampai 25% dari ukuran aslinya (O'Shea & Nash, 2015). Ilustrasi proses ini dapat dilihat pada Gambar 6 yang menggunakan penggunaan kernel berukuran 2×2 dengan *stride* 2.



Gambar 6. *Max Pooling* (O'Shea & Nash, 2015).

4. *Fully-connecter layer*. *Layer* ini melakukan tugas yang sama seperti jaringan saraf standar, yaitu berusaha menghasilkan nilai kelas dari aktivasi yang digunakan untuk klasifikasi (O'Shea & Nash, 2015). *Fully-connected layer* adalah lapisan yang terhubung secara penuh, di mana setiap *neuron* terhubung langsung dengan *neuron* lainnya pada dua lapisan yang berdekatan, tanpa melibatkan lapisan lain di antaranya.

2.8. *You Only Look Once (YOLO)*

You Only Look Once (YOLO) adalah pendekatan dalam sistem deteksi objek yang dirancang untuk pemrosesan secara *real time*. YOLO membingkai deteksi objek sebagai masalah regresi tunggal, di mana dari *pixel* gambar langsung menghasilkan kotak pembatas (*bounding box*) spasial yang terpisah dan probabilitas kelas yang terkait (Huang dkk., 2018). Langkah-langkah dalam mendeteksi objek menggunakan YOLO yaitu mengubah ukuran gambar *input* menjadi 448×448 , kemudian menjalankan *convolutional network*, dan selanjutnya membatasi deteksi yang dihasilkan berdasarkan *model's confidence* (Redmon dkk., 2016). Proses gambar di dalam YOLO dapat dilihat pada gambar 7.

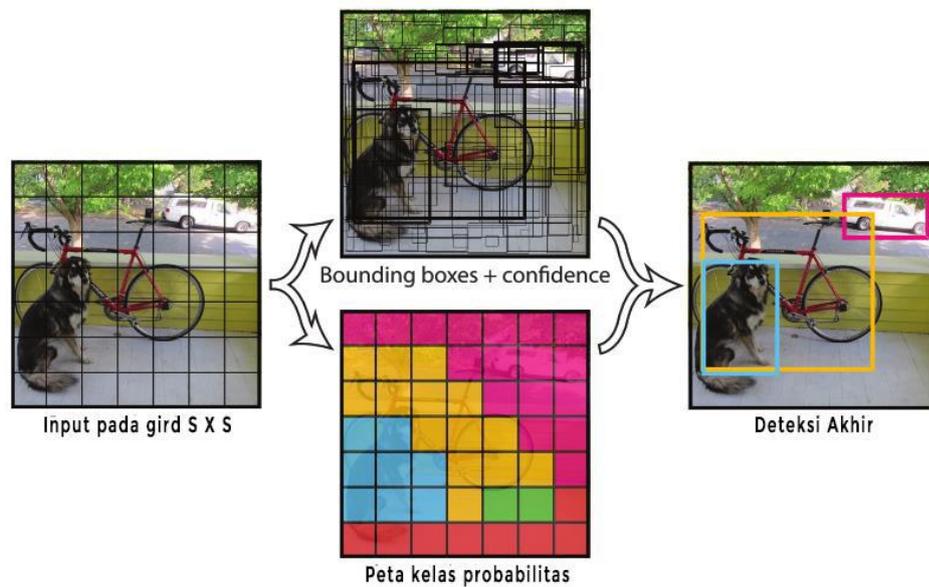


Gambar 7. Proses Sistem Deteksi YOLO (Redmon, dkk., 2016).

YOLO membagi gambar *input* menjadi *grid* berukuran $S \times S$. Jika pusat suatu objek berada dalam sel *grid*, maka sel *grid* tersebut akan mendeteksi objek tersebut. Setiap sel *grid* memprediksi B *bounding box* dan *confidence scores*. *Confidence score* merepresentasikan seberapa yakin model bahwa *bounding box* tersebut berisi objek dan seberapa akurat objek tersebut diprediksi. *Confidence* umumnya didefinisikan sebagai $Pr(Object) * IoU_{pred}^{truth}$, di mana jika tidak ada objek pada sel tersebut, maka nilai *confidence* adalah nol. Setiap *bounding box* terdiri dari 5 komponen prediksi: x , y , w , h , dan *confidence score*. Koordinat (x, y) mewakili titik tengah *bounding box* relatif terhadap batas-batas sel *grid*. Lebar dan tinggi (w, h) diperkirakan relatif terhadap keseluruhan gambar. *Prediction score* mengukur *Intersection over Union* (IoU) antara kotak yang diprediksi dan *ground truth*. Setiap sel *grid* juga memprediksi probabilitas kelas bersyarat $Pr(Class_i|Object)$ pada sel *grid* yang berisi objek, yang kemudian dikalikan dengan *confidence prediction* dari kotak individu untuk mendapatkan *confidence score* khusus kelas untuk setiap kotak (Redmon dkk., 2016).

$$Pr(Class_i|Object) * Pr(Object) * IoU_{pred}^{truth} = Pr(Class_i) * IoU_{pred}^{truth} \quad (1)$$

Persamaan 1 merupakan *confidence score* kelas khusus untuk setiap kotak. Skor ini mengodekan probabilitas kelas yang muncul dalam kotak serta seberapa sesuai kotak yang diprediksi dengan objek. Model deteksi membagi gambar menjadi *grid* $S \times S$, dan untuk setiap sel *grid* memprediksi *bounding box* B , *confidence* untuk setiap kotak, dan probabilitas kelas C . Prediksi ini dikodekan sebagai $S \times S \times (B * 5 + C)$. Gambar 8 merupakan gambaran dari prediksi *bounding box* B (Redmon dkk., 2016).

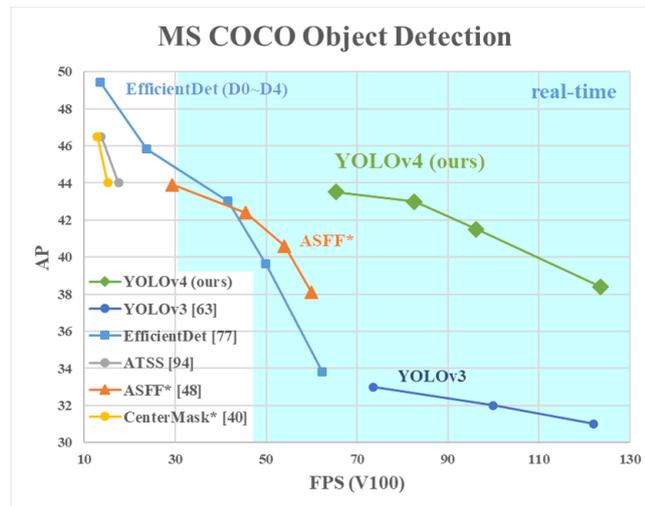


Gambar 8. Model Deteksi Menggunakan *Bounding Box* (Redmon, dkk., 2016).

Dalam mendeteksi objek, langkah pertama adalah menentukan lokasi setiap objek yang akan dideteksi dalam gambar. *You Only Look Once* (YOLO) merupakan metode yang menggunakan jaringan saraf tunggal (*single neural network*) untuk memproses keseluruhan gambar. Jaringan saraf tunggal ini membagi gambar menjadi beberapa wilayah (*grid*) dan kemudian akan memprediksi *bounding box* dari setiap wilayah, yang selanjutnya diklasifikasikan sebagai objek atau bukan objek (Mailoa & Santoso, 2022).

Arsitektur *You Only Look Once* (YOLO) yang diperkenalkan oleh Joseph Redmon dapat dilihat pada Gambar 9. YOLO diimplementasikan sebagai jaringan saraf konvolusi (*convolutional neural network*). Arsitektur ini terinspirasi oleh model GoogleNet untuk klasifikasi gambar. Jaringan YOLO terdiri dari 24 lapisan konvolusi diikuti oleh 2 lapisan *fully connected*. Secara sederhana, arsitektur ini menggunakan *layer* reduksi 1×1 yang diikuti oleh 3×3 *convolutional layers*. Prediksi dari *output* akhir jaringan YOLO ini adalah tensor berukuran $7 \times 7 \times 30$ (Redmon dkk., 2016).

komputasi paralel. YOLOv4 dirancang dapat dengan mudah dilatih dan digunakan dalam mendeteksi objek yang dirancang. Penggunaan GPU konvensional untuk pelatihan dan pengujian dapat mencapai hasil deteksi objek yang *real-time*, berkualitas tinggi, dan meyakinkan (Bochkovski et al., 2020). Berdasarkan hasil YOLOv4 dapat dilihat pada Gambar 10.

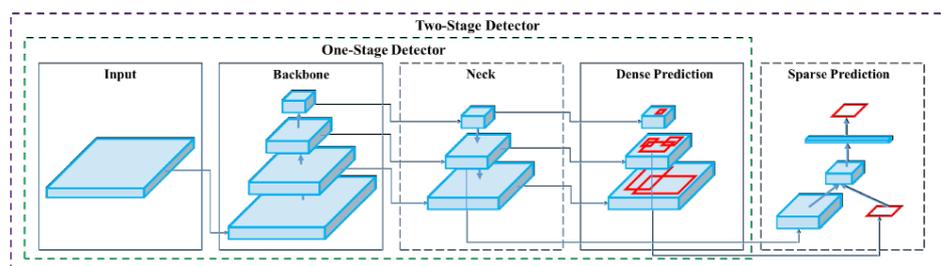


Gambar 10. Perbandingan YOLOv4 dengan Detektor Objek Lain . (Bochkovski et al., 2020).

Berdasarkan Gambar 10, YOLOv4 beroperasi dua kali lebih cepat dibandingkan EfficientDet dengan kinerja yang sebanding. YOLOv4 mencapai nilai *Average Precision* (AP) sebesar 43.5% pada *dataset* COCO dengan kecepatan *real-time* 65 FPS, yang dapat dilihat pada garis grafik berwarna hijau. YOLOv4 menunjukkan peningkatan signifikan dibandingkan dengan YOLOv3, yaitu peningkatan *Average Precision* (AP) sebesar 10% dan *Frame Per Second* (FPS) sebesar 12%.

Detektor modern umumnya terdiri dari dua bagian utama yaitu *backbone* dan *head*. *Backbone* yang telah dilatih sebelumnya menggunakan ImageNet, digunakan untuk ekstraksi fitur. *Head* digunakan untuk memprediksi *class* dan *bounding boxes* dari objek. *Backbone* yang digunakan pada detektor yang berjalan pada *platform* GPU dapat berupa VGG, ResNet, ResNetXt, atau DenseNet. Selain itu, untuk detektor pada *platform* CPU, *backbone* yang

digunakan adalah SqueezeNet, MobileNet, atau ShuffleNet (Bochkovskiy dkk., 2020). Tahapan dari detektor dapat dilihat pada Gambar 11.



Gambar 11. Tahapan Detektor Objek (Bochkovskiy dkk., 2020).

Arsitektur YOLO terdiri dari 2 bagian utama yaitu *backbone* yang berfungsi meningkatkan akurasi sebelum dilakukan pendeteksian dan *head* yang menjadi bagian utama dalam pendeteksian. Proses deteksi diawali dengan memposisikan gambar atau video di area *input*, yang kemudian diteruskan ke bagian *backbone*. Selain kedua bagian utama tersebut, terdapat bagian lain yaitu *neck* yang berfungsi untuk menggabungkan *feature maps* dari berbagai *stage* setelah *backbone*. Pada arsitektur YOLOv4 terdiri dari 3 elemen yaitu *Backbone*: CSPDarknet53, *Neck*: SPP, dan *Head*: YOLOv3. YOLOv4 unggul dalam hal kecepatan karena termasuk dalam kategori dari *one stage detector*. Berbeda dengan *two stage detector* yang memerlukan tahap tambahan seperti *prediction* sebelum objek dapat terdeteksi, YOLOv4 mengurangi waktu deteksi dengan langsung melakukan prediksi dalam satu tahap (Bochkovskiy dkk., 2020).

2.10. Confusion Matrix

Confusion Matrix merupakan visualisasi yang digunakan untuk mengevaluasi kinerja model klasifikasi. Matriks ini menyajikan informasi tentang kelas yang sebenarnya dan kelas prediksi. Kolom dalam matriks mewakili kelas yang diprediksi, sedangkan baris mewakili kelas yang sebenarnya. *Confusion matrix* adalah alat ukur yang berbentuk matriks 2×2 yang digunakan untuk

menilai akurasi algoritma yang diterapkan. *Confusion matrix* dapat dilihat pada Tabel 2 (A'yunnisa dkk., 2022).

Tabel 2. *Confusion Matrix*

		<i>Actual Class</i>	
		<i>Class = Yes</i>	<i>Class = No</i>
<i>Class Predicted</i>	<i>Class = Yes</i>	TP (<i>True Positive</i>)	FP (<i>False Positive</i>)
	<i>Class = No</i>	FN (<i>False Negative</i>)	TN (<i>True Negative</i>)

Keterangan:

- TP : Jika data yang diprediksi bernilai positif dan sesuai dengan nilai aktual (positif)
- FP : Jika data yang diprediksi bernilai positif tidak sesuai dengan nilai aktual (negatif)
- FN : Data yang diprediksi bernilai negatif dan aktualnya bernilai positif
- TN : Jika data yang diprediksi bernilai negatif dan aktualnya negatif

Pada *confusion matrix* terdapat 4 kategori data yang dapat digunakan untuk mengukur performa dari suatu model (Kusuma dkk., 2022), yaitu:

- 1) *Accuracy*, adalah persentase benar model dalam melakukan klasifikasi. Rumus *accuracy* ditunjukkan pada Persamaan 2.

$$Accuracy = \frac{(TP+TN)}{(TP+TN+FP+FN)} \dots\dots\dots(2)$$

Pada YOLO dapat digunakan rumus pada Persamaan 3 untuk menghitung nilai *accuracy* pada deteksi objeknya (Ramadhan dkk., 2022).

$$Accuracy = \frac{Jumlah\ terdeteksi\ benar}{Jumlah\ pendeteksian} \dots\dots\dots(3)$$

- 2) *Precision*, adalah persentase model yang memprediksi benar positif dengan keseluruhan data yang diprediksi positif. Rumus *precision* ditunjukkan pada Persamaan 4.

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots(4)$$

- 3) *Recall*, adalah persentase prediksi benar positif ketika kelas *actual* data tersebut bernilai positif. Rumus *recall* dapat dilihat pada Persamaan 5.

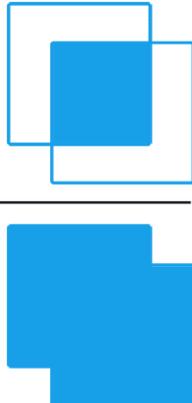
$$Recall = \frac{TP}{TP+FN} \dots\dots\dots(5)$$

- 4) *F-1 Score*, adalah rata-rata antara nilai *precision* dengan *recall* yang dibobotkan. Rumus dari *f-1 score* dapat dilihat pada Persamaan 6.

$$F-1 \text{ Score} = 2 \times \frac{(Recall \times Precision)}{(Recall+Precision)} \dots\dots\dots(6)$$

2.11. Intersection over Union (IoU)

Intersection over Union (IoU) adalah metode evaluasi yang digunakan untuk mengukur akurasi deteksi objek terhadap *dataset* yang telah dilatih. IoU mengukur kesesuaian antara dua area, yaitu area *bounding box ground-truth* (*bounding box* aktual) dan area *bounding box* yang dideteksi oleh model. IoU dihitung dengan membandingkan area irisan (*intersection*) dari kedua *bounding box* dengan area gabungan (*union*) dari kedua *bounding box* tersebut. Ilustrasi persamaan IoU dapat dilihat pada Gambar 12.

$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$


Gambar 12. *Intersection over Union* (Shianto dkk., 2019).

Intersection over Union (IoU) menghitung luas area yang berpotongan antara dua *bounding box* dan membaginya dengan luas area gabungan dari kedua *bounding box* tersebut. Nilai IoU digunakan untuk menilai seberapa baik *bounding box* yang diprediksi sesuai dengan objek sebenarnya dalam citra (*ground truth*) (Fandisyah dkk., 2021). Nilai IoU berfungsi sebagai *threshold*

dalam deteksi objek, dengan dua nilai *threshold* yang umum digunakan, yaitu 0.5 dan 0.75 (Kusuma dkk., 2021). Saat mengevaluasi algoritma deteksi objek, ambang IoU sebesar 0.5 biasanya digunakan untuk menentukan apakah deteksi dianggap benar. Namun nilai IoU = 0.5 memiliki area yang cukup longgar, sehingga umumnya diinginkan nilai IoU yang lebih besar dari 0.5 (Pramestya, 2018). Jika nilai *threshold* IoU ≥ 0.5 , maka objek deteksi sebagai *True Positive* (TP). Sedangkan ketika *threshold* IoU < 0.5 , maka objek deteksi sebagai *False Positive* (FP) (Kusuma dkk., 2021).

2.12. Average Precision (AP) dan Mean Average Precision (mAP)

Average Precision (AP) adalah standar *de facto* untuk evaluasi kinerja dalam deteksi objek. Hasil AP dan *mean-AP* sering digunakan dalam deteksi objek gambar statis, deteksi objek video, dan penelitian deteksi objek video *online*, menjadikannya sebagai kriteria utama untuk membandingkan metode deteksi objek (Oksuz dkk., 2018). Dalam perhitungan AP dapat menggunakan *N-Point Interpolation*, untuk nilai *recall* dilambangkan dengan $R_r(n)$, sedangkan untuk nilai *precision* dilambangkan dengan $Pr_{interp}(R_r n)$. Untuk persamaan dari $R_r(n)$ dapat dilihat pada persamaan 7.

$$R_r(n) = \frac{N-n}{N-1}, n = 1, 2, \dots, N \dots\dots\dots(7)$$

Sehingga untuk persamaan AP menjadi:

$$AP = \frac{1}{N} \sum_{n=1}^N Pr_{interp}(R_r(n)) \dots\dots\dots(8)$$

Persamaan 8 merupakan persamaan untuk mencari nilai AP menggunakan *N-Point Interpolation*. Biasanya nilai N yang dipakai saat mencari hasil AP adalah $N = 11$ (Padilla dkk., 2021).

Mean Average Precision (mAP) adalah matriks yang digunakan untuk mengevaluasi kinerja model deteksi objek, dan mengukur performa dari *weights file* hasil *training* data (Kusuma dkk., 2021). Nilai mAP diperoleh dengan menghitung rata-rata presisi dari item relevan yang dihasilkan, dan

menggunakan nilai 0 untuk item relevan yang tidak dihasilkan oleh sistem (Fandisyah dkk., 2021). Persamaan mAP dapat dilihat pada Persamaan 9.

$$mAP = \frac{1}{c} \sum_t^c AP_i \dots\dots\dots(9)$$

2.13. Konfigurasi *Hyperparameter*

Hyperparameter merupakan konstanta yang dapat disesuaikan dengan kebutuhan untuk memperoleh model dengan kinerja yang lebih optimal (Sutama dkk., 2020). *Hyperparameter* juga dapat digunakan untuk mengontrol algoritma dengan melakukan penyetelan agar menghasilkan prediksi yang lebih baik (Septiani & Rizal, 2021). Berikut adalah beberapa jenis *hyperparameter*.

2.13.1. *Max Batches*

Max Batches adalah parameter yang menentukan jumlah iterasi dalam proses pelatihan data. Semakin besar nilai *max batch*, maka akan semakin banyak data yang dipelajari oleh model. Jumlah data pelatihan tidak boleh melebihi nilai *max batch* karena nilai *max batches* perlu disesuaikan dengan jumlah kelas dari objek yang dideteksi (Kusuma dkk., 2021). Persamaan untuk mencari nilai *max batch* berdasarkan jumlah *class* dapat dilihat pada Persamaan 10. Apabila perhitungan nilai *max batches* kurang dari 6000, maka nilai *max batches* yang digunakan adalah 6000 (Hidayatullah, 2021).

$$Max\ batches = number\ of\ class \times 2000 \dots\dots\dots(10)$$

2.13.2. *Subdivision*

Subdivision adalah proses membagi nilai *batch* menjadi *mini-batch* yang lebih kecil. Tujuan dari *subdivision* adalah untuk mempercepat

proses *training* dan meningkatkan akurasi dengan memanfaatkan GPU secara lebih efisien. Sebagai contoh, jika menggunakan nilai *batch* sebesar 64 dan membaginya menjadi 8 *subdivisions*, maka setiap *mini-batch* akan terdiri dari 8 gambar. Proses *training* dilakukan untuk 8 gambar pada setiap mini-batch, dan diulang sebanyak 8 kali hingga proses *training* untuk satu *batch* selesai. Setelah itu sistem akan memproses ke *batch* selanjutnya yang juga memiliki nilai *batch* sebesar 64 (Kusuma dkk., 2021).

2.13.3. Steps

Steps adalah *epoch* di mana *learning rate* mengecil sesuai dengan *scale factor* atau dengan persentase dari *max batches*. *Steps* juga digunakan sebagai indikator untuk menerapkan skala pada jumlah iterasi yang ditentukan. Nilai *steps* biasanya dihitung berdasarkan 80% dan 90% dari nilai *max_batch*. (Hidayatullah, 2021).

2.13.4. Scale

Scale atau disebut juga *scale factor* digunakan sebagai pengecil *learning rate*. *Scale* pula sebagai koefisien dari *learning rate* untuk menentukan bagaimana *learning rate* akan diubah selama peningkatan jumlah iterasi pada proses *training* (Hidayatullah, 2021).

2.13.5. Momentum

Momentum adalah teknik yang digunakan untuk memperbarui bobot berdasarkan arah gradien pola terakhir dan pola sebelumnya. Nilai *momentum* berada dalam rentang antara 0 hingga 1. Jika nilai *momentum* = 0, maka perubahan bobot hanya akan dipengaruhi oleh gradien saat ini. Jika nilai *momentum* = 1, maka perubahan bobot sepenuhnya bergantung pada perubahan bobot sebelumnya (Faza, 2018).

2.13.6. *Decay*

Decay merupakan *hyperparameter* yang digunakan untuk mengurangi ketidakseimbangan dalam *dataset* dengan menurunkan nilai bobot secara bertahap selama proses *training*. Nilai *default decay* yang umum digunakan adalah 0.0005, dan nilai ini seringkali memberikan hasil bobot yang baik (Hidayatullah, 2021).

2.13.7. *Learning Rate*

Learning rate adalah parameter yang menentukan seberapa besar perubahan bobot selama proses *back propagation*. *Learning rate* juga mempengaruhi kecepatan iterasi untuk mencapai nilai minimum dari *loss function*. Semakin tinggi nilai *learning rate*, maka semakin cepat proses *training*. Namun *learning rate* terlalu tinggi, dapat menyebabkan nilai *loss function* naik-turun tidak menentu.

2.13.8. *Filters*

Filters dalam parameter ini merujuk pada jumlah *filter* yang digunakan dalam lapisan konvolusi. Penentuan jumlah filter disesuaikan dengan jumlah *class* yang ingin dideteksi dalam model (Hidayatullah, 2021). Perhitungan filter dapat dilihat pada Persamaan 11.

$$\text{Filters} = (\text{jumlah kelas} + 5) \times 3 \dots\dots\dots(11)$$

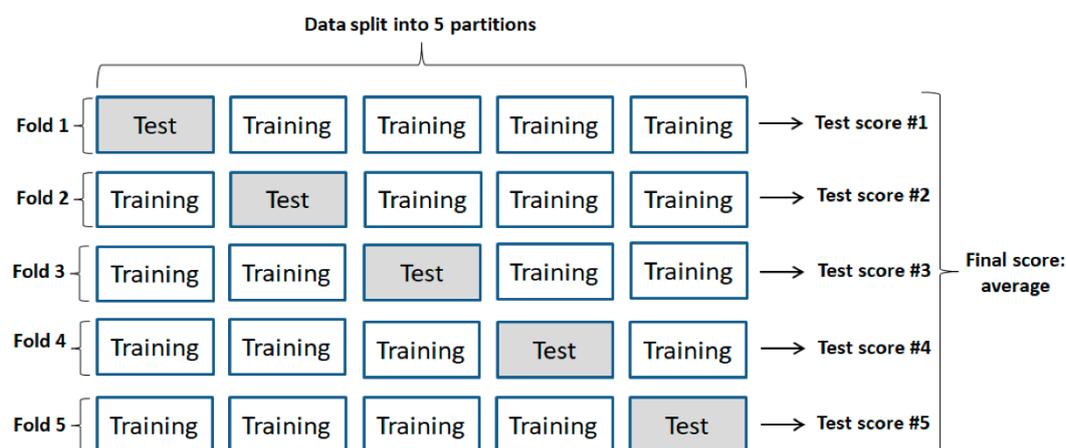
2.13.9. *Classes*

Classes adalah parameter yang menunjukkan jumlah objek *class* yang akan digunakan selama proses *training* atau pelatihan. Jumlah *class* yang digunakan harus sesuai dengan objek *class* pada data yang telah dianotasi (Hidayatullah, 2021).

2.14. K-Fold Cross validation

Cross validation atau validasi silang adalah metode *resampling* data untuk menilai kemampuan generalisasi model prediktif untuk mencegah *overfitting*. *Cross validation* merupakan salah satu metode yang paling umum digunakan untuk memperkirakan kesalahan prediksi sebenarnya dari model dan untuk menyesuaikan parameter model. Salah satu teknik dari *cross validation* adalah *k-fold cross validation* (Berrar, 2019). Dalam *k-fold cross validation*, *dataset* yang tersedia akan dipisahkan menjadi k bagian dengan jumlah data atau ukuran yang sama.

Cara kerja *k-fold cross validation* melibatkan pengelompokan data latih dan data uji yang saling terpisah, kemudian melakukan pengujian yang diulang sebanyak k kali (Jamaludin dkk., 2021). Model dilatih menggunakan $k-1$ bagian dari *dataset* sebagai data latih, dan diuji pada bagian *dataset* yang tersisa sebagai data uji untuk mengukur kinerjanya pada setiap *fold*. Prosedur ini diulang hingga setiap bagian *dataset* k telah digunakan sebagai data uji. Hasil dari setiap *fold* kemudian dirata-ratakan untuk menghasilkan nilai prediksi akhir (Jung, 2018).



Gambar 13. 5-Fold Cross Validation (Phung & Rhee, 2019).

Gambar 13 mengilustrasikan proses pada *k-fold cross validation*, dengan menggunakan nilai $k = 5$. Pada proses pertama, bagian pertama *dataset* berfungsi sebagai *test set*, sementara empat bagian *dataset* lainnya berfungsi

sebagai *training set*. Pada proses kedua, bagian *dataset* kedua berfungsi sebagai *test set* dan *dataset* yang tersisa sebagai *training set*, dan seterusnya (Berrar, 2019).

2.15. Python

Python merupakan bahasa pemrograman tingkat tinggi yang dikembangkan oleh Guido Van Rossum dan pertama kali dirilis pada tahun 1991 di Scitcing Mathematisch Centrum, Belanda. Python merupakan bahasa pemrograman yang multi fungsi, salah satunya yaitu dapat digunakan dalam bidang *machine learning* dan *deep learning*. Python terkenal dengan sintaksisnya yang mudah dipahami dan memiliki *library* yang lengkap serta bersifat *open source*. Beberapa *Integrated Development Environment* (IDE) yang digunakan untuk menuliskan *source code* Python yaitu Visual Studio Code, Sublime Text, PyCharm, serta IDE *online* seperti Jupyter Notebook dan Google Colaboratory (Alfarizi dkk., 2023). Beberapa *library* Python yang dapat digunakan pada *machine learning* dan *deep learning* yaitu:

2.10.1. Numpy

Library Numpy menyediakan fungsi matematika dengan kompleksitas tinggi yang dapat digunakan untuk memproses *array* dan matriks multidimensi. *Numpy* berguna untuk memproses aljabar linear, transformasi Fourier, dan operasi dengan bilangan acak (Alfarizi dkk., 2023). Salah satu keuntungan dari *library Numpy* adalah memori yang digunakan sedikit serta kemampuannya untuk berjalan dengan sangat cepat (Amrozi dkk., 2022).

2.10.2. OpenCV

Open Computer Vision (OpenCV) merupakan *library open source* yang dirancang khusus untuk pengolahan citra agar memungkinkan

komputer untuk memproses gambar dan video dengan cara yang mirip dengan penglihatan manusia. *OpenCV* menyediakan berbagai algoritma dasar untuk visi komputer dan menyediakan modul pendeteksian objek (Prasetya & Nurviyanto, 2012).

2.10.3. Pillow (PIL)

Pillow merupakan *Python Imaging Library* (PIL) yang digunakan untuk membuka, memanipulasi, dan menyimpan gambar. *Pillow* mempermudah proses pengelolaan citra karena membutuhkan kode yang lebih sedikit dibandingkan dengan *library* lain, terutama saat bekerja dengan gambar dalam skala keabuan (Utami dkk., 2021).

2.10.4. Pandas

Pandas merupakan *library* Python yang digunakan untuk keperluan data analisis, seperti menyelaraskan data, menangani data yang hilang, manipulasi data, pembersihan data, penggabungan, dan lain sebagainya (Fadilla dkk., 2020). *Pandas* menjadi salah satu *library* paling populer untuk menganalisis karena memiliki struktur data yang cepat, fleksibel, dan ekspresif, sehingga cocok digunakan pada data yang bersifat “relasional” atau “berlabel” (Alfarizi dkk., 2023).

2.10.5. Scikit Learn

Library Scikit Learn adalah *library machine learning* yang *open source* untuk Python. Beberapa fitur utama yang tersedia di *library Scikit Learn* meliputi regresi, klasifikasi, seperti *gradient boosting*, *k-means*, *Support Vector Machine* (SVM), DBSCAN, serta integrasi dengan *library SciPy* dan *NumPy* (Amrozi dkk., 2022).

III. METODOLOGI PENELITIAN

3.1. Tempat dan Waktu Penelitian

Berikut adalah pemaparan tempat penelitian dan waktu pada penelitian ini.

3.1.1. Tempat Penelitian

Penelitian ini dilakukan di Laboratorium Komputasi Dasar MIPA T lantai 3, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung yang beralamat di Jalan Prof. Dr. Ir. Sumantri Brojonegoro No. 1, Gedong Meneng, Kota Bandar Lampung.

3.1.2. Waktu Penelitian

Penelitian dilakukan pada bulan Maret 2023 hingga penyelesaian pada bulan Maret 2024. Alur waktu penelitian dapat dilihat pada Tabel 3.

Tabel 3. *Timeline* Penelitian

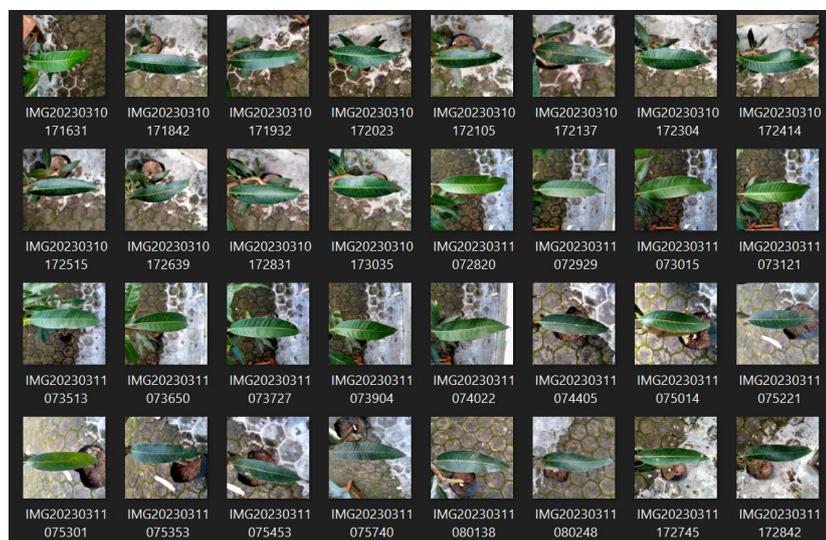
Tahapan	Kegiatan	2023										2024			
		Mar	Apr	Mei	Jun	Jul	Ag	Sep	Okt	Nov	Des	Jan	Feb	Mar	
Penelitian Awal	Studi literatur	■													
	Pengumpulan data		■	■	■	■	■	■							
	Penyusunan draft (Bab I-III)	■	■	■	■	■	■								
Penelitian Lanjutan	<i>Pre-processing</i>					■	■	■							
	Anotasi data						■	■	■	■	■	■	■	■	■
	Pelatihan Model YOLO							■	■	■	■	■	■	■	■
	Pengujian Model								■	■	■	■	■	■	■
	Penyusunan draft (Bab IV-V)										■	■	■	■	■
Evaluasi	Revisi skripsi												■	■	■

3.2. Data dan Alat Pendukung

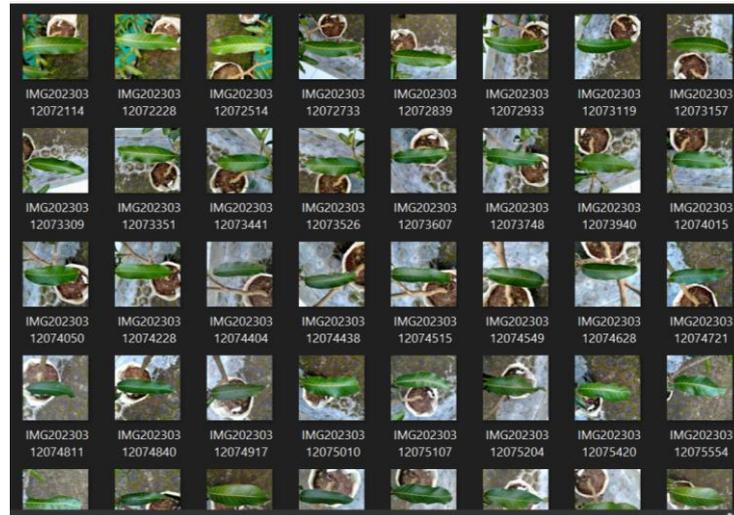
Adapun data dan alat yang digunakan untuk melakukan penelitian ini adalah sebagai berikut.

3.2.1. Data

Data yang digunakan pada penelitian ini adalah data primer yang didapatkan melalui pengambilan gambar secara langsung dengan menggunakan kamera *smartphone*. Setiap pengambilan gambar daun menggunakan kamera *smartphone* yang sama. Data yang digunakan sebanyak 500 data citra daun mangga irwin dan 500 citra daun mangga okyong, mangga sehingga keseluruhan data citra yang digunakan berjumlah 1000 data citra dengan format JPG/JPEG. Setiap data *image* daun mangga irwin dan daun mangga okyong memiliki ukuran 3000×3000 piksel. *Dataset* daun mangga irwin, dan daun mangga okyong dapat dilihat pada Gambar 14 dan Gambar 15.



Gambar 14. *Dataset* Daun Mangga Irwin Australia.



Gambar 15. *Dataset* Daun Mangga Okyong Thailand.

3.2.2. Alat

Alat pendukung yang digunakan dalam penelitian ini terbagi menjadi dua jenis, yaitu perangkat keras dan perangkat lunak.

3.2.2.1. Perangkat Keras (*Hardware*)

Perangkat keras yang digunakan pada penelitian ini adalah sebuah laptop dan *smartphone* dengan spesifikasi sebagai berikut:

1) Laptop Lenovo Ideapad Slim 3

- a) *Processor* : AMD Ryzen 5 4500U
- b) *Installed RAM* : 8 GB
- c) *GPU* : Integrated AMD Radeon Graphics
- d) *Penyimpanan* : SSD 512 GB

2) *Smartphone* OPPO A5 2020

- a) *RAM* : 3 GB
- b) *Memori internal* : 64 GB
- c) *Kamera belakang* : 12 MP

3.2.2.2. Perangkat Lunak (*Software*)

Perangkat lunak yang digunakan dalam penelitian ini sebagai berikut:

- a) Sistem Operasi : Windows 10 Home Single Language 64-bit
- b) Pengukur intensitas cahaya : Light Meter
- c) *Text Editor* : Jupyter Notebook dan Google Colab
- d) *Web Browser*
- e) Bahasa pemrograman Python 3

Python merupakan bahasa pemrograman yang digunakan untuk *machine learning* dan *deep learning*. Python memiliki sintaks yang mudah dipahami dan memiliki library yang lengkap serta bersifat open source.

- f) *Numpy*

Numpy merupakan *library* Python digunakan untuk memproses *array* dan matriks multidimensi. *Numpy* dapat memproses aljabar linear, transformasi Fourier, dan bilangan acak.

- g) *Scikit Learn*

Scikit Learn dapat digunakan untuk pemodelan data science yang memiliki fitur utama yaitu regresi, klasifikasi, *k-means*, *SciPy*, dan sebagainya.

- h) *Pillow (PIL)*

PIL berfungsi untuk mempermudah pengolahan citra dalam membuka, menggunakan, dan menyimpan gambar.

- i) *Darknet*

Darknet merupakan *framework* pada *neural network* yang bersifat *open source*. *Framework darknet* dibuat menggunakan bahasa C dan CUDA. Kelebihan *darknet*

yaitu cepat, mudah dalam penginstallan, dan mendukung untuk komputasi pada CPU dan GPU.

j) *OpenCV*

OpenCV, dikhususkan untuk melakukan pengolahan citra agar komputer memiliki kemampuan yang mirip dengan cara pengolahan visual pada manusia dan menyediakan modul pendeteksian objek.

k) *CMake*

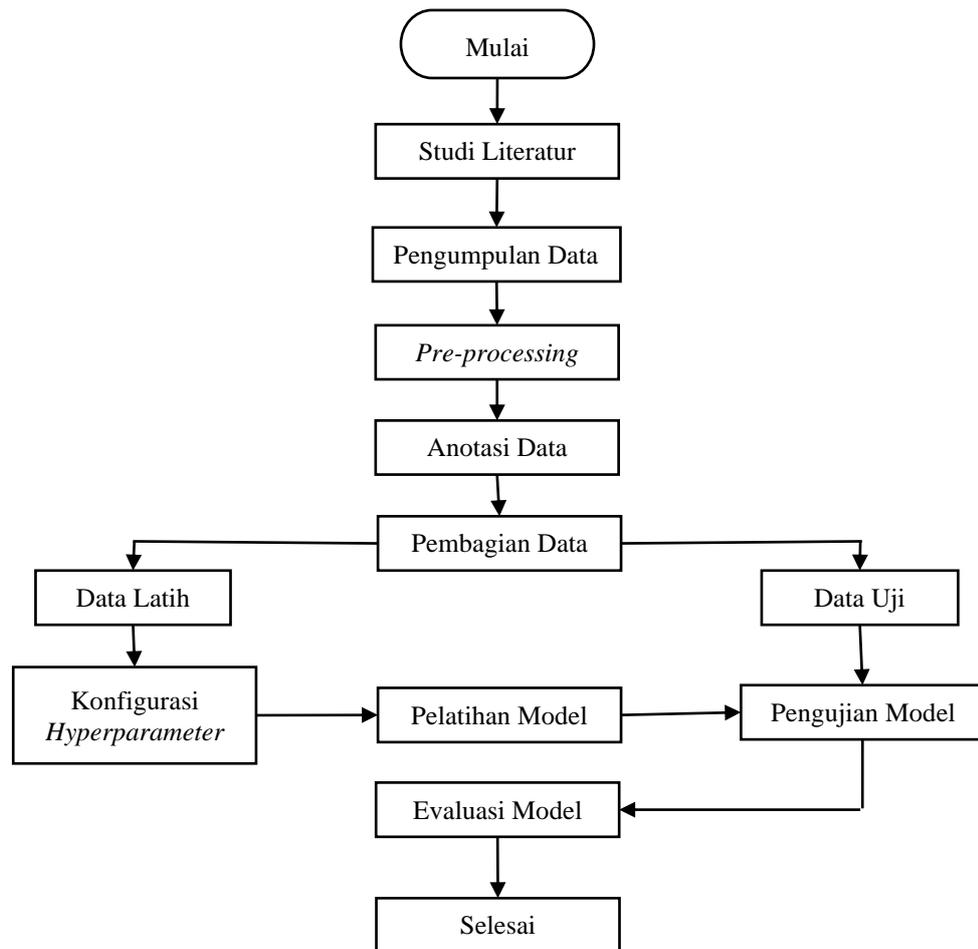
CMake merupakan *build tools* yang digunakan untuk *built*, *testing*, dan *packaging*. *CMake* sering digunakan untuk membantu proses pengembangan aplikasi yang dibangun dengan C++.

l) YOLOv4

YOLOv4 merupakan pengembangan dari YOLO yang menjadi *state of the art* dari model deteksi berbasis *deep learning*.

3.3. Alur Kerja Penelitian

Tahapan yang dilakukan pada penelitian ini dapat dilihat pada Gambar 16.



Gambar 16. Alur Penelitian.

Penjelasan dari setiap tahapan pada Gambar 16 adalah sebagai berikut:

3.3.1. Studi Literatur

Pada tahap studi literatur dilakukan pencarian dan pengumpulan informasi dari sumber teori valid. Pencarian data dan informasi didapatkan dari beberapa sumber yaitu melalui jurnal penelitian terdahulu, buku-buku, dan artikel ilmiah yang dapat memperkuat penelitian yang sedang dilakukan.

3.3.2. Pengumpulan Data

Pada penelitian ini, data yang digunakan adalah citra daun dari bibit mangga. Penelitian ini menggunakan 2 kelas yaitu daun mangga irwin

dan daun mangga okyong. Data yang digunakan berupa data primer yang didapatkan melalui pengambilan gambar secara langsung menggunakan kamera *smartphone* dengan intensitas cahaya di luar ruangan sebesar 4000 LUX – 8000 LUX tanpa pengaturan cahaya tambahan. Pengambilan data citra daun dilakukan di dua tempat penjualan bibit yaitu grosir bibit buah Rusmi yang beralamat di Jl. ZA. Pagar Alam No. 10, Rajabasa, Kota Bandar Lampung, dan Tabulampot Lampung yang beralamat di Jl. Darussalam No. 82, Susunan Baru, Kec. Tanjung Karang Barat, Kota Bandar Lampung. Jumlah data yang diambil untuk setiap varietas mangga adalah 500 citra daun mangga irwin dan 500 citra daun mangga okyong, sehingga keseluruhan data citra yang digunakan berjumlah 1000 data citra dengan format JPG/JPEG. Setiap data yang diambil dengan menggunakan kamera *smartphone* memiliki ukuran 3000×3000 piksel dengan ekstensi JPG/JPEG.

3.3.3. Pre-processing

Tahap *pre-processing* merupakan tahap pengolahan data gambar agar data mudah untuk diolah pada tahap selanjutnya. *Pre-processing* data yang dilakukan pada penelitian ini adalah *resize image*. *Resize image* dilakukan dengan mengubah ukuran piksel dan dimensi pada gambar agar sesuai dengan kebutuhan penelitian sehingga setiap gambar memiliki rasio yang sama. Pada penelitian ini, ukuran piksel setiap data diubah menjadi ukuran 416×416 *pixels* sesuai dengan ketentuan literatur (Kusuma dkk., 2021) yang menyesuaikan ukuran standar dari YOLO.

3.3.4. Anotasi Data

Anotasi data yang dilakukan adalah membuat label dengan cara memberikan kotak batas (*bounding box*) beserta nama kelas pada

objek di setiap citra. Pada penelitian ini, proses anotasi data dilakukan dengan menggunakan perangkat lunak Yolo_mark.

3.3.5. Pembagian Data

Proses pembagian data dilakukan setelah proses anotasi data. Data dibagi menjadi dua jenis, yaitu data latih dan data uji. Data latih adalah data yang akan digunakan untuk pelatihan pada model deteksi objek YOLOv4, sedangkan data uji adalah data yang akan digunakan pada proses pengujian untuk mengetahui kinerja dari model YOLOv4 yang telah dilatih. Data citra yang digunakan dalam penelitian ini adalah 500 citra daun mangga irwin dan 500 citra daun mangga irwin. Pembagian data dalam deteksi objek YOLOv4 yaitu 80% sebagai data latih, dan 20% sebagai data uji pada deteksi objek YOLOv4 berdasarkan literatur (Harun & Kharisma, 2023) yang melakukan beberapa kali *training* dengan pembagian data yang berbeda, dan mendapatkan model terbaik dengan nilai mAP tertinggi pada pembagian data 80:20.

3.3.6. Konfigurasi *Hyperparameter*

Hyperparameter merupakan konstanta yang dapat disesuaikan dengan kebutuhan untuk mendapatkan model yang hasil kinerja yang lebih optimal. Konfigurasi yang dilakukan adalah menyesuaikan nilai *hyperparameter*. Beberapa *hyperparameter* dalam pelatihan model yang dirancang adalah *batch*, *subdivision*, *width* dan *height*, *max_batch*, *steps*, *scale*, *momentum*, *decay*, *learning rate*, *filters*, dan *classes*.

3.3.7. Pelatihan dan Pengujian Model

Tahap pelatihan model adalah proses untuk menjalankan algoritma YOLOv4 agar dapat belajar mengenali pola dari *dataset* yang diberikan. Lalu pada tahap pengujian model dilakukan dengan

menggunakan data uji untuk menguji model yang telah dibuat sebelumnya apakah dapat mendeteksi dan mengklasifikasi varietas bibit mangga impor dengan baik atau belum. Pada proses *training* atau pelatihan model dilakukan dengan teknik *k-fold Cross validation* dengan nilai *k* adalah 5 berdasarkan literatur (Agustin & Prasetyo, 2011) dan (Islam dkk., 2019). Penelitian (Agustin & Prasetyo, 2011) melakukan klasifikasi daun mangga dengan menggunakan *k-fold cross validation* yaitu dengan nilai $k = 5, 6, 10$, dan memperoleh kinerja terbaik pada *5-fold cross validation* pada salah satu metode. Pada penelitian (Islam dkk., 2019) menggunakan *5-fold cross validation* pada klasifikasi daun menggunakan algoritma YOLO.

3.3.8. Evaluasi Model

Proses evaluasi model dilakukan untuk mengetahui tingkat keakuratan dari suatu model. Keakuratan kinerja model YOLOv4 dapat diuji dengan menghitung nilai *Intersection over Union* (IoU) antara prediksi *bounding box* dengan *bounding box* sebenarnya. Nilai *Intersection over Union* (IoU) tersebut akan digunakan pada *confusion matrix* untuk menghitung *accuracy*, *recall*, *precision*, *f1-score*, dan mAP.

V. PENUTUP

5.1. Simpulan

Berdasarkan penelitian yang telah dilakukan mengenai klasifikasi citra daun mangga impor menggunakan algoritma YOLOv4, dapat diambil beberapa kesimpulan sebagai berikut.

1. YOLOv4 dapat mengklasifikasikan citra daun mangga impor, di mana model dapat membuat *bounding box* setiap objek yang ada di dalam citra dan menampilkan kelas dari objek tersebut.
2. Dalam proses pelatihan menggunakan *5-fold cross validation* menghasilkan model dengan nilai rata-rata mAP 99.05%, *accuracy* 0.917, *precision* 0.918, *recall* 0.980, dan *f1-score* 0.947. Pada pengujian model menggunakan 20% dari keseluruhan *dataset* memperoleh nilai mAP 98.48%, *accuracy* 0.895, *precision* 0.894, *recall* 0.975, dan *f1-score* 0.933.

5.2. Saran

Adapun saran yang diberikan untuk penelitian selanjutnya sebagai berikut.

1. Memperbanyak *dataset* baru dengan kualitas gambar yang baik dan jelas agar model yang dihasilkan memiliki kinerja yang lebih baik.
2. Menambahkan jumlah kelas objek baru pada daun mangga impor.

3. Setiap citra yang digunakan tidak hanya berisi satu objek di dalamnya, agar model dapat mengklasifikasikan beberapa objek di dalam satu citra dengan baik.
4. Pada penelitian selanjutnya dapat memodifikasi model YOLOv4 atau menggunakan algoritma YOLO versi lain untuk meningkatkan hasil kinerjanya.

DAFTAR PUSTAKA

- A'ayunnisa, N., Salim, Y., & Azis, H. (2022). Analisis Performa Metode Gaussian Naïve Bayes untuk Klasifikasi Citra Tulisan Tangan Karakter Arab. *Indonesian Journal of Data and Science*, 3(3), 115–121.
- Abu, A. (2017). Mengenal Artificial Intelligence, Machine Learning, & Deep Learning. *Jurnal Teknologi Indonesia*, 1(June), 1–6. <https://amt-it.com/mengenal-perbedaan-artificial-intelligence-machine-learning-deep-learning/>
- Agromedia, R. (2011). *Bertanam Mangga Di Dalam Pot & Di Kebun*. AgroMedia.
- Agustin, S., & Prasetyo, E. (2011). Klasifikasi Jenis Pohon Mangga Gadung dan Curut Berdasarkan Tesktur Daun. *SESINDO 2011-Jurusan Sistem Informasi ITS*, 58, 64.
- Alfarizi, M. R. S., Al-farish, M. Z., Taufiqurrahman, M., Ardiansah, G., & Elgar, M. (2023). Python Sebagai Bahasa Pemrograman Penggunaan Python Sebagai Bahasa Pemrograman untuk Machine Learning dan Deep Learning. *KARIMAH TAUHID*, 2(1).
- Amrozi, Y., Yuliati, D., Susilo, A., Novianto, N., & Ramadhan, R. (2022). Klasifikasi Jenis Buah Pisang Berdasarkan Citra Warna dengan Metode SVM. *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, 11(3), 394–399.
- Berrar, D. (2019). Cross-Validation. *Encyclopedia of Bioinformatics and Computational Biology*, 1, 542–545.
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. *arXiv preprint arXiv:2004.10934*.
- Deng, L., & Yu, D. (2013). Deep Learning: Methods and Applications. *Foundations and Trends in Signal Processing*, 7(3–4), 197–387. <https://doi.org/10.1561/20000000039>
- Fadilla, R., Andarsyah, R., Awangga, R. M., & Habibi, R. (2020). *Data Analytics: Peningkatan Performa Algoritma Rekomendasi Collaborative Filtering Menggunakan K-Means Clustering*. Kreatif.

- Fandisyah, A. F., Iriawan, N., & Winahju, W. S. (2021). Deteksi Kapal di Laut Indonesia Menggunakan YOLOv3. *Jurnal Sains dan Seni ITS*, 10(1), D25–D32.
- Faza, S. (2018). *Peningkatan Kinerja Dalam Pengklasifikasian Menggunakan Deep Learning*. Universitas Sumatera Utara.
- Fitrianingsih, F., & Rodiah, R. (2021). Klasifikasi Jenis Citra Daun Mangga Menggunakan Convolutional Neural Network. *Jurnal Ilmiah Teknologi dan Rekayasa*, 25(3), 223–238.
- Goodfellow, Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Gunastri, C. T. (2012). *Mangga Top di Kebun dan Pot*. Penebar Swadaya Grup.
- Harun, A., & Kharisma, O. B. (2023). Implementasi Deep Learning Menggunakan Metode You Only Look Once untuk Mendeteksi Rokok. *Jurnal Media Informatika Budidarma*, 7(1).
- Hidayat, D. (2022). Klasifikasi Jenis Mangga Berdasarkan Bentuk dan Tekstur Daun Menggunakan Metode Convolutional Neural Network(CNN) Classification of Types of Mango Based on Leave Shape and Texture Using Convolutional Neural Network(CNN) Method. *Journal of Information Technology and Computer Science (INTECOMS)*, 5(1).
- Hidayatullah, P. (2021). Buku Sakti Deep Learning Computer Vision Menggunakan Yolo untuk Pemula. *Stunning Vision AI Academy*.
- Huang, R., Pedoeem, J., & Chen, C. (2018). YOLO-LITE: a Real-Time Object Detection Algorithm Optimized for Non-GPU Computers. *2018 IEEE international conference on big data (big data)*, 2503–2510.
- Islam, M. K., Habiba, S. U., & Ahsan, S. M. M. (2019). Bangladeshi Plant Leaf Classification and Recognition Using YOLO Neural Network. *2019 2nd International Conference on Innovation in Engineering and Technology (ICIET)*, 1–5.
- Jamaludin, J., Rozikin, C., & Irawan, A. S. Y. (2021). Klasifikasi Jenis Buah Mangga dengan Metode Backpropagation. *Techné: Jurnal Ilmiah Elektroteknika*, 20(1), 1–12.
- Jung, Y. (2018). Multiple Predicting K-Fold Cross-Validation for Model Selection. *Journal of Nonparametric Statistics*, 30(1), 197–215.
- Kusuma, T. A. A. H., Usman, K., & Saidah, S. (2021). People Counting for Public Transportations Using You Only Look Once Method. *Jurnal Teknik Informatika (Jutif)*, 2(1), 57–66. <https://doi.org/10.20884/1.jutif.2021.2.2.77>
- Mailoa, R. M., & Santoso, L. W. (2022). Deteksi Rompi dan Helm Keselamatan Menggunakan Metode YOLO dan CNN. *Jurnal Infra*, 10(2), 56–62.

- O'Shea, K., & Nash, R. (2015). An Introduction to Convolutional Neural Networks. *arXiv preprint arXiv:1511.08458*.
- Oktilas, A. F., Dwinta, D., Shofi, G., Mariza, N. P., Kinanti, S. A., & Sari, Y. A. (2023). Akurasi Pengujian Model Hasil Training Menggunakan YOLOv4 untuk Pengenalan Kendaraan di Jalan Raya. *JUPITER: Jurnal Penelitian Ilmu dan Teknologi Komputer*, 15(1d), 799–806.
- Oksuz, K., Cam, B. C., Akbas, E., & Kalkan, S. (2018). Localization Recall Precision (LRP): a New Performance Metric for Object Detection. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11211 LNCS, 521–537. https://doi.org/10.1007/978-3-030-01234-2_31
- Padilla, R., Passos, W. L., Dias, T. L. B., Netto, S. L., & Da Silva, E. A. B. (2021). A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit. *Electronics (Switzerland)*, 10(3), 1–28. <https://doi.org/10.3390/electronics10030279>
- Paturrahman, A. A., & Wijaya, I. G. P. S. (2021). Analisis Pengenalan Pola Daun Berdasarkan Fitur Canny Edge Detection dan Fitur GLCM Menggunakan Metode Klasifikasi k-Nearest Neighbor (kNN). *Journal of Computer Science and Informatics Engineering (J-Cosine)*, 5(1), 68–76. <https://doi.org/10.29303/jcosine.v5i1.388>
- Pramestya, R. H. (2018). Deteksi dan Klasifikasi Kerusakan Jalan Aspal Menggunakan Metode YOLO Berbasis Citra Digital. *Institut Teknologi Sepuluh Nopember*.
- Prasetya, D. A., & Nurviyanto, I. (2012). *Deteksi Wajah Metode Viola Jones pada OpenCV Menggunakan Pemrograman Python*.
- Purwanto, E. H., & Lukiawan, R. (2019). Parameter Teknis dalam Usulan Standar Pengolahan Penginderaan Jauh: Metode Klasifikasi Terbimbing. *Jurnal Standardisasi*, 21(1), 67–78.
- Rahayu, A. P., Honainah, H., & Pawening, R. E. (2016). Klasifikasi Jenis Mangga Berdasarkan Bentuk dan Tekstur Daun Menggunakan Metode K-Nearest Neighbor. *SENTIA 2016*, 8(1).
- Rahim, A., Kusri, K., & Luthfi, E. T. (2020). Convolutional Neural Network untuk Kalasifikasi Penggunaan Masker. *Inspiration: Jurnal Teknologi Informasi dan Komunikasi*, 10(2), 109. <https://doi.org/10.35585/inspir.v10i2.2569>
- Ramadhan, M. N., Utaminingrum, F., & Syauqy, D. (2022). Deteksi Tangga Naik dan Turunan untuk Notifikasi Keamanan pada Tunanetra menggunakan YOLO Versi 4 berbasis Jetson Nano B01. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 6(1), 370–375.

- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 779–788.
- Retnoningsih, E., & Pramudita, R. (2020). Mengenal Machine Learning dengan Teknik Supervised dan Unsupervised Learning Menggunakan Python. *Bina Insani Ict Journal*, 7(2), 156–165.
- Rohim, A., Sari, Y. A., & Tibyani, T. (2019). Convolution Neural Network (CNN) untuk Pengklasifikasian Citra Makanan Tradisional. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(7), 7037–7042.
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN computer science*, 2(3), 160.
- Septiani, A., & Rizal, A. (2021). Klasifikasi Suara Paru Normal dan Abnormal dengan Menggunakan Discrete Wavelet Transform dan Support Vector Machine. *e-Proceeding of Engineering*, 8(1), 731–742.
- Setyaningsih, E. R., & Edy, M. S. (2022). YOLOv4 dan Mask R-CNN untuk Deteksi Kerusakan pada Karung Komoditi. *Teknika*, 11(1), 45–52.
- Sharma, S., & Chaudhary, P. (2023). Machine Learning and Deep Learning. *Quantum Computing and Artificial Intelligence: Training Machine and Deep Learning Algorithms on Quantum Computers*, 71–84. <https://doi.org/10.1515/9783110791402-004>
- Suhendri, S., Muharam, F. M., & Aelani, K. (2017). Implementasi Support Vector Machine (SVM) untuk Klasifikasi Jenis Daun Mangga Menggunakan Metode Gray Level Co-Occurrence Matrix. *KOPERTIP: Jurnal Ilmiah Manajemen Informatika dan Komputer*, 1(3), 93–100.
- Sutama, V. A., Wibowo, S. A., & Rahmania, R. (2020). Investigasi Pengaruh Step Training pada Metode Single Shot Multibox Detector untuk Marker dalam Teknologi Augmented Reality. *Jurnal Ilmiah FIFO*, 12(1), 1. <https://doi.org/10.22441/fifo.2020.v12i1.001>
- Utami, F., Suhendri, S., & Mujib, M. A. (2021). Implementasi Algoritma Haar Cascade pada Aplikasi Pengenalan Wajah. *Journal of Information Technology*, 3(1), 33–38.
- Voulodimos, A., Doulamis, N., Doulamis, A., & Protopadakis, E. (2018). Deep Learning for Computer Vision: A Brief Review. *Computational Intelligence and Neuroscience*, 2018. <https://doi.org/10.1155/2018/7068349>
- Wahyuni, S., & Sulaeman, M. (2022). Penerapan Algoritma Deep Learning Untuk Sistem Absensi Kehadiran Deteksi Wajah Di PT Karya Komponen Presisi. *Jurnal Informatika SIMANTIK*, 7(1), 12–21.

- Wibowo, S. (2017). Penentuan Jenis Buah Mangga Berdasarkan Bentuk Daun Menggunakan Metode K-Means. *Simki-Techsain*, 1(12), 16–24.
- Yang, Y. (2021). Waste Classification Based On Yolov4. *JOURNAL OF SIMULATION*, 9(6), 79.
- Yuan, W. (2023). Accuracy Comparison of YOLOv7 and YOLOv4 Regarding Image Annotation Quality for Apple Flower Bud Classification. *AgriEngineering*, 5(1), 413–424.