

# Detection of Ripeness in Oil Palm Fresh Fruit Bunches Using the YOLO12S Algorithm on Digital Images

Linnda Prawidya Nur'aini <sup>1\*</sup>, Majid Rahardi <sup>2\*</sup>

<sup>\*</sup> Informatika, Universitas AMIKOM Yogyakarta  
[linnda.p.n@students.amikom.ac.id](mailto:linnda.p.n@students.amikom.ac.id) <sup>1</sup>, [majid@amikom.ac.id](mailto:majid@amikom.ac.id) <sup>2</sup>

## Article Info

### Article history:

Received 2025-07-15

Revised 2025-07-26

Accepted 2025-07-30

### Keyword:

*Deep Learning,  
FFB Ripeness,  
Object Detection,  
Oil Palm,  
YOLO12s.*

## ABSTRACT

Indonesia is the world's largest producer of palm oil, with a production volume reaching 46.82 million tons in 2022. This industry heavily relies on the quality of Fresh Fruit Bunches (FFB) harvests, which is determined by the accuracy of ripeness at the time of harvest. Unfortunately, ripeness assessment of FFB is still conducted manually and subjectively by field workers, posing risks to both efficiency and production accuracy. Although various studies have employed YOLOv5 and YOLOv8 for fruit ripeness detection, few have explored the potential of YOLO12s in classifying FFB ripeness in a comprehensive and efficient manner. In this study, we present the application of the YOLO12s algorithm to automatically classify the ripeness levels of oil palm FFB using digital images. The YOLO12s model was trained on 14,620 FFB images categorized into four ripeness levels: unripe, under-ripe, ripe, and overripe. Evaluation results showed a precision of 93.1%, recall of 95.9%, mAP@0.50 of 97.8%, and mAP@0.50–0.95 of 78.8%. The model was able to perform inference in approximately 4.7 milliseconds per image and demonstrated good generalization despite challenges related to varying lighting conditions. These results indicate that YOLO12s holds great potential to replace subjective manual methods with a more accurate, consistent, and efficient classification solution to support the harvesting process in the palm oil industry.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

## I. PENDAHULUAN

Negara Indonesia memegang posisi sebagai produsen kelapa sawit terbesar di dunia. Data dari Kementerian Pertanian Direktorat Jenderal Perkebunan menunjukkan bahwa pada tahun 2022, luas areal perkebunan kelapa sawit di Indonesia mencapai 16,83 juta hektar dengan total produksi sebesar 46,82 juta ton. Wilayah yang menjadi pusat utama kegiatan produksi di Indonesia, di antaranya adalah Riau, Kalimantan Tengah, Kalimantan Barat, Sumatera Utara, Kalimantan Timur, Sumatera Selatan, dan Jambi [1][2]. Peran kelapa sawit sangat krusial bagi perekonomian nasional, terutama melalui ekspor minyak sawit mentah [3].

Dalam industri kelapa sawit, panen Tandan Buah Segar (TBS) pada waktu dan tingkat kematangan yang tepat merupakan kunci utama yang memengaruhi kualitas dan kuantitas produk akhir. Jika panen dilakukan terlalu awal atau terlalu lambat, hal ini dapat mengakibatkan penurunan

rendemen minyak serta mutu produk akhir [4][5]. Sayangnya, proses panen TBS saat ini masih banyak mengandalkan penilaian visual secara manual oleh pekerja lapangan. Metode ini, meskipun umum, rentan terhadap kesalahan subjektif [6], yang berpotensi mengurangi efisiensi dan kualitas produksi secara keseluruhan.

Ketergantungan pada penilaian manual dalam menentukan tingkat kematangan tandan buah segar (TBS) kelapa sawit membutuhkan keahlian khusus dan rentan menimbulkan perbedaan subjektif antar pekerja. Akibatnya, proses pemilihan buah sering kali tidak konsisten. Hal ini berdampak pada efisiensi operasional dan profitabilitas industri. Untuk mengatasi hal tersebut, diperlukan solusi berbasis teknologi yang lebih objektif dan konsisten. Salah satu pendekatan yang potensial adalah pemanfaatan pengolahan citra digital dan metode pembelajaran mesin seperti Multi-Layer Perceptron (MLP), yang terbukti mampu mengklasifikasikan tingkat kematangan TBS dengan akurasi

hingga 85,71% berdasarkan parameter warna RGB dan HIS. Selain itu, pendekatan deep learning dengan metode YOLOv5 juga telah berhasil diterapkan untuk mendeteksi objek kelapa sawit secara otomatis menggunakan citra multispektral, dengan F1-score hingga 81,0% pada kombinasi pita RBN (Red, Blue, dan Near-Infrared) [7]. Oleh karena itu, diperlukan solusi yang lebih objektif dan konsisten untuk mengidentifikasi tingkat kematangan TBS.

Kemajuan teknologi digital, khususnya dalam pengolahan citra dan kecerdasan buatan, menawarkan pendekatan inovatif untuk mengatasi permasalahan ini. Algoritma You Only Look Once (YOLO), yang sering dikenal kemampuannya dalam mendeteksi dan mengklasifikasikan objek secara real-time dengan akurasi yang tinggi, sangat relevan untuk kasus ini [8]. Teknologi ini memungkinkan komputer untuk secara langsung mengenali bentuk dan warna TBS melalui citra visual, mengurangi ketergantungan pada penilaian manusia yang rentan kesalahan [9].

Penelitian ini bertujuan untuk mengukur kinerja model object detection berbasis deep learning dengan algoritma YOLO12s dalam mengklasifikasikan tingkat kematangan TBS kelapa sawit secara utuh. Signifikansi penelitian ini terletak pada potensi untuk mengatasi keterbatasan metode manual yang tidak akurat dan tidak efisien dalam penilaian kematangan TBS. Dengan menerapkan YOLO12s untuk klasifikasi TBS kelapa sawit secara utuh, diharapkan dapat tercipta solusi yang lebih objektif, konsisten, dan efisien, berkontribusi pada peningkatan kualitas dan produktivitas dalam industri kelapa sawit.

Penggunaan teknologi computer vision dan deep learning telah merevolusi berbagai sektor, termasuk pertanian, dalam upaya meningkatkan efisiensi dan akurasi proses deteksi serta klasifikasi. Berbagai penelitian telah mengonfirmasi efektivitas YOLO dalam mengidentifikasi tingkat kematangan buah, membedakan kualitas buah, hingga mendeteksi objek lain di lingkungan pertanian seperti pohon sawit.

Studi-studi terbaru menunjukkan keberagaman aplikasi YOLO dalam menentukan kematangan buah. Ferdi Gusnanto et al. (2025) berhasil mencapai akurasi, presisi, recall, dan F1-score di atas 97% dalam klasifikasi tingkat kematangan buah mangga menggunakan YOLO11, membuktikan potensi superioritas versi YOLO terbaru dalam tugas klasifikasi yang kompleks [10]. Meski demikian, Suhardi Aras et al. (2024) dengan YOLOv5 untuk deteksi tingkat kematangan tomat hanya mencapai akurasi 73%, mengindikasikan bahwa performa model dapat bervariasi tergantung pada karakteristik spesifik dataset dan kerumitan tugas [11]. Dalam ranah kualitas buah secara umum, Lusiana Lusiana et al. (2023) berhasil mengimplementasikan YOLOv5 untuk mendeteksi buah segar dan busuk pada apel, pisang, dan jeruk dengan rata-rata presisi 0,990 dan akurasi 84%, menunjukkan kapabilitas model dalam aspek sortasi kualitas [12].


Fokus penelitian terhadap komoditas sawit juga telah banyak dilakukan dengan memanfaatkan algoritma YOLO. Rudi Kurniawan et al. (2023) menunjukkan bahwa YOLOv5s

efektif untuk klasifikasi tingkat kematangan brondolan buah sawit, dengan mAP mencapai 92%, presisi 97%, dan recall 96% [6]. Lebih lanjut, Zahwa Genoveva dan Rama Dian Syah (2024) menggunakan YOLOv8s untuk deteksi tingkat kematangan Tandan Buah Segar (TBS) kelapa sawit, menghasilkan nilai presisi 0,945, recall 0,947, dan mAP 0,98 [13]. Penelitian-penelitian ini menggarisbawahi bahwa YOLO versi 5 dan 8 telah berhasil diterapkan untuk penilaian kematangan pada buah sawit, baik dalam bentuk brondolan maupun TBS, yang krusial untuk efisiensi dan kualitas produksi di industri perkebunan.

Fleksibilitas YOLO juga terbukti dalam deteksi objek pertanian yang lebih luas. Desta Sandya Prasvita et al. (2024) mengeksplorasi deteksi pohon kelapa sawit menggunakan berbagai varian YOLOv5 pada citra multispektral, menemukan bahwa konfigurasi RBN-YOLOv5m memberikan hasil terbaik dengan mAP@50 sebesar 78,3% dan F1-score 81,0%. Ini menegaskan adaptabilitas YOLO untuk tugas pemantauan area Perkebunan [14]. Meski demikian, literatur yang ada menunjukkan bahwa aplikasi YOLO untuk deteksi tingkat kematangan TBS kelapa sawit masih dominan menggunakan versi YOLOv5 dan YOLOv8. Padahal, kemunculan versi YOLO11 telah menunjukkan performa yang signifikan lebih tinggi pada deteksi buah mangga. Dengan mempertimbangkan bahwa tingkat kematangan TBS sangat mempengaruhi rendemen dan kualitas minyak kelapa sawit, eksplorasi terhadap arsitektur YOLO yang lebih mutakhir menjadi sangat relevan. Maka dari itu, penelitian ini akan berfokus pada optimalisasi deteksi tingkat kematangan Tandan Buah Segar (TBS) kelapa sawit dengan menggunakan algoritma YOLO12, dan diharapkan dapat meningkatkan akurasi dan efisiensi identifikasi kematangan secara lebih presisi dibandingkan penelitian sebelumnya.

## II. METODE

Rancangan kegiatan penelitian ini mengikuti alur sistematis seperti yang digambarkan pada alur penelitian, yang dapat dilihat pada gambar 1.



Gambar 1. Alur Penelitian.

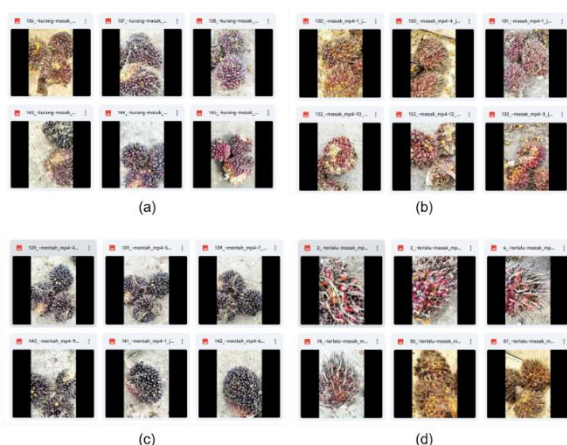
### A. Tahap Awal

Tahap awal meliputi business understanding, literature review dan data collection. Tahap ini penting untuk mendefinisikan secara spesifik masalah yang akan dipecahkan. Dalam penelitian ini, masalah utamanya adalah penilaian tingkat kematangan Tandan Buah Segar (TBS) kelapa sawit yang masih bergantung pada penilaian visual manual. Maka dari itu, masalah ini akan menjadi dasar bagi perumusan

tujuan penelitian dan pengembangan solusi, yaitu sistem deteksi tingkat kematangan TBS kelapa sawit berbasis deep learning yang memanfaatkan jaringan saraf tiruan (artificial neural networks) dengan lapisan-lapisan yang tersembunyi [15].

### B. Data Preparation

Tahap ini berpusat pada pengadaan dan persiapan dataset yang akan digunakan untuk melatih dan menguji model. Data yang digunakan dalam penelitian ini adalah dataset public berupa citra Tandan Buah Segar (TBS) kelapa sawit yang diunduh melalui website Roboflow. Dataset ini telah melalui proses augmentasi dan anotasi, serta dikategorikan berdasarkan empat tingkat kematangan, yaitu: Kurang Masak, Masak, Mentah, dan Terlalu Masak. Jumlah total citra dalam dataset adalah 14.620. Proses preprocessing yang dilakukan meliputi auto-orient, resize menggunakan mode fit kedalam ukuran 540x540 piksel dengan menambahkan batas hitam, serta auto-adjust contrast dengan metode contrast stretching untuk meningkatkan kontras gambar. Sedangkan proses augmentasi mencakup jumlah output per training example: 3, zoom minimum 0% hingga maksimum 30%, serta rotasi antara -15% hingga +15%. Contoh sample citra dapat dilihat pada gambar 2.



Gambar 2. (a)Kurang Masak, (b)Masak, (c)Mentah, dan (d)Terlalu Masak

### C. Pre-processing Data

Tahap ini sangat krusial untuk mempersiapkan data agar sesuai dengan format input yang dibutuhkan oleh model YOLO12s dan memastikan kualitas data yang optimal untuk pelatihan. Proses ini meliputi:

- 1) *Ekstraksi Dataset*: Setelah dataset diunduh, file dataset yang sebelumnya dalam format .zip akan diekstrak ke dalam direktori kerja. Proses ekstraksi ini akan menghasilkan folder berisi citra (.jpg) dan file anotasi (.csv).
- 2) *Pemetaan Label*: Proses ini akan memastikan bahwa setiap file anotasi memiliki mapping kelas yang benar sesuai dengan matangan TBS. Dalam penelitian ini mapping kelas

dimetakan 0 untuk Kurang Masak, 1 untuk Masak, 2 untuk Mentah, dan 3 untuk Terlalu Masak.

3) *Konversi ke Format YOLO*: File anotasi pada dataset awalnya dalam format .csv dan akan dikonversi ulang ke format YOLO. Dalam format YOLO, setiap objek dalam gambar dipresentasikan oleh satu baris dalam file .txt yang berisi [class\_id], [x\_center], [y\_center], [width], dan [height]. Koordinat bounding box dinormalisaikan antara 0 dan 1 relatif terhadap dimensi gambar.

4) *Penyusunan Struktur Folder Gambar/Label Sesuai Format YOLO*: Dataset kemudian akan diorganisir ke dalam struktur direktori standar yang diharapkan oleh framework YOLO (ultralytics). Direktori ini mencakup folder train, val, dan test. Masing-masing subfolder berisi data gambar dan label.

5) *Pembuatan File YML (data.yaml)*: File data.yaml adalah konfigurasi penting yang memberitahu model di mana menemukan data latih, validasi dan uji, serta mendefinisikan nama-nama kelas yang akan dideteksi. File ini akan berisi path ke folder train, val, test dan daftar names yang berisi nama-nama kategori kematangan TBS.

6) *Persiapan Direktori Output*: Proses membuat folder kosong yang akan digunakan oleh framework YOLO untuk menyimpan log pelatihan, checkpoint model, metrik, dan hasil prediksi. Biasanya akan tersimpan di runs/detect/train.

### D. Splitting Data

Tahap ini merupakan pembagian dataset yang telah di preprocessing ke dalam tiga bagian untuk tujuan pelatihan, validasi, dan pengujian. Jumlah total citra dalam dataset adalah 14.620. Dataset ini kemudian dibagi menjadi tiga set data, yaitu set train sebanyak 87%, set valid sebanyak 9%, dan set test sebanyak 4%. Pembagian sudah dilakukan sebelumnya pada dataset dari Roboflow, detail pembagian dataset dapat dilihat di tabel 1.

TABEL I  
DETAIL KELAS DATASET

Kelas	Train Set	Valid Set	Test Set
Kurang Masak	3.202	305	152
Masak	3.402	380	185
Mentah	3.130	299	150
Terlalu Masak	2.986	285	144
Total	12.720	1.269	631

### E. Pelatihan Model (YOLO12s)

Proses ini adalah tahapan inti dalam pengembangan model. Model YOLO12s (small) akan dilatih menggunakan dataset yang telah dipre-processing. Pemilihan arsitektur menggunakan pretrained model YOLO12s dengan menentukan hyperparameter seperti epoch, batch size, dan image size, dapat dilihat di tabel 2.

TABEL 2  
TABEL PARAMETER

Parameter	Nilai
Model	YOLO12s
Epoch	50
Batch Size	16
Image Size	544
Learning Rate	0.01
Optimazer	auto

Proses training model dilakukan menggunakan Google Colaboratory dengan menggunakan GPU nvidia Tesla T4. Selama Pelatihan model, kinerja model pada data validasi akan dipantau secara berkala untuk mendeteksi overfitting dan mengoptimalkan hyperparameter, dan model checkpoint akan disimpan secara berkala. Hasil proses training model terbaik akan disimpan dalam file model .pt untuk mendeteksi Tingkat kematangan TBS Kelapa sawit.

#### F. Evaluasi Model

Setelah pelatihan selesai, model yang telah dilatih selanjutnya dievaluasi secara menyeluruh menggunakan data uji (test set) yang belum pernah dilihat oleh model. Evaluasi ini bertujuan untuk mengukur kemampuan generalisasi model. Hasil evaluasi akan disajikan dalam bentuk tabel dan grafik. Metrik yang akan dihitung dan dianalisis adalah:

1) *Precision*: Mengukur ketepatan deteksi model, yaitu proporsi dari semua deteksi positif yang benar-benar merupakan objek yang dicari. Rumusnya:

$$Precision = \frac{TP}{(TP+FP)} \quad (1)$$

Dimana:

(TP) True Positive = Objek yang ada dan terdeteksi dengan benar

(FP) False Positive = Objek yang ada dan terdeteksi namun salah

2) *Recall*: Mengukur kemampuan model untuk menemukan semua objek yang relevan dalam gambar, yaitu proporsi dari semua objek yang sebenarnya ada dan berhasil dideteksi oleh model. Rumusnya:

$$Recall = \frac{TP}{(TP+FN)} \quad (2)$$

Dimana:

(TP) True Positive = Objek yang ada dan terdeteksi dengan benar


(FP) False Negative = Objek yang ada namun tidak terdeteksi

3) *mAP@0.50* (mean Average Precision at IoU=0.50): Ini adalah metrik standar dalam deteksi objek. ini dihitung dengan mengambil rata-rata nilai Average Precision (AP) untuk setiap kelas, dimana AP dihitung berdasarkan kurva Precision-Recall pada ambang Intersection over Union (IoU) 0,050. IoU mengukur tumpang tindih antara bounding box prediksi dan ground truth.

4) *mAP@0.50-0.95* (mean Average Precision at IoU=0.50 to 0.95): Metrik ini memberikan evaluasi yang lebih ketat dan komprehensif. Metrik ini adalah rata-rata mAP pada berbagai ambang IoU, mulai dari 0,50 hingga 0,95, dengan step 0,05. Metrik ini lebih sensitif terhadap akurasi lokasi bounding box dan memberikan gambaran performa model dalam kondisi yang lebih ekstrim.

### III. HASIL DAN PEMBAHASAN

Hasil penelitian ini adalah hasil dari proses pelatihan model YOLO12s (small) yang akan menghasilkan metrics evaluasi seperti precision, recall, dan mAP (Mean Average Precision). Proses pelatihan dipantau melalui kurva pelatihan yang di plot sepanjang 50 epoch.




Gambar 3. Visualisasi Grafik Hasil Pelatihan

Grafik hasil pelatihan pada gambar 3 menunjukkan bahwa semua loss plot mengalami tren penurunan yang stabil dan konvergen ke nilai rendah. Grafik train loss (train/box\_loss, train/cls\_loss, dan train/dfl\_loss) memperlihatkan penurunan tajam di awal epoch dan stabil di akhir. Hal ini menandakan bahwa model berhasil belajar secara efektif dalam melokalisasi dan mengklasifikasikan objek pada data latih. Tren serupa juga terlihat pada grafik validasi loss (val/box\_loss, val/cls\_loss, dan val/dfl\_loss), yang menunjukkan konsistensi model dalam memprediksi objek pada data validasi tanpa tanda overfitting signifikan. Nilai loss yang rendah dan stabil di kedua set data mengindikasikan kemampuan generalisasi model yang baik dan akurasi prediksi yang tinggi.

Metrik performa model menunjukkan hasil yang sangat baik dalam mendeteksi dan mengklasifikasikan objek pada data validasi. Precision dan recall meningkat tajam di awal pelatihan dan stabil pada nilai tinggi menandakan model mampu melakukan deteksi dengan sangat sedikit kesalahan dan mencakup Sebagian besar objek yang relevan.

Nilai mAP@0.50 yang mencapai 0.98 mencerminkan keseimbangan optimal antara akurasi klasifikasi dan lokalisasi bounding box pada ambang toleransi standar. Sementara itu, mAP@50-95 yang mencapai 0.78 menunjukkan performa kuat bahkan pada evaluasi spasial yang lebih ketat, menandakan bahwa model tidak hanya akurat mendeteksi objek tetapi juga presisi dalam menempatkan bounding box pada berbagai Tingkat ketelitian.






Gambar 4. (a) Kurva F1, (b) Kurva Precision, (c) Kurva Recall, dan (d) Kurva Hubungan Precision-Recall

Kurva kinerja model yolo12s pada gambar 4 menunjukkan performa deteksi objek yang sangat baik untuk klasifikasi Tingkat kematangan TBS kelapa sawit. F1-Confidence Curve mengindikasikan keseimbangan optimal antara presisi dan recall terjadi pada confidence threshold sekitar 0.508 dengan F1-score mencapai 0.94. Precision dan Recall masing-masing menunjukkan tren yang saling melengkapi. Precision meningkat drastic pada threshold tinggi, sementara recall tinggi pada threshold rendah. Precision mencapai 1.00 pada threshold 0.979, dan recall mencapai 1.00 pada threshold 0.000, mencerminkan fleksibilitas model tergantung kebutuhan aplikasi.

Precision-Recall Curve (P-R Curve) menggambarkan trade-off yang sangat baik, dengan area dibawah kurva yang luas dan presisi tetap tinggi bahkan saat recall tinggi. Nilai Average Precision per kelas berkisar antara 0.971 hingga 0.984, dan mAP@0.5 keseluruhan mencapai 0.978, menandakan akurasi tinggi dan stabilitas model dalam mendeteksi dan mengklasifikasikan objek secara tepat. Keseluruhan hasil ini meunjukkan bahwa model sangat andal untuk diterapkan pada tugas klasifikasi visual tingkat kematangan TBS di dunia nyata.



Gambar 5. Confusion Matrix

Confusion Matrix pada gambar 5 menunjukkan bahwa model YOLO12s memiliki kemampuan klasifikasi yang sangat baik, dengan nilai True Positives tinggi di semua kelas kematangan TBS. Sebagian besar prediksi benar pada diagonal matriks, menandakan akurasi tinggi dalam mengenali dan membedakan masing-masing kelas. Kesalahan klasifikasi antar kelas sangat minim, menunjukkan model mampu membedakan tingkat kematangan dengan baik.

Namun, tantangan utama terletak pada jumlah False Negatives yang diklasifikasikan sebagai "background", terutama pada kelas "terlalu masak" yang menunjukkan 94 instance terlewat. Hal ini mengindikasikan bahwa model terkadang gagal mendeteksi objek Ketika tampilan buah kurang jelas atau tingkat keyakinan rendah. Meski demikian, kesalahan memprediksi background sebagai objek tergolong sangat kecil, yang mendukung tingkat presisi tinggi secara keseluruhan.

Untuk hasil pendeteksian model dengan set data validasi dapat dilihat pada gambar 6 di bawah ini:



Gambar 6. Hasil Deteksi Model

Hasil performa yang dihasilkan oleh model YOLO12s dapat dilihat pada gambar 7 dibawah ini.

```
Validating runs/detect/tandan_palm_detection/weights/best.pt...
Ultralytics 8.3.159 Python-3.11.13 torch-2.6.0-cu124 CUDA: 0 (Tesla T4, 15095MiB)
YOLOv12s summary (fused): 159 layers, 9,232,428 parameters, 0 gradients, 21.2 GFLOPs
```

Class	Images	Instances	Box(P)	R	mAP50	mAP50-95)
all	1269	2528	0.931	0.959	0.978	0.788
kurang masak	304	699	0.957	0.95	0.984	0.782
masak	383	522	0.926	0.964	0.98	0.832
mentah	298	706	0.938	0.966	0.976	0.768
terlalu masak	349	601	0.905	0.957	0.971	0.77

Speed: 0.2ms preprocess, 4.7ms inference, 0.0ms loss, 2.0ms postprocess per image

Gambar 6. Hasil Performa Model YOLO12s

Untuk melihat lebih detail hasil performa yang dihasilkan oleh model YOLO12s, meliputi precision, recall, mAP@:50, dan mAP@:50-95 pada setiap kelasnya dapat dilihat pada table 3.

TABEL 3  
HASIL EVALUASI MODEL YOLO12s

Kelas	Precision	Recall	mAP@:5 0	mAP@:5 0-95
All	0.931	0.959	0.978	0.788
Kurang Masak	0.957	0.95	0.984	0.782
Masak	0.926	0.964	0.98	0.832
Mentah	0.938	0.966	0.976	0.768
Terlalu Masak	0.905	0.957	0.971	0.77

Hasil model YOLO12s pada tabel 3 menunjukkan performa yang sangat tinggi dalam mendeteksi dan mengklasifikasikan tingkat kematangan TBS kelapa sawit. Dengan presisi rata-rata 93.1%, recall 95.9%, mAP@0.50 sebesar 97.8% dan mAP@0.50-0.95 sebesar 78.8%. Walaupun mAP@0.50-0.95 lebih rendah dibandingkan dengan metrik lainnya, hasil tersebut sudah sangat baik. Hal ini dikarenakan metrik ini mengharuskan bounding box memiliki tumpang tindih yang lebih tinggi dan akurat, angka 78.8% sudah menunjukkan bahwa model terbukti mampu mengenali dan melokalisasi objek dengan akurasi yang sangat baik bahkan pada ambang IoU yang lebih ketat. Kinerja ini konsisten di semua kelas, dengan mAP@0.50 per kelas melebihi 97% dan presisi-recall umumnya di atas 90%, meskipun kelas “terlalu masak” sedikit lebih menantang dengan presisi yang sedikit lebih rendah.

Model juga memiliki kecepatan inferensi yang dimana model hanya membutuhkan sekitar 4.7 milidetik per gambar untuk di proses. Hal ini menunjukkan bahwa model memiliki kemampuan yang baik untuk diterapkan dalam deteksi real-time.

Model ini sensitive terhadap variasi pencahayaan, bayangan, serta posisi dan sudut dari pengambilan gambar. Kondisi lapangan yang memiliki sumber pencahayaan alami yang berubah-ubah, background, dan tandan buah segar yang saling bertumpukkan dapat memengaruhi akurasi deteksi. Selain itu, model ini belum diuji secara luas dalam kondisi nyata, seperti lingkungan pabrik kelapa sawit atau area kebun yang tidak seragam dan berubah-ubah.

#### IV. KESIMPULAN

Berdasarkan hasil evaluasi menyeluruh, model object detection YOLO12s menunjukkan kinerja yang sangat baik dalam mengklasifikasikan tingkat kematangan TBS kelapa sawit, dengan nilai presisi dan recall diatas 90%, serta mAP@0.50 mencapai 97.8% dan mAP@0.50-0.95 sebesar 78.8%. performa tinggi ini konsisten di seluruh kelas kematangan, didukung oleh kecepatan inferensi yang sangat cepat dan tingkat kesalahan klasifikasi yang rendah, sehingga membuktikan bahwa YOLO12s mampu menjalankan tugas deteksi dan klasifikasi tingkat kematangan TBS secara utuh, akurat, dan efisien. Untuk pengembangan kedepan, penelitian dapat meningkatkan ketahanan model terhadap kondisi lingkungan yang beragam, seperti memperluas variasi data latih dengan melakukan teknik augmentasi data dan

pengambilan citra dari berbagai sudut dan posisi, serta berbagai kondisi pencahayaan.

#### DAFTAR PUSTAKA

- [1] *Outlook Kelapa Sawit*. Jakarta: Pusat Data dan Sistem Informasi Pertanian, 2024.
- [2] B. P. Statistik, “Produksi Tanaman Perkebunan (Ribu Ton), 2023,” 2 May 2024. Accessed: Jun. 21, 2025. [Online]. Available: <https://www.bps.go.id/id/statistics-table/2/MTMyIzI=/produksi-tanaman-perkebunan.html>
- [3] E. F. Himmah, M. Widyarningsih, and M. Maysaroh, “Identifikasi Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Menggunakan Metode K-Means Clustering,” *J. Sains dan Inform.*, vol. 6, no. 2, pp. 193–202, 2020, doi: 10.34128/jsi.v6i2.242.
- [4] J. Zulkarnain, Kusrini, and T. Hidayat, “Klasifikasi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit Menggunakan Pendekatan Deep Learning,” *JST (Jurnal Sains dan Teknol.*, vol. 12, no. 3, pp. 748–758, 2024, doi: 10.23887/jstundiksha.v12i3.59140.
- [5] M. Y. M. A. Mansour, K. D. Dambul, and K. Y. Choo, “Object Detection Algorithms for Ripeness Classification of Oil Palm Fresh Fruit Bunch,” *Int. J. Technol.*, vol. 13, no. 6, pp. 1326–1335, 2022, doi: 10.14716/ijtech.v13i6.5932.
- [6] 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, pp. 302–309, 2023, doi: 10.47065/josh.v5i1.4408.
- [7] A. Ritonga, A. A. Munawar, and I. S. Nasution, “Klasifikasi Kematangan Tandan Buah Segar Kelapa Sawit (*Elaeis guineensis* Jacq) menggunakan Pengolahan Citra Digital,” *J. Ilm. Mhs. Pertan.*, vol. 8, no. 3, pp. 437–445, 2023.
- [8] 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, pp. 91–99, 2023, doi: 10.34010/komputa.v12i2.10654.
- [9] T. M. Banhazi and M. Tschärke, “A brief review of the application of machine vision in livestock behaviour analysis,” *J. Agric. Informatics*, vol. 7, no. 1, pp. 23–42, 2016, doi: 10.17700/jai.2016.7.1.279.
- [10] F. Gusnanto, N. Rahaningsih, R. D. Dana, T. Informatika, and K. Cirebon, “Optimasi Model Klasifikasi Tingkat Kematangan Buah Mangga Dengan Metode Yolo11,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 1, pp. 1773–1780, 2025, doi: doi.org/10.36040/jati.v9i1.12591.
- [11] 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, pp. 623–628, 2024, doi: 10.57152/malcom.v4i2.1270.
- [12] A. Wibowo, L. Lusiana, 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, p. 123, 2023, doi: 10.35138/paspalum.v11i1.489.
- [13] Z. Genoveva and R. D. Syah, “Model Machine Learning Untuk Deteksi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit Menggunakan Metode,” *J. Pertan. Presisi (Journal Precis. Agric.*, vol. 8, pp. 121–136, 2024, doi: <http://dx.doi.org/10.35760/jpp.2024.v8i2.11848>.
- [14] D. S. Prasvita, M. M. Santoni, and N. Falihi, “Deteksi Pohon Kelapa Sawit dengan Pendekatan Deep Learning pada Citra Multispectral di Indonesia,” *Indones. J. Comput. Sci.*, vol. 13, no. 2, pp. 3111–3125, 2024, doi: 10.33022/ijcs.v13i2.3753.
- [15] M. Gelar, S. Komputer, and U. M. Sorong, “Implementasi deep learning untuk deteksi umur berdasarkan citra wajah suku moi menggunakan metode yolo,” 2024.