

# Implementasi Convolutional Neural Network untuk Klasifikasi Tingkat Kematangan Buah Nanas Menggunakan YOLOv8

Syadina A. Prasetya<sup>1</sup>, Mihuandayani<sup>2\*</sup>, Yansen Abast<sup>1</sup>, Michael Mangole<sup>1</sup>, Jonathan Rahman<sup>1</sup>

<sup>1</sup>Teknik Informatika, STMIK Multicom Bolaang Mongondow, Kotamobagu, Indonesia

<sup>2</sup>Sistem Informasi, STMIK Multicom Bolaang Mongondow, Kotamobagu, Indonesia

Email: <sup>1</sup>syadinap@gmail.com, <sup>2\*</sup>mihuandayani20@gmail.com, <sup>3</sup>yansenabast25@gmail.com, <sup>4</sup>michaelmangole28@gmail.com, <sup>5</sup>jonatanbaka@gmail.com

Email Penulis Korespondensi: mihuandayani20@gmail.com

Submitted: 23/06/2024; Accepted: 30/06/2024; Published: 30/06/2024

**Abstrak**—Klasifikasi kematangan buah merupakan tahap penting dalam bidang pertanian dan pengolahan makanan, memastikan standar kualitas produk yang optimal. Terkhusus pada buah nanas, menilai tingkat kematangan secara manual membutuhkan waktu dan pengalaman yang cukup lama. Berdasarkan data di Dinas Perdagangan Bolaang Mongondow tahun 2019 ada sekitar 8,75% buah nanas di Desa Lobong yang merupakan desa penghasil buah nanas terbesar di Bolaang Mongondow Raya yang busuk atau terbuang begitu saja, yang artinya ada waktu tertentu masa panen buah nanas tidak tepat waktu. Sebagai respon terhadap tantangan ini, penelitian dilakukan untuk memperkenalkan metodologi deep learning yang memanfaatkan algoritma Convolutional Neural Network (CNN) dengan YOLOv8 (You Only Look Once) versi 8 untuk secara otonom mengklasifikasikan tahap kematangan buah nanas. Dengan mengembangkan sistem klasifikasi tingkat kematangan buah nanas menggunakan algoritma YOLO, diharapkan dapat mengatasi permasalahan tersebut, dan membantu para petani dalam menentukan tingkat kematangan buah nanas untuk proses penjualan dan pengolahan buah nanas. Penggunaan CNN dengan YOLOv8 dikarenakan dapat dengan cepat dan akurat mendeteksi objek berdasarkan citra secara realtime. Selain itu, model YOLOv8 yang telah terlatih dapat mengklasifikasikan tingkat kematangan buah nanas, sehingga dapat membantu petani dalam memilah buah berdasarkan tingkat kematangan. Pengujian yang dilakukan untuk mengukur kinerja algoritma YOLOv8 dalam mendeteksi dan mengklasifikasikan tingkat kematangan buah nanas menunjukkan hasil yang baik dengan nilai mAP 81%, Precision 70,5%, Recall 75,9%, yang menghasilkan tingkat akurasi cukup memuaskan dengan beragam tingkat. Penelitian ini bisa mengoptimalkan proses sortir tingkat kematangan buah nanas, sehingga dapat meningkatkan kualitas produk dan daya saing petani di pasar domestik maupun ekspor.

**Kata Kunci:** Klasifikasi; CNN; YOLOv8; Buah Nanas; Kematangan

**Abstract**—Classifying fruit ripeness is a crucial stage in agriculture and food processing, ensuring optimal product quality standards. Specifically for pineapples, assessing ripeness manually requires considerable time and experience. According to data from the Bolaang Mongondow Department of Trade in 2019, around 8.75% of pineapples in Lobong Village—the largest pineapple-producing village in Bolaang Mongondow Raya—were spoiled or wasted, indicating that the harvest timing for pineapples was often inaccurate. In response to this challenge, research was conducted to introduce a deep learning methodology utilizing the Convolutional Neural Network (CNN) with YOLOv8 (You Only Look Once) version 8 to autonomously classify the ripeness stages of pineapples. By developing a pineapple ripeness classification system using the YOLO algorithm, it is expected to address these issues and assist farmers in determining the ripeness level of pineapples for sales and processing purposes. The use of CNN with YOLOv8 is chosen due to its ability to quickly and accurately detect objects based on images in real time. Additionally, the trained YOLOv8 model can classify the ripeness levels of pineapples, thereby helping farmers sort the fruit according to its ripeness stage. Tests conducted to measure the performance of the YOLOv8 algorithm in detecting and classifying pineapple ripeness showed promising results with an mAP value of 81%, Precision of 70.5%, and Recall of 75.9%, producing a satisfactory level of accuracy across various levels. This research can optimize the process of sorting pineapple ripeness stages, thereby improving product quality and enhancing farmers' competitiveness in both domestic and export markets.

**Keywords:** Classification; CNN; YOLOv8; Pineapple; Ripeness

## 1. PENDAHULUAN

Buah nanas merupakan buah tropis yang memiliki kulit berdaging tebal dengan tonjolan-tonjolan yang kasar. Daging buahnya berwarna kuning atau kuning kehijauan, dengan rasa yang manis dan sedikit asam. Nanas sering digunakan dalam berbagai masakan, salad, atau dimakan segar sebagai buah penutup. Buah ini juga kaya akan vitamin C dan serat, sehingga baik untuk kesehatan pencernaan dan sistem kekebalan tubuh. Ciri-ciri dan proses kematangan buah nanas bisa dilihat dari warna kulit, aroma, tekstur kulit, tonjolan-tonjolan, dan rasa. Buah nanas dapat dipercepat dengan menyimpannya pada suhu ruangan yang hangat, namun proses alami kematangan juga bisa terjadi dengan sendirinya jika disimpan pada suhu ruangan. Pada umumnya, nanas yang dipetik dalam kondisi belum matang akan matang setelah beberapa hari. Masalah yang sering terjadi terkait dengan kematangan buah nanas adalah kesulitan dalam menentukan waktu panen yang optimal. Klasifikasi tingkat kematangan buah nanas menjadi penting karena membantu petani atau produsen untuk mengidentifikasi kapan buah-buahan telah mencapai tingkat kematangan yang tepat untuk dipanen. Tanpa klasifikasi ini, risiko panen terlalu dini atau terlambat dapat menyebabkan penurunan kualitas dan nilai pasaran buah nanas. Oleh karena itu, dengan mengklasifikasikan tingkat kematangan buah nanas, petani dapat meningkatkan efisiensi panen, mengurangi kerugian, dan memastikan kualitas produk yang optimal. Klasifikasi objek adalah langkah mengelompokkan objek berdasarkan karakteristik yang diamati.

Dalam klasifikasi objek menggunakan algoritma untuk memperkirakan label objek baru sesuai dengan ciri-ciri yang ada. Algoritma klasifikasi dipakai untuk memahami pola dari data latih dan menerapkannya pada data baru yang

belum berlabel. Contohnya termasuk Naive Bayes, K-Nearest Neighbors, Decision Trees, Support Vector Machines, dan Neural Networks. Proses klasifikasi terdiri dari pemilihan fitur yang relevan, pembelajaran model, evaluasi performa, dan penyetalan model agar akurasinya meningkat. Sasarannya adalah menciptakan model yang mampu mengklasifikasikan objek dengan tingkat keakuratan yang tinggi. YOLO merupakan algoritma yang menerapkan konsep jaringan saraf untuk mempelajari pola sehingga dapat mendeteksi objek dalam waktu -real-time. Algoritma You Only Look Once (YOLO) ini mulai diperkenalkan pada tahun 2015 dan mengalami perkembangan yang signifikan dalam bidang deteksi objek [1]. Masalah deteksi objek sebagai deteksi regresi (menemukan nilai numerik bukan kategorikal) alih-alih tugas klasifikasi dengan memisahkan kotak pembatas secara spasial dan menghubungkan probabilitas ke masing-masing gambar yang terdeteksi menggunakan Convolutional Neural Network (CNN) tunggal, algoritma yang sering digunakan untuk kasus data citra gambar. Implementasi CNN sebagai bagian dari deep learning terus berkembang dalam mendeteksi citra digital [2][3]. Berbagai penelitian dengan tingkat akurasi cukup baik yang menerapkan algoritma CNN [4] untuk mengklasifikasikan tingkat kematangan buah jeruk menggunakan sistem komputer, dengan pengujian menggunakan 100 dataset gambar jeruk manis, akurasi mencapai 97.5184%. Pengujian pada 10 citra buah jeruk yang dibagi menjadi 5 gambar baik dan 5 gambar busuk, dan mencapai tingkat akurasi 96% untuk pelatihan dan 92% untuk pengujian. Hasilnya dinilai baik, dan sistem mampu mengklasifikasikan kelayakan buah jeruk manis dengan sangat baik.

Selanjutnya pada penelitian terkait [5] aplikasi berbasis Android yang menggunakan metode CNN dilakukan untuk mendeteksi kematangan pepaya secara otomatis. Dataset pepaya yang telah dikumpulkan digunakan untuk melatih model CNN guna mengklasifikasikan pepaya menjadi tiga kategori kematangan, yaitu belum matang, setengah matang, dan matang. Aplikasi ini juga menyediakan prediksi masa panen pepaya berdasarkan analisis kematangan. Implementasi pada platform Android memungkinkan akses yang mudah dan cepat bagi petani atau pemilik kebun pepaya untuk menghubungkan kematangan buah pepaya mereka. Hasil eksperimen menunjukkan bahwa model CNN yang diusulkan tersebut memiliki tingkat akurasi yang cukup tinggi yaitu sebesar 96.97% dalam mengklasifikasikan kematangan pepaya. Aplikasi tersebut dapat membantu petani dalam mengoptimalkan proses panen dan pengolahan pepaya secara efisien. Pada penelitian lain [6] dilakukan untuk mengklasifikasikan citra buah pir menggunakan algoritma CNN, yang didesain untuk mengolah data dua dimensi seperti citra dengan cara mengekstraksi fitur dan melakukan klasifikasi secara end-to-end. Dataset yang digunakan adalah Fruit-360 dari Kaggle dengan total 75.937 citra dari 111 kelas buah dan sayur berukuran 100x100 piksel. Model CNN yang dirancang terdiri dari 3 layer konvolusi, 3 layer pooling, layer flatten, dan 2 dense layer dengan input 100x100 piksel. Proses training menggunakan 640 citra dan validasi 160 citra dengan learning rate 0,001 serta 15 epoch menghasilkan akurasi 100%. Pengujian pada 100 citra baru mendapatkan akurasi 98% dalam mengklasifikasikan antara jenis pir Williams dan Forelle. Semakin kecil nilai learning rate maka akurasi semakin baik, sementara semakin besar jumlah epoch meningkatkan waktu proses namun tidak terlalu mempengaruhi akurasi.

Deteksi kematangan buah pepaya menggunakan algoritma YOLO berbasis Android juga dilakukan pada penelitian [7], dimana hasil pengujian menunjukkan akurasi 93%, presisi 94%, dan recall 93% dalam mendeteksi kematangan buah pepaya, meskipun terdapat beberapa kendala seperti pencahayaan, sudut kamera, pergerakan cepat, dan objek terhalang yang dapat mempengaruhi keakuratan deteksi. Penelitian tersebut juga dilakukan untuk mendeteksi tingkat kematangan buah tomat menggunakan algoritma YOLOv5 (You Only Look Once versi 5). Algoritma deep learning YOLOv5 dibimbing dengan dataset gambar tomat pada berbagai tingkat kematangan (muda, setengah matang, dan matang) yang berjumlah 981 gambar untuk data latih, 121 untuk validasi, dan 64 untuk penelitian. Hasil penelitian menunjukkan algoritma YOLOv5 dapat mendeteksi dan mengklasifikasikan tingkat kematangan pada tomat dengan akurasi maksimum 73%. Metode ini berpotensi diterapkan dalam industri pertanian untuk pengawasan kualitas, pemilihan panen, dan manajemen rantai pasokan buah tomat yang lebih efisien. Sistem klasifikasi kematangan buah menggunakan metode Convolutional Neural Network (CNN) memang sudah banyak dilakukan, seperti pada penelitian [8] dengan bahasa pemrograman Python. Sistem ini dibangun untuk memenuhi permintaan industri buah yang terus meningkat dengan menerapkan teknologi pendeteksi jenis dan tingkat kematangan buah secara otomatis. Proses pelatihan model CNN menggunakan Teachable Machine untuk mengklasifikasikan 5 jenis buah (pisang, apel, anggur, cabai, dan jeruk) ke dalam kategori matang dan tidak matang. Hasil pengujian menunjukkan sistem ini berhasil mendeteksi jenis dan kematangan buah dengan akurasi 90% pada jarak tertentu. Pencahayaan dan latar belakang saat pelatihan model mempengaruhi jarak deteksi maksimum. Penelitian ini menyimpulkan bahwa rancangan deteksi objek dan kematangan buah berbasis CNN dapat berfungsi sesuai algoritma dan berpotensi dimanfaatkan dalam industri makanan untuk penyortiran buah.

Adapun penelitian [9] membahas tentang klasifikasi tingkat kematangan tandan/tangkai buah segar (TBS) kelapa sawit menggunakan pendekatan Deep Learning dengan model ResNet50. Penelitian tersebut bertujuan untuk menganalisis kinerja model ResNet50 dalam mengklasifikasikan empat tingkat kematangan TBS (mentah, kurang matang, matang, dan terlalu matang) dengan melakukan percobaan pada berbagai parameter seperti alokasi data, Optimizer, dan Learning Rate. Hasil penelitian menunjukkan bahwa model ResNet50 dengan Optimizer Adam, alokasi data 90/10, dan learning rate 0,0001 menghasilkan kinerja terbaik dengan akurasi 97%, presisi 96%, recall 98%, dan F1 score 97%. Penelitian ini menyimpulkan bahwa model ResNet50 berhasil mencapai akurasi yang baik dalam mengklasifikasikan tingkat kematangan TBS, namun memerlukan data latih dalam jumlah besar dan memperhatikan pemilihan dataset serta metode yang digunakan. Pada Penelitian [10] mengusulkan sistem untuk mengklasifikasi tingkat kematangan buah sawit menggunakan algoritma YOLOv5 berbasis deep learning. Dataset


yang digunakan terdiri dari 1500 foto buah sawit yang dibagi menjadi tiga kelas: matang, belum matang, dan busuk. Proses meliputi akuisisi data, eksplorasi data, pemodelan dengan algoritma YOLOv5, evaluasi performa model, dan pengujian sistem secara real-time. Berdasarkan hasil estimasi model, nilai mAP mencapai 92%, akurasi 97%, presisi 97%, dan recall 96%. Penelitian ini bertujuan membantu mengklasifikasi kematangan buah sawit secara otomatis untuk mengatasi kelemahan penentuan kematangan secara tradisional yang bersifat subjektif. Hasil pengujian menunjukkan bahwa sistem dapat mendeteksi tingkat kematangan buah sawit dengan akurasi yang baik menggunakan metode YOLOv5. Implementasi algoritma deep learning YOLOv5 untuk mendeteksi buah segar dan busuk juga menggunakan dataset gambar buah apel, pisang, dan jeruk, dengan total 1200 gambar untuk data latih dan 330 gambar untuk data validasi. Metode yang digunakan adalah mengumpulkan dataset, melakukan pelabelan, membagi data menjadi data latih dan validasi, melakukan pra-pemrosesan data, lalu melatih model dengan algoritma YOLOv5. Berdasarkan pengujian, metode ini dapat mendeteksi dan mengklasifikasikan buah segar dan busuk secara konsisten dengan akurasi tinggi mencapai 90%. Penelitian menggunakan YOLOv5 karena cukup efektif untuk diimplementasikan dalam mendeteksi kesegaran buah secara real-time [11].

Jurnal penelitian terkait juga dapat digunakan untuk deteksi objek masa siap panen tanaman sayuran berbasis mobile Android dengan menggunakan deep learning [12]. Tujuannya adalah membangun model deep learning yang dapat mendeteksi secara real-time apakah tanaman sayuran seperti pakcoy, bayam, kangkung, dan kale keriting siap dipanen atau belum. Arsitektur yang digunakan adalah MobileNetV3 dengan evaluasi menggunakan skor Mean Average Precision (MAP). Setelah melakukan pelatihan model dan evaluasi, model terbaik dengan skor MAP 0,705510 diimplementasikan ke dalam aplikasi Android. Aplikasi diuji secara real-time dengan berbagai jarak, dan diperoleh hasil bahwa jarak ideal untuk deteksi adalah 5 cm dan 10 cm dengan akurasi tertinggi 0,7 atau 70%. Algoritma YOLO memang memiliki kemampuan yang cukup signifikan untuk mendeteksi kematangan buah seperti pepaya dengan akurasi tinggi dan kemampuan deteksi secara real-time. Algoritma YOLO dibandingkan dengan metode lain seperti K-Nearest Neighbor, ekstraksi fitur warna, dan Analisis Diskriminan Linear, menunjukkan hasil yang lebih baik [13]. Implementasi algoritma YOLO berpotensi untuk pengembangan teknologi pendeteksian buah yang lebih efisien dan akurat. Perkembangan YOLO memberikan dampak yang signifikan khususnya dalam identifikasi dan klasifikasi 15 jenis buah berdasarkan atribut visual menggunakan YOLOv8, model populer dalam deteksi objek dengan CNN. Hasil eksperimen dengan YOLOv8 menunjukkan akurasi deteksi rata-rata di atas 90% [14][15][16].

Klasifikasi kematangan buah merupakan tahap penting dalam bidang pertanian dan pengolahan makanan, memastikan standar kualitas produk yang optimal. Khususnya pada buah nanas, menilai tingkat kematangan secara manual membutuhkan waktu dan usaha yang besar. Sebagai respon terhadap tantangan ini, penelitian ini menerapkan Deep Learning yang memanfaatkan algoritma YOLOv8 untuk secara otonom mengkategorikan tahap kematangan nanas. Kerangka YOLOv8 dan melatih model menggunakan dataset yang terdiri dari gambar-gambar nanas yang dianotasi dan dikategorikan berdasarkan kematangannya. Evaluasi melibatkan metrik seperti akurasi klasifikasi dan kecepatan deteksi, dievaluasi melalui set tes independen. Temuan eksperimental ini dapat menunjukkan efektivitas pendekatan algoritma yang digunakan, menampilkan akurasi tinggi dalam klasifikasi bersamaan dengan deteksi yang cepat. Dalam penelitian ini dapat menghasilkan potensi besar penggunaan algoritma YOLOv8 dalam menyempurnakan proses klasifikasi buah, terutama dalam membedakan tingkat kematangan yang tepat.

## 2. METODOLOGI PENELITIAN

Penelitian ini terdiri dari beberapa tahapan yaitu tahapan pengumpulan data, pra pemrosesan data, pemodelan data, dan tahapan pengujian. Penelitian ini menerapkan algoritma YOLOv8 dengan menggunakan dataset foto buah nanas yang telah dianotasikan dengan empat label. Berikut ini gambaran tahapan penelitian secara umum yang ditunjukkan pada Gambar 1.




Gambar 1. Tahapan Penelitian

### 2.1 Pengumpulan Data

Pengumpulan data dalam penelitian ini dilakukan dengan observasi lapangan dan wawancara kepada pemilik lahan dan Industri Kecil Menengah (IKM) buah nanas yang terdapat di Desa Lobong, Bolaang Mongondow sebagai studi kasus penelitian. Pemilik lahan dan IKM yang diwawancarai juga merupakan seorang pengepul yakni berperan sebagai pengumpul buah nanas dari petani lainnya. Adapun lama waktu panen buah nanas adalah sekitar 12 bulan atau lebih. Berbeda dengan nanas rangsang yang memakai pupuk, jangka waktunya lebih singkat yaitu 4 bulan sampai bibit muncul, lalu dirangsang dan dipanen setelah 5 bulan. Kemudian untuk buahnya, nanas bisa berbuah beberapa kali. Namun, kualitas nanas setelah panen selanjutnya tidak sebaik kualitas buah yang pertama kali dipanen. Lalu jangka waktu kematangan buah nanas yang mengkal sejak dipetik dari pohon membutuhkan 3-4 hari untuk matang. Dari observasi tersebut dihasilkan empat kategori tingkat kematangan yang akan dipakai sebagai label dalam

proses anotasi dataset yaitu Mentah, Setengah Matang, Matang, dan Terlalu Matang. Selain mengumpulkan dokumentasi berupa citra atau gambar nanas dari lapangan sebagai sampel, juga diambil gambar buah nanas dari sumber lainnya yaitu internet, dengan total 153 foto sebagai dataset yang akan dilabeli lalu diuji.



**Gambar 2.** Dataset Split

Gambar 2 menunjukkan pembagian dataset, yang menggunakan 107 foto sebagai Train Set, 31 foto Valid Set, dan 15 Test Set. Pada proses ini data dilatih menggunakan Algoritma YOLOv8. Dilakukan juga pelatihan dataset yang sama lewat Pycharm menggunakan package Ultralytics dengan Epochs 75 kali.

## 2.2 Prapemrosesan Data

Dalam Data Preprocessing akan dilakukan anotasi citra buah nanas dengan 4 label yaitu Mentah, Setengah Matang, Matang, dan Terlalu Matang, yang akan digunakan sebagai dataset. Dalam proses anotasi ini digunakan Platform Cvat.AI dan Roboflow dengan 153 dataset. Anotasi dilakukan untuk memberikan kotak penanda dan label nama pada objek di suatu gambar yang biasa disebut dengan bounding box [17] dengan 4 parameter, (X center, Y center, Width, dan Height).

## 2.3 Pemodelan Data

Tahap pemodelan data merupakan proses pelatihan algoritma sebagai tahap untuk training phase yang dilakukan untuk mendapatkan pola-pola data untuk melakukan prediksi serta membuat suatu keputusan [18]. Penelitian ini menggunakan pendekatan klasifikasi Deep Learning dengan CNN yang dapat menangkap input image atau gambar. CNN juga menetapkan signifikansi bobot yang dapat dipelajari ke dalam aspek atau objek yang berbeda pada gambar, dan memisahkannya satu sama lain [19]. YOLOv8 juga memanfaatkan CNN sebagai backbone untuk mengekstrak fitur dari gambar/map input. YOLOv8 ini termasuk model deteksi objek one-stage yang dapat memproses gambar dan mendeteksi objek dalam satu tahapan sehingga menghasilkan model yang jauh lebih cepat dibanding model deteksi objek two-stage tradisional [20]. Penerapan model backbone CSPNet pada YOLOv8 juga menjadi peningkatan yang efisien dalam perkembangannya. Komponen utama dalam YOLO meliputi convolution layer, pooling layer, activation function, and fully connected layer [21]. Lapisan konvolusi dalam CNN menggunakan filter untuk menerapkan konvolusi pada input gambar, menghasilkan peta fitur yang menyoroti pola-pola spesifik. Lapisan pooling dapat mengurangi dimensi spasial peta fitur untuk membantu mengurangi overfitting. Activation function diterapkan setelah operasi konvolusi untuk mengubah nilai output dari rentang linier menjadi rentang non-linear. Fully connected layer akan menghubungkan setiap neuron dalam lapisan sebelumnya ke setiap neuron dalam lapisan berikutnya untuk mendapatkan prediksi dari ekstrasi peta fitur.

$$\emptyset(x) = \begin{cases} x, & \text{if } x > 0 \\ 0.1x, & \text{otherwise} \end{cases} \quad (1)$$

Loss Function digunakan dalam pelatihan YOLOv8 merupakan kombinasi dari beberapa komponen yaitu :

$$\begin{aligned} & \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{\text{obj}} [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2] \\ & + \lambda_{\text{coord}} \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{\text{obj}} \left[ (\sqrt{w_i} - \sqrt{\hat{w}_i})^2 + (\sqrt{h_i} - \sqrt{\hat{h}_i})^2 \right] \\ & + \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{\text{obj}} (C_i - \hat{C}_i)^2 \\ & + \lambda_{\text{noobj}} \sum_{i=0}^{S^2} \sum_{j=0}^B \mathbb{1}_{ij}^{\text{noobj}} (C_i - \hat{C}_i)^2 \\ & + \sum_{i=0}^{S^2} \mathbb{1}_i^{\text{obj}} \sum_{c \in \text{classes}} (p_i(c) - \hat{p}_i(c))^2 \end{aligned} \quad (2)$$

Di mana  $\mathbb{1}_{ij}^{\text{obj}}$  menunjukkan jika objek berada di kotak prediksi  $i$ ,  $\mathbb{1}_{ij}^{\text{noobj}}$  menunjukkan jika tidak ada objek,  $C$  adalah skor kepercayaan, dan  $p_i(c)$  adalah prediksi probabilitas kelas. YOLO adalah algoritma deteksi objek

yang menggunakan CNN untuk mendeteksi dan mengklasifikasikan objek dalam gambar. YOLOv8 adalah versi terbaru yang memiliki peningkatan dalam akurasi dan kecepatan mendeteksi objek secara Real Time.

### 2.4 Testing dan Evaluasi

Setelah dataset selesai dilatih, dilakukan pengujian untuk mengetahui bila deteksi kematangan pada buah berhasil mengidentifikasi tingkat kematangannya. Dalam YOLOv8 metrik yang digunakan meliputi Mean Average Precision (mAP) untuk mengukur akurasi deteksi dan klasifikasi objek, Precision untuk mengukur akurasi dari deteksi yang benar, Recall untuk mengukur sensitivitas model dalam mendeteksi semua objek yang relevan, dan F1-Score yang merupakan harmonisasi antara Precision dan Recall.

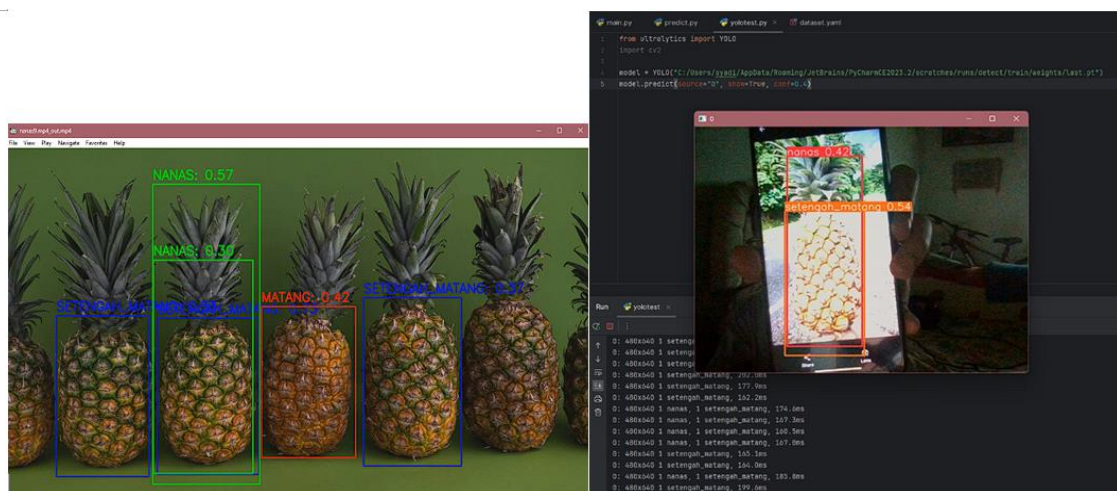
## 3. HASIL DAN PEMBAHASAN

Dalam penelitian ini, berhasil mengimplementasikan algoritma YOLOv8 untuk mendeteksi dan mengklasifikasikan tingkat kematangan buah nanas secara otomatis. Hal ini dilakukan dengan melatih model menggunakan dataset gambar nanas yang telah dianotasi berdasarkan 4 tingkatan kematangan yaitu Mentah, Setengah Matang, Matang, Terlalu Matang. Ada beberapa pengujian yang telah dilakukan. Pada dataset yang dilatih Pycharm, dilakukan pengujian pada foto, video, dan kamera langsung (Webcam). Dan untuk Roboflow diuji menggunakan data berupa foto dan video.



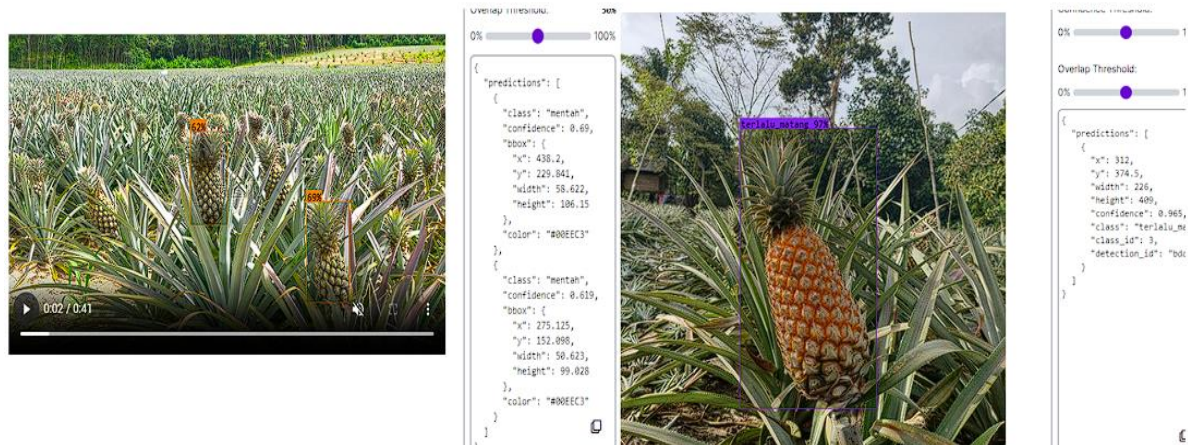
Gambar 3. Hasil deteksi tingkat kematangan buah nanas

Pada Gambar 3, hasil tes menggunakan Pycharm memiliki nilai confidence 0,64 dengan kategori mentah, dan hasil tes menggunakan Roboflow dengan nilai confidence 0,95 menghasilkan kategori mentah juga.



Gambar 4. Hasil klasifikasi buah nanas dengan Pycharm

Pada Gambar 4 merupakan perbandingan hasil identifikasi untuk klasifikasi tingkat kematangan buah nanas berdasarkan citra digital. Hasil tes Pycharm menggunakan video dengan beragam nilai confidence dan diperoleh dua label tingkat kematangan yaitu matang dan setengah matang. Selanjutnya hasil klasifikasi Pycharm juga dapat menggunakan Webcam (Real-Time) dengan nilai confidence 0,54 dan label yang dihasilkan yaitu setengah matang.



**Gambar 5.** Hasil klasifikasi buah nenas dengan Roboflow

Pada Gambar 5 terdiri dari dua gambar yaitu data dengan video dan juga gambar. Hasil identifikasi citra digital untuk mengklasifikasikan tingkat kematangan buah nenas dilakukan menggunakan aplikasi Roboflow. Dari klasifikasi tersebut dengan beragam nilai confidence dan diperoleh satu label tingkat kematangan yaitu mentah. Selanjutnya menggunakan foto atau citra buah nenas dengan nilai confidence 0,97 menunjukkan kategori nenas yang terlalu matang. Diambil juga 10 data sampel dari data latih yang diuji dengan 75 Epochs seperti pada Tabel 1 dan 2.

**Tabel 1.** Data sampel yang dilatih

Epoch	Train/Box _Loss	Train/Cls _Loss	Train/Dfl _Loss	Metrics/ Precision(B)	Metrics/ Recall(B)	Metrics/ mAP50(B)	Metrics/ mAP50-95(B)
1	3,232	4,52	4,351	0,001	0,085	0,0006	0,0002
2	3,215	4,394	4,221	0,0009	0,076	0,0009	0,0002
3	3,181	4,333	4,164	0,0008	0,070	0,002	0,0004
10	2,872	3,428	3,530	0,853	0,047	0,064	0,024
11	2,776	3,319	3,442	0,402	0,128	0,048	0,048
12	2,699	3,299	3,365	0,427	0,171	0,071	0,071
20	2,367	2,866	2,958	0,441	0,361	0,113	0,113
21	2,424	2,942	3,035	0,309	0,202	0,081	0,081
22	2,226	2,836	2,910	0,434	0,528	0,194	0,194
30	2,117	2,681	2,752	0,469	0,512	0,219	0,219

**Tabel 2.** Data sampel yang dilatih

Epoch	Val/Box_Loss	Val/Cls_Loss	Val/Dfl_Loss	Lr/pg 0	Lr/pg 1	Lr/pg 2
1	3,096	4,435	4,158	9,999e	9,999e	9,999e
2	3,092	4,435	4,156	0,00020	0,00020	0,00020
3	3,083	4,431	4,150	0,00031	0,00031	0,00031
10	2,465	4,026	3,461	0,000969	0,00096	0,00056
11	2,475	4,020	3,528	0,000964	0,00056	0,00096
12	2,486	4,016	3,44	0,000949	0,00094	0,00054
20	2,060	3,484	2,798	0,000832	0,00083	0,00083
21	2,054	3,127	2,776	0,000817	0,00081	0,00081
22	2,008	2,859	2,750	0,000803	0,00080	0,00080
30	1,783	3,195	2,466	0,000685	0,00068	0,00068


Train/Box\_Loss, Train/Cls\_Loss, dan Train/Dfl\_Loss adalah kerugian yang diukur selama pelatihan model YOLOv8 untuk memprediksi posisi bounding box, klasifikasi objek dalam bounding box, dan representasi jarak antar piksel dalam objek yang terdeteksi. Metrik precision menunjukkan proporsi prediksi objek yang benar dibandingkan dengan semua prediksi positif. Metrik recall mengukur sensitivitas model deteksi objek yang menjelaskan tentang proporsi objek yang benar-benar terdeteksi dibandingkan dengan semua objek yang ada. Metrik mAP atau Mean Average Precision at IoU threshold 0,5 menunjukkan hasil pengukuran akurasi keseluruhan model dalam deteksi objek. Val/Box\_Loss, Val/Cls\_Loss, dan Val/Dfl\_Loss adalah kerugian yang diukur selama validasi model YOLOv8 untuk prediksi posisi, kelas objek dalam bounding box, dan representasi jarak antar piksel dalam objek yang terdeteksi. Lr/pg 0, Lr/pg 1, dan Lr/pg 2 adalah learning rate dan parameter group dalam optimisasi model selama pelatihan. Learning rate mengontrol seberapa besar model berubah berdasarkan perubahan dalam fungsi kerugian, sedangkan parameter group mengatur kelompok parameter dengan learning rate yang berbeda, tergantung pada jenis optimizernya.

Hasil visualisasi pada Gambar 4 dan 5 dapat diberikan penjelasan lebih lanjut tentang kinerja dari sistem. Selain itu, selama proses pelatihan dan pengujian dalam tiap epoch-nya, sistem mengalami perkembangan dan peningkatan kinerja, yang juga dapat dilihat pada Gambar 6 dan 7.




Gambar 6. Hasil confusion matrix


Sebagai alat evaluasi untuk mengukur kinerja algoritma klasifikasi, confusion matrix pada Gambar 6 menunjukkan perbandingan antara hasil klasifikasi yang sebenarnya dengan hasil yang diprediksi oleh model menggunakan model YOLOv8 untuk mendeteksi tingkat kematangan buah nanas.



Gambar 7. Diagram mAP (Result)

Diagram mAP pada Gambar 7 menunjukkan kurva yang menggambarkan hubungan antara recall dan precision saat nilai IoU (Intersection over Union) yang berbeda digunakan sebagai threshold. IoU mengukur seberapa besar tumpang tindih antara prediksi bounding box dan ground truth. Dengan mengubah IoU threshold dari 0 hingga 1 (biasanya dengan increment 0.05) dapat dilihat bagaimana precision dan recall berubah sepanjang kurva.





**Gambar 8.** Kurva hubungan parameter pengujian

Pada Gambar 8 menunjukkan kurva hubungan tiap parameter pengujian yang menjelaskan tentang hubungan precision dan nilai confidence, hubungan precision dan recall, hubungan recall dan confidence, dan hubungan F1 dengan confidence. Kurva hubungan parameter-parameter pengujian dalam deteksi objek memberikan pandangan penting tentang kinerja model. Precision meningkat seiring dengan nilai confidence, menunjukkan ketepatan model dalam mengklasifikasikan hasil positif. Namun, recall cenderung menurun dengan peningkatan confidence karena model lebih memilih prediksi yang pasti dengan confidence tinggi. Terdapat trade-off antara precision dan recall, di mana peningkatan salah satu bisa menurunkan nilai yang lain. F1 score, yang menggabungkan precision dan recall, juga dipengaruhi oleh nilai confidence.

Berdasarkan implementasi algoritma YOLOv8 dalam mendeteksi dan mengklasifikasikan tingkat kematangan buah nanas menunjukkan hasil yang baik dengan nilai mAP 81%, Precision 70,5%, Recall 75,9%, yang menghasilkan tingkat akurasi cukup memuaskan dengan beragam tingkat. Setelah dilakukan pengujian dan evaluasi secara berulang, penelitian menemukan bahwa pada beberapa kasus, keakuratan hasil deteksi kematangan buah nanas menghasilkan nilai yang tidak memuaskan, yang mana hal itu dipengaruhi oleh kekurangan variasi dalam dataset yang digunakan. Selain itu, kualitas data dalam artian kualitas foto harus jernih dan jelas, objek yang akan dideteksi tidak tertutupi objek lain, dan kualitas penangkap gambar (Camera/Webcam) harus bagus bila ingin digunakan secara Real Time.

## 4. KESIMPULAN

Penelitian ini mengimplementasikan algoritma YOLOv8 untuk tujuan deteksi dan klasifikasi tingkat kematangan buah nanas dengan hasil yang cukup baik. Algoritma berhasil mencapai nilai mAP sebesar 81%, Precision sebesar 70,5%, dan Recall sebesar 75,9%, menunjukkan kemampuan yang memuaskan dalam mengenali dan membedakan antara berbagai tingkat kematangan buah nanas. Meskipun demikian, penelitian menghadapi beberapa tantangan yang memengaruhi akurasi deteksi. Salah satu tantangan utama adalah kekurangan variasi dalam dataset yang digunakan, yang dapat mengurangi kemampuan model dalam mengenali kondisi buah nanas yang berbeda-beda. Kualitas data juga menjadi kunci penting; gambar yang digunakan harus jelas, tidak terlalu buram, dan objek yang akan dideteksi tidak boleh tertutupi oleh objek lain. Selain itu, kualitas perangkat penangkap gambar, baik kamera maupun webcam, berpengaruh signifikan terutama dalam aplikasi real-time. Untuk mengatasi tantangan tersebut, rekomendasi pengembangan termasuk perluasan variasi dataset dengan mencakup lebih banyak kondisi buah nanas yang berbeda, termasuk variasi tingkat kematangan dan pose. Selain itu, penting untuk meningkatkan kualitas pengambilan gambar agar lebih jernih dan memastikan kejernihan objek yang ingin dideteksi. Peningkatan perangkat keras juga dapat membantu dalam meningkatkan akurasi deteksi, terutama ketika aplikasi diimplementasikan secara real-time. Penelitian ini membuktikan bahwa algoritma YOLOv8 dapat digunakan secara Real-Time untuk mendeteksi tingkat kematangan buah, yang sangat bermanfaat bagi petani dalam memastikan kualitas buah nanas.

## REFERENCES

- [1] Y. Zhang, S. Wang, X. Zhang, and X. Li, "A Comprehensive Survey on YOLO: A Versatile Object Detection Framework," *arXiv Prepr. arXiv2304.01028*, 2023.
- [2] M. F. Tomatala and Mihuandayani, "Prototyping of Machine Learning at Traditional Market as Option for Sales and Purchasing Transaction," in *Proc. 2020 2nd Int. Conf. Cybernetics and Intelligent System (ICORIS)*, Manado, Indonesia, 2020, pp. 1–6. doi: 10.1109/ICORIS50180.2020.9320844.
- [3] A. Mohite, R. Joshi, S. Kunjir, and M. Kodmelwar, "Deep Learning-Based Fruit Recognition and Quality Assessment: A Convolutional Neural Network Approach," in *Proc. 2024 ASU Int. Conf. Emerging Technologies for Sustainability and Intelligent Systems (ICETISIS)*, Manama, Bahrain, 2024, pp. 589–593. doi: 10.1109/ICETISIS61505.2024.10459453.
- [4] B. Yanto, L. Fimawahib, A. Supriyanto, B. H. Hayadi, and R. R. Pratama, "Klasifikasi Tekstur Kematangan Buah Jeruk Manis Berdasarkan Tingkat Kecerahan Warna dengan Metode Deep Learning Convolutional Neural Network," *J. Inovtek Polbeng - Seri Inform.*, vol. 6, no. 2, 2021, doi: 10.35314/isi.v6i2.2104.
- [5] M. S. Hawibowo and I. Muhimmah, "Aplikasi Pendeteksi Tingkat Kematangan Pepaya menggunakan Metode Convolutional Neural Network (CNN) Berbasis Android," *J. Edukasi dan Penelit. Inform.*, vol. 10, no. 1, Apr. 2024, doi:



- 10.26418/jp.v10i1.77819.
- [6] S. Juliansyah and A. D. Laksito, "Klasifikasi Citra Buah Pir Menggunakan Convolutional Neural Networks," *InComTech J. Telekomun. dan Komput.*, vol. 11, no. 1, pp. 65–72, Apr. 2021, doi: 10.22441/incomtech.v11i1.10185.
  - [7] F. Agustina and M. Sukron, "Deteksi Kematangan Buah Pepaya Menggunakan Algoritma YOLO Berbasis Android," *J. Infokam*, vol. XVIII, no. 2, Sep. 2022, doi: 10.53845/infokam.v18i2.320.
  - [8] S. Aras, P. Tanra, and M. Bazhar, "Deteksi Tingkat Kematangan Buah Tomat Menggunakan YOLOv5," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 2, Apr. 2024, doi: 10.57152/malcom.v4i2.1270.
  - [9] F. B. Setiawan, C. B. Adipradana, and L. H. Pratomo, "Fruit Ripeness Classification System Using Convolutional Neural Network (CNN) Method," *PROtek J. Ilm. Tek. Elektro*, vol. 10, no. 1, Jan. 2023, doi: 10.33387/protk.v10i1.5549.
  - [10] J. Zulkarnain, Kusri, and T. Hidayat, "Klasifikasi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit Menggunakan Pendekatan Deep Learning," *J. Sains dan Teknol.*, vol. 12, no. 3, 2023, doi: 10.23887/jstundiksha.v12i3.59140.
  - [11] R. Kurniawan, A. T. Martadinata, and S. D. Cahyo, "Klasifikasi Tingkat Kematangan Buah Sawit Berbasis Deep Learning dengan Menggunakan Arsitektur YOLOv5," *J. Inf. Syst. Res.*, vol. 5, no. 1, Oct. 2023, doi: 10.47065/josh.v5i1.4408.
  - [12] L. Lusiana, A. Wibowo, and T. K. Dewi, "Implementasi Algoritma Deep Learning You Only Look Once (YOLOv5) Untuk Deteksi Buah Segar Dan Busuk," *Paspalum J. Ilm. Pertan.*, vol. 11, no. 1, Mar. 2023, doi: 10.35138/paspalum.v11i1.489.
  - [13] A. Kusuma, A. R. S. Nurrohman, K. T. Anggoro, and R. S. Pakpahan, "Implementasi Algoritma Yolo Dalam Pendeteksian Tingkat Kematangan Pada Buah Pepaya," *J. AI dan SPK J. Artif. Intel. dan Sist.*, vol. 1, no. 1, Jun. 2023, [Online]. Available: <http://jurnalmahasiswa.com/index.php/aidanspk/article/view/177>
  - [14] C. Dewi, O. M. Kamlasi, G. Chhabra, G. Dai, K. Kaushik, and I. U. Khan, "Automated Fruit Classification Based on Deep Learning Utilizing YOLOv8," in *Proc. 2023 10th IEEE Uttar Pradesh Section Int. Conf. Electrical, Electronics and Computer Engineering (UPCON)*, Gautam Buddha Nagar, India, 2023, pp. 801–807. doi: 10.1109/UPCON59197.2023.10434542.
  - [15] Y. Su, B. Cheng, and Y. Cai, "Detection and Recognition of Traditional Chinese Medicine Slice Based on YOLOv8," in *Proc. 2023 IEEE 6th Int. Conf. Electronic Information and Communication Technology (ICEICT)*, Qingdao, China, 2023, pp. 214–217. doi: 10.1109/ICEICT57916.2023.10245026.
  - [16] A. Ardiansyah, J. Triloka, and Indera, "Evaluasi Akurasi dan Presisi Model YOLOv8 dalam Deteksi Kesegaran Buah," *JUPITER J. Penelit. Ilmu Dan Teknol. Komput.*, vol. 16, no. 2, pp. 357–368, 2024, doi: 10.5281/zenodo.11296226.
  - [17] M. Ibrahim and U. Latifa, "Penerapan Algoritma YOLOv8 Dalam Deteksi Waktu Panen Tanaman Pakcoy Berbasis Website," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 4, Aug. 2023, doi: 10.36040/jati.v7i4.7154.
  - [18] N. J. Hayati, D. Singasatia, and M. R. Muttaqin, "Object Tracking Menggunakan Algoritma You Only Look Once (YOLO)v8 Untuk Menghitung Kendaraan," *KOMPUTA J. Ilm. Komput. dan Inform.*, vol. 12, no. 2, Oct. 2023, doi: 10.34010/komputa.v12i2.10654.
  - [19] S. Shubathra, P. C. D. Kalaivaani, and S. Santhoshkumar, "Clothing Image Recognition Based on Multiple Features Using Deep Neural Networks," in *Proc. 2020*, 2020, p. 7. doi: 10.1109/9155959.
  - [20] A. Ng and S. Spielberg, *Deep Learning for Computer Vision: Applications and Trends*. Manning Publications, 2022.
  - [21] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.