

Klasifikasi *Grade* Tomat Menggunakan *You Only Look Once* Untuk Penyortiran Pascapanen

<http://dx.doi.org/10.28932/jutisi.v12i2.14259>

Riwayat Artikel

Received: 30 Desember 2025 | Final Revision: 15 Juli 2026 | Accepted: 30 Juli 2026

Creative Commons License 4.0 (CC BY – NC)



Anggoro Panji Sulisty^{✉ #1}, Magdalena Ariance Ineke Pakereng^{#2}

<sup>#Prodi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana
Jl. Dr. O. Notohamidjojo, Salatiga 50714, Indonesia</sup>

¹anggoropanji845@gmail.com

²ineke.pakereng@uksw.edu

[✉]Corresponding author: anggoropanji845@gmail.com

Abstrak — Tomat merupakan salah satu komoditas hortikultura bernilai ekonomi tinggi, namun proses pemilahan kualitas pada lingkungan pertanian skala kecil masih dilakukan secara manual sehingga menimbulkan ketidakkonsistenan, subjektivitas, dan ketergantungan pada tenaga kerja. Penelitian ini merancang sistem klasifikasi *grade* tomat berbasis *You Only Look Once* version 8 Large (YOLOv8-L) untuk mengoptimalkan pemilahan hasil panen di tingkat petani. Dataset terdiri dari 683 citra lapangan yang dianotasi menggunakan *polygon tool* pada platform Roboflow, dengan pembagian 512 data pelatihan, 103 validasi, dan 68 pengujian. Model dilatih menggunakan *optimizer Adaptive Moment Estimation with Decoupled Weight Decay* (AdamW) dengan *batch size* 16 selama 50 *epoch*. Hasil evaluasi menunjukkan *mean Average Precision* pada *Intersection over Union* 0,5 (mAP@0,5) sebesar 97,5% dan *mean Average Precision* pada rentang *Intersection over Union* 0,5 hingga 0,95 (mAP@0,5:0,95) sebesar 95,2%, dengan *precision* 93,3% dan *recall* 91,6%. Pada tahap pengujian, sistem mampu memproses sekitar 40 tomat dalam waktu $\pm 2,5$ detik per wadah, meningkatkan efisiensi pemilahan hingga $\pm 97,2\%$ dibandingkan metode manual yang membutuhkan sekitar 90 detik. Hasil ini menunjukkan potensi penerapan kecerdasan buatan dalam mendukung *precision agriculture* serta integrasi dengan sistem penyortiran otomatis.

Kata kunci—Deteksi objek; Klasifikasi *grade* tomat; Penyortiran pascapanen; Pertanian presisi; YOLOv8.

Tomato Grade Classification Using *You Only Look Once* for Post-Harvest Sorting

Abstract — Tomatoes are one of the horticultural commodities with high economic value; however, quality grading in small-scale agricultural environments is still predominantly performed manually, leading to inconsistency, subjectivity, and high labor dependency. This study proposes a tomato grade classification system based on *You Only Look Once* version 8 Large (YOLOv8-L) to optimize post-harvest sorting at the farmer level. The dataset consists of 683 field images annotated using a *polygon tool* on the Roboflow platform, divided into 512 training images, 103 validation images, and 68 testing images. The model was trained using *Adaptive Moment Estimation with Decoupled Weight Decay* (AdamW) optimizer with a *batch size* of 16 for 50 *epochs*. Evaluation results show a *mean Average Precision* at an *Intersection over Union* threshold of 0.5 (mAP@0.5) of 97.5% and a *mean Average Precision* averaged over *Intersection over Union* thresholds from 0.5 to 0.95 (mAP@0.5:0.95) of 95.2%, with *precision* and *recall* values of 93.3% and 91.6%, respectively. During testing, the system processed approximately 40 tomatoes in ± 2.5 seconds per container, improving sorting efficiency by approximately 97.2% compared to the manual method, which required around 90 seconds. These results demonstrate the potential

of artificial intelligence to support precision agriculture and its integration into automated sorting systems such as conveyor-based solutions.

Keywords—Classification; Detection; Post-harvest sorting; Precision agriculture; YOLOv8.

I. PENDAHULUAN

Tomat merupakan salah satu komoditas hortikultura bernilai ekonomi tinggi [1], terutama di wilayah pertanian Indonesia. Tomat memberikan kontribusi signifikan terhadap penyerapan tenaga kerja dan pendapatan petani, namun proses pemilihan kualitas masih dilakukan secara manual sehingga menimbulkan ketidakonsistenan, subjektivitas, dan ketergantungan pada tenaga kerja yang terbatas. Selain itu, metode manual ini juga menimbulkan biaya operasional yang tinggi dan ketergantungan pada jumlah tenaga kerja yang terbatas [2].

Seiring dengan perkembangan teknologi, kecerdasan buatan (*Artificial Intelligence*) mulai dimanfaatkan dalam sektor pertanian untuk meningkatkan efisiensi dan akurasi kerja. Salah satu pendekatan yang digunakan adalah algoritma deteksi objek, seperti *You Only Look Once* (YOLO), yang mampu mengenali dan mengklasifikasikan objek dalam citra secara otomatis dengan kecepatan *real-time* [3]. Versi baru dari algoritma ini, yaitu YOLOv8, menawarkan peningkatan performa yang signifikan dalam hal kecepatan pelatihan model dan akurasi deteksi objek [4], sehingga cocok digunakan untuk aplikasi klasifikasi hasil panen berbasis karakteristik visual seperti warna, bentuk, dan cacat permukaan.

Penelitian terdahulu telah menunjukkan potensi algoritma YOLO dalam aplikasi pertanian. Penelitian tentang "Deteksi Tingkat Kematangan Buah Tomat Menggunakan YOLOv5" memanfaatkan YOLOv5 untuk klasifikasi kematangan tomat berdasarkan warna dan tekstur, dengan akurasi 89% dan waktu inferensi 23 ms per gambar [5]. Meskipun efektif, model ini masih memiliki keterbatasan dalam hal akurasi dan adaptabilitas dibandingkan versi yang lebih baru. Penelitian tentang "Fruit ripeness identification using YOLOv8 model" mengembangkan sistem identifikasi tingkat kematangan buah tropis berbasis YOLOv8 [6], dengan akurasi mencapai 94%. Model ini terbukti adaptif terhadap kondisi pencahayaan alami dan latar belakang kompleks, yang umum di wilayah pertanian. Temuan ini relevan karena kematangan buah merupakan indikator penting dalam klasifikasi *grade* tomat.

Studi "YOLOv8-Orah: An Improved Model for Postharvest Orah Mandarin Surface Defect Detection" memodifikasi YOLOv8 dengan *Multi-Scale Attention Module* untuk mendeteksi cacat permukaan buah jeruk [7], mencapai presisi 91%. Meskipun fokus pada jeruk, metodologi ini berpotensi diterapkan untuk deteksi cacat fisik tomat sebagai indikator *grade*. Penelitian "YOLO-Tomato: A Robust Algorithm for Tomato Detection Based on YOLOv3" menerapkan algoritma YOLO untuk deteksi tomat secara akurat [8], menunjukkan keunggulan dalam kecepatan pemrosesan. Penelitian "*Deep learning-based real-time detection and classification of tomato ripeness stages using YOLOv8 on raspberry Pi*" mengimplementasikan YOLOv8 pada perangkat *edge* (Raspberry Pi) [9] untuk deteksi kematangan tomat secara *real-time*, menunjukkan bahwa *pipeline* berbasis YOLOv8 dapat beroperasi pada infrastruktur komputasi terbatas.

Penelitian "Tomato Health Monitoring System: Tomato Classification, Detection, and Counting System Based on YOLOv8 Model With Explainable MobileNet Models Using Grad-CAM++" menggabungkan YOLOv8 dengan Grad-CAM++ untuk klasifikasi tomat dengan interpretabilitas yang baik [10], mencapai akurasi 90%. Studi "ASE-YOLOv8n: A Method for Cherry Tomato Ripening Detection" memodifikasi YOLOv8 dengan *Adaptive Spatial Enhancement* [11] untuk meningkatkan akurasi deteksi kematangan tomat ceri hingga 95%. Penelitian "CNN-YOLOv8-Based Tomato Quality Inspection System: A Case Study in Vietnam" menerapkan model hybrid CNN-YOLOv8 untuk inspeksi kualitas tomat di Vietnam [12], dengan akurasi 94% dan presisi 93%, menunjukkan bahwa *pipeline* berbasis YOLOv8 tetap operasional pada infrastruktur pertanian skala kecil. Penelitian terbaru juga menunjukkan bahwa sistem klasifikasi tomat berbasis YOLOv8 mampu mendukung proses penyortiran otomatis secara *real-time* dengan integrasi mekanisme sortir fisik pada lingkungan pascapanen [13].

Studi "Overview of Deep Learning and Nondestructive Detection Technology for Quality Assessment of Tomatoes" mengevaluasi penerapan *deep learning* termasuk YOLO dalam inspeksi kualitas tomat secara *real-time* [14], menunjukkan akurasi tinggi (92%-95%) dalam mendeteksi cacat tanpa merusak buah. Penelitian "Tomato Maturity Detection and Counting Model Based on MHSA-YOLOv8" mengintegrasikan *Multi-Head Self-Attention* ke dalam YOLOv8 [15] untuk mendeteksi tiga tingkat kematangan tomat, mencapai 93,4% mAP@0.5. Penelitian "*Deep Learning Techniques in Tomato Plant – A Review*" membandingkan berbagai teknik *deep learning* termasuk YOLO untuk klasifikasi kualitas dan kematangan tomat [16], menekankan pentingnya data lokal untuk menghindari bias model. Penelitian "Automating Tomato Ripeness Classification and Counting with YOLOv9" menggunakan YOLOv9 untuk mengotomatisasi klasifikasi kematangan dan penghitungan tomat [17], menghasilkan akurasi 93,6% namun dengan kompleksitas komputasi yang lebih besar.

Meskipun penelitian-penelitian sebelumnya telah menunjukkan efektivitas YOLO dalam klasifikasi tomat, terdapat *gap* yang signifikan dalam literatur. Sebagian besar penelitian fokus pada klasifikasi kematangan (*ripeness*) daripada klasifikasi *grade* (kualitas), menggunakan *dataset* sintesis atau terkontrol, serta belum banyak yang mengimplementasikan pada konteks

pertanian lokal Indonesia dengan kondisi lapangan yang kompleks. Penelitian ini menutup *gap* tersebut dengan memanfaatkan *dataset* lokal yang dikumpulkan langsung dari lapangan, fokus pada klasifikasi *grade* tomat (Grade A dan B) berdasarkan karakteristik visual (warna, kilap, bentuk), dan mengevaluasi efektivitas model pada kondisi pencahayaan alami serta latar belakang kompleks yang khas di wilayah pertanian Indonesia.

Secara arsitektur, YOLOv8 menonjol melalui desain *decoupled head* yang memisahkan tugas klasifikasi dan regresi untuk spesialisasi yang lebih baik, desain *anchorfree* yang menyederhanakan *Non-Maximum Suppression* (NMS) dan mengurangi kebutuhan penalaan parameter, serta *Distribution Focal Loss* (DFL) pada *backbone* C2f yang meningkatkan *trade-off* antara *precision-recall* dan stabilitas pelatihan dibanding generasi sebelumnya [18]. Untuk menegaskan alasan pemilihan model, perbandingan arsitektur YOLOv5, YOLOv7, dan YOLOv8 disajikan pada Tabel 1.

TABEL 1
PERBANDINGAN ARSITEKTUR YOLOv5, YOLOv7, YOLOv8.

Aspek	YOLOv5	YOLOv7	YOLOv8
<i>Backbone</i>	CSPDarknet53	ELAN/E-LAN	C2f
<i>Head Architecture</i>	Coupled	Coupled	Decoupled
<i>Anchor</i>	<i>Anchor-based</i>	<i>Anchor-based</i>	<i>Anchor-free</i>
Indikator mAP (COCO)	50,7%	53,1%	53,9%

Sumber: Diadaptasi dari Ultralytics [19], [20]


Nilai mAP yang dicantumkan pada Tabel 1 bersifat indikatif literatur dan sangat dipengaruhi oleh perangkat, ukuran input, serta *pipeline*. Oleh karena itu, pengukuran aktual studi ini dilaporkan tersendiri pada bagian Hasil untuk menjaga kesesuaian konteks uji. Dengan mempertimbangkan perbandingan pada Tabel 1, YOLOv8 dipilih karena kombinasi *decoupled head*, desain *anchor-free*, *backbone* C2f yang matang, serta ekosistem Ultralytics yang mendukung dengan baik. Pada penelitian ini digunakan varian YOLOv8-L (*Large*) untuk memperoleh kapasitas representasi fitur yang lebih tinggi dalam proses klasifikasi *grade* tomat pada kondisi lapangan yang kompleks. Pilihan ini memungkinkan pencapaian kinerja yang relevan secara praktis di lapangan dan mudah direplikasi.

Penelitian ini bertujuan menganalisis efektivitas sistem klasifikasi *grade* tomat berbasis YOLOv8-L untuk mengoptimalkan pemilahan hasil panen di tingkat petani, dengan evaluasi melalui metrik standar (mAP@0,5, mAP@0,5:0,95, *precision*, *recall*, dan *F1-score*) serta perbandingan efisiensi waktu terhadap praktik sortir manual. Kontribusi penelitian ini mencakup tiga aspek utama. Pertama, pemanfaatan *dataset* lokal dengan pencahayaan alami dan latar belakang kompleks, mengurangi *domain gap* antara *training* dan skenario penerapan sebenarnya. Kedua, penyesuaian *pipeline* YOLOv8-L yang selaras dengan karakteristik data lokal, memastikan model dilatih pada distribusi data yang representatif. Ketiga, pelaporan dampak praktis melalui efisiensi waktu per wadah sebagai evidensi manfaat konkret menuju integrasi ke sistem otomatis.

Ruang lingkup penelitian dibatasi pada dua kelas *grade* (Grade A dan B), citra lapangan dengan ukuran input 640×640 piksel, tanpa perancangan mekanisme sortir fisik, dan tidak mencakup perbandingan mendalam antar versi YOLO (perbandingan Tabel 1 bersifat studi literatur). Penelitian ini diharapkan dapat memberikan landasan teknis dan praktis bagi adopsi teknologi *deep learning* dalam sektor pertanian tomat Indonesia, khususnya untuk optimalisasi penyortiran hasil panen di tingkat petani skala kecil hingga menengah.

II. METODE

Penelitian ini dirancang melalui serangkaian tahapan sistematis untuk mengembangkan sistem klasifikasi *grade* tomat berbasis YOLOv8-L. Tahapan-tahapan tersebut meliputi pengumpulan data, pengolahan data, pembuatan model, pengujian model, dan evaluasi hasil penelitian, sebagaimana ditunjukkan dalam Gambar 1.



Gambar 1. Tahapan Penelitian

A. Pengumpulan Data.

Tahap pengumpulan *dataset* dilakukan pada lingkungan pascapanen tomat skala pertanian hortikultura dengan pencahayaan alami dan latar kebun yang bervariasi. Setiap sampel terlebih dahulu ditetapkan untuk setiap *grade* (Grade A/Grade B) melalui kesepakatan operasional dengan petani hortikultura, kemudian citra diambil menggunakan kamera ponsel pada jarak sekitar 20–30 cm dengan komposisi objek dominan, sudut pengambilan konsisten, serta beberapa variasi orientasi untuk menangkap heterogenitas kondisi lapangan. Kontrol kualitas dilakukan dengan menyingkirkan citra yang buram atau *over-exposed* serta memastikan adanya variasi latar dan skala agar model belajar dari distribusi kondisi nyata. Seluruh citra hasil akuisisi diteruskan ke tahap anotasi *polygon* dan diekspor ke format YOLO pada resolusi kerja 640×640 piksel untuk keselarasan dengan *pipeline* pelatihan. Proses pengambilan citra tomat pada lingkungan pascapanen dengan pencahayaan alami ditunjukkan pada Gambar 2.



Gambar 2. Proses pengambilan citra tomat pada lingkungan pascapanen dengan pencahayaan alami.


B. Preprocessing Data

Tahap pengolahan data diawali dengan anotasi seluruh citra menggunakan *polygon tool* pada platform Roboflow untuk mengikuti kontur buah secara presisi. Pendekatan ini dipilih agar batas objek yang tidak beraturan tetap terwakili sehingga informasi bentuk dan sebaran warna yang relevan bagi perbedaan *grade* dapat dipelajari model dengan lebih akurat. Setelah proses penandaan, dilakukan peninjauan ulang untuk mengoreksi *polygon* yang memotong objek atau menyisakan latar berlebih, memastikan konsistensi kelas pada tiap citra, serta menstandarkan ukuran kanvas ke 640×640 piksel sebelum ekspor ke format YOLO beserta berkas daftar kelas.

Penetapan kelas dilakukan secara operasional melalui observasi lapangan dan pemilihan langsung bersama petani hortikultura. Definisi operasional untuk masing-masing *grade* adalah sebagai berikut:

- 1) Grade A: Didefinisikan sebagai buah dengan karakteristik visual dengan warna dominan orange-kemerahan yang relatif merata di seluruh permukaan, permukaan cerah dan mengkilap, serta bentuk cenderung proporsional dan simetris.
- 2) Grade B: Didefinisikan sebagai buah dengan karakteristik visual seperti warna kurang merata dengan dominasi hijau-kekuningan atau campuran warna yang tidak seragam, permukaan cenderung kusam atau tidak mengkilap, serta bentuk kurang simetris atau irregular.

Contoh proses anotasi tomat Grade A dan Grade B menggunakan *polygon tool* pada platform Roboflow masing-masing ditunjukkan pada Gambar 3 dan Gambar 4.



Gambar 3. Proses anotasi tomat Grade A menggunakan *polygon tool* pada platform Roboflow, menunjukkan presisi penandaan kontur buah untuk pembelajaran fitur bentuk dan distribusi warna.




Gambar 4. Proses anotasi tomat Grade B menggunakan *polygon tool* pada platform Roboflow, menunjukkan variasi karakteristik visual seperti warna tidak merata dan bentuk irregular yang dipelajari model.

C. Pembagian Dataset

Dataset citra tomat dibagi menjadi tiga bagian utama, yaitu 75% data pelatihan (*training*), 15% data validasi (*validation*), dan 10% data pengujian (*testing*). Pembagian ini bertujuan memastikan model mampu mempelajari pola secara optimal dari data pelatihan, memvalidasi kinerja selama iterasi pelatihan, serta menguji kemampuan generalisasi pada data yang sama sekali baru. Total *dataset* terdiri dari 683 citra, yang meliputi 512 citra pelatihan, 103 citra validasi, dan 68 citra pengujian.

Dataset yang digunakan mengandung variasi pencahayaan alami, sudut pengambilan gambar, dan latar belakang yang beragam untuk merepresentasikan kondisi lapangan sebenarnya. Setiap citra berisi objek tomat dengan karakteristik visual yang digunakan untuk klasifikasi Grade A dan Grade B. Contoh citra *dataset* beserta distribusi pembagian data ditunjukkan pada Gambar 5.



Gambar 5. Contoh citra *dataset* dan distribusi pembagian data *training*, *validation*, dan *testing*.

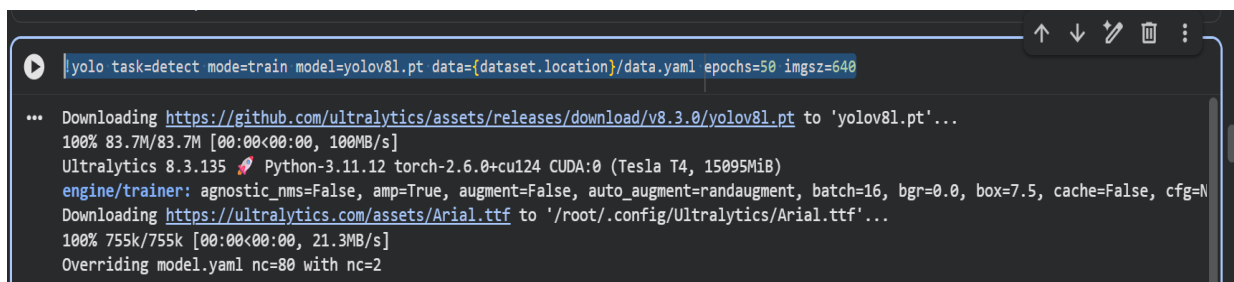
Seluruh *dataset* yang telah dianotasi dikelola melalui platform Roboflow dan dimuat ke lingkungan Google Colab melalui API proyek sehingga struktur direktori *training*, *validation*, dan *testing*, serta berkas konfigurasi data kompatibel dengan format YOLOv8.

D. Konfigurasi dan Pelatihan Model

Model yang diimplementasikan adalah YOLOv8-L. Proses pelatihan dijalankan pada GPU Tesla T4 dengan resolusi input 640×640 piksel selama 50 *epoch*, *batch size* 16, menggunakan *optimizer* AdamW dan penjadwalan laju belajar *cosine annealing*, serta didukung oleh augmentasi Mosaic, AutoAugment, dan penyesuaian HSV. Pemilihan YOLOv8-L didasarkan pada keseimbangan antara akurasi dan efisiensi komputasi, khususnya untuk menangkap variasi karakter visual *grade* tomat pada kondisi lapangan. Parameter pelatihan yang digunakan meliputi:

- *Optimizer*: AdamW
- *Learning rate schedule*: *Cosine annealing* (0,001667–0,0000497)
- *Batch size*: 16
- *Epochs*: 50
- *Input resolution*: 640×640 piksel
- Augmentasi: Mosaic, AutoAugment, dan HSV

Augmentasi HSV digunakan untuk meningkatkan ketahanan model terhadap variasi pencahayaan alami yang umum dijumpai pada lingkungan pertanian terbuka [6]. Implementasi pelatihan model YOLOv8-L di Google Collab menggunakan perintah Ultralytics ditunjukkan pada Gambar 6.




```
!yolo task=detect mode=train model=yolov8l.pt data={dataset.location}/data.yaml epochs=50 imgsz=640

... Downloading https://github.com/ultralytics/assets/releases/download/v8.3.0/yolov8l.pt to 'yolov8l.pt'...
100% 83.7M/83.7M [00:00<00:00, 100MB/s]
Ultralytics 8.3.135 Python-3.11.12 torch-2.6.0+cu124 CUDA:0 (Tesla T4, 15095MiB)
engine/trainer: agnostic_nms=False, amp=True, augment=False, auto_augment=randaugment, batch=16, bgr=0.0, box=7.5, cache=False, cfg=N
Downloading https://ultralytics.com/assets/Arial.ttf to '/root/.config/Ultralytics/Arial.ttf'...
100% 755k/755k [00:00<00:00, 21.3MB/s]
Overriding model.yaml nc=80 with nc=2
```

Gambar 6. Implementasi pelatihan model YOLOv8-L di Google Collab menggunakan perintah Ultralytics.

E. Pengujian Model

Tahap pengujian dilakukan menggunakan 10% data uji yang tidak terlibat pada proses pelatihan maupun penalaan. Model terbaik hasil pelatihan, berdasarkan kinerja pada data validasi, dimuat untuk melakukan inferensi pada seluruh citra uji dengan mekanisme *Non-Maximum Suppression*. Ambang kepercayaan (*confidence threshold*) dan ambang *Intersection-over-Union* (IoU) ditetapkan berdasarkan hasil validasi dan dikunci sebelum pengujian untuk menjaga objektivitas evaluasi [7]. Waktu inferensi diukur sebagai rata-rata milidetik per gambar dari tiga kali pengulangan dan dikonversi menjadi *Frame Per Second* (FPS). Proses pengujian model YOLOv8-L pada data uji ditunjukkan pada Gambar 7.



```
!yolo detect predict model=/content/runs/detect/train/weights/best.pt source=/content/drive/MyDrive/TTU/testing

... Ultralytics 8.3.135 Python-3.11.12 torch-2.6.0+cu124 CUDA:0 (Tesla T4, 15095MiB)
Model summary (fused): 112 layers, 43,608,150 parameters, 0 gradients, 164.8 GFLOPs
```

Gambar 7. Proses pengujian model YOLOv8-L pada data uji.

F. Metrik Evaluasi

Evaluasi kinerja sistem klasifikasi *grade* tomat dilakukan secara kuantitatif dan kualitatif menggunakan matrix yang umum digunakan pada penelitian deteksi objek berbasis *deep learning*. Pengujian dilakukan pada data uji yang tidak terlibat dalam proses pelatihan maupun penalaan model untuk memastikan objektivitas dan kemampuan generalisasi sistem. Kinerja model dievaluasi menggunakan *Precision*, *Recall*, *F1-score*, dan *mean Average Precision* (mAP). Definisi matematis masing-masing metrik dirumuskan sebagai berikut.

Precision mengukur rasio prediksi benar terhadap seluruh prediksi positif, dinyatakan dengan Persamaan

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

Recall mengukur kemampuan model dalam mendeteksi seluruh sampel positif aktual, dinyatakan dengan Persamaan

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

F1-score merupakan rata-rata harmonik dari *Precision* dan *Recall*, yang memberikan ukuran kinerja seimbang antara keduanya, dirumuskan pada Persamaan

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

Selain itu, digunakan *Average Precision* (AP) yang diperoleh dari luas area di bawah kurva *Precision-Recall* untuk setiap kelas. Mean *Average Precision* (mAP) dihitung sebagai rata-rata AP dari seluruh kelas, sebagaimana dinyatakan pada Persamaan

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4)$$

dengan AP_i menyatakan *Average Precision* kelas ke- i dan N jumlah kelas. Dua variasi mAP digunakan, yaitu mAP@0,5 dan mAP@0,5:0,95, untuk merepresentasikan performa model pada berbagai tingkat ketelitian IoU.

Efisiensi komputasi dievaluasi berdasarkan waktu inferensi rata-rata per citra dalam satuan milidetik (ms/gambar), yang diukur melalui beberapa pengulangan pada perangkat keras yang sama untuk menjaga konsistensi. Nilai tersebut kemudian dikonversi menjadi FPS menggunakan Persamaan

$$FPS = \frac{1000}{ms/gambar} \quad (5)$$

Metrik ini digunakan untuk menilai kelayakan sistem dalam mendukung proses penyortiran pasca panen secara *semi-real-time*. Selain metrik kuantitatif, evaluasi kinerja sistem juga dilengkapi dengan analisis kualitatif untuk memperkuat interpretasi hasil. Analisis tersebut meliputi:

- Kurva *Precision-Recall* per kelas, untuk menilai stabilitas kinerja model pada berbagai ambang kepercayaan.
- *Confusion matrix*, untuk mengidentifikasi pola kesalahan dan misklasifikasi antar *grade* tomat.
- Kurva *F1-Confidence*, untuk mengevaluasi sensitivitas sistem terhadap perubahan nilai *confidence threshold*.
- Visualisasi hasil inferensi pada data uji, guna memastikan bahwa deteksi dan klasifikasi yang dihasilkan sesuai secara visual dengan karakteristik objek sebenarnya.

Seluruh hasil evaluasi kuantitatif dan kualitatif disajikan secara terperinci pada bagian Hasil dan Pembahasan sebagai dasar analisis performa dan potensi penerapan sistem di lingkungan pascapanen.

III. HASIL DAN PEMBAHASAN

Model YOLOv8-L yang dilatih selama 50 *epoch* menunjukkan performa optimal berdasarkan metrik mAP@0,5:0,95 pada set validasi. Metrik presisi mencapai 93,3%, menunjukkan bahwa model mampu meminimalkan *false positive* dengan sangat efektif. *Recall* sebesar 91,6% mengindikasikan kemampuan model dalam mendeteksi sebagian besar objek tomat yang sebenarnya ada dalam citra. *F1-score* 92,5% sebagai rata rata harmonik antara *precision* dan *recall* menunjukkan keseimbangan performa yang baik antara kedua metrik tersebut.


Nilai mAP@0,5 sebesar 97,5% menunjukkan kemampuan deteksi yang sangat baik pada *threshold* IoU 0,5, sementara mAP@0,5:0,95 sebesar 95,3% mengindikasikan bahwa model tetap akurat pada *threshold* IoU yang lebih ketat. Kecepatan inferensi rata-rata tercatat sebesar 62,7 ms per gambar atau setara dengan sekitar 15,9 FPS. Dengan asumsi satu wadah berisi 40 tomat, estimasi waktu pemrosesan adalah sekitar 2,5 detik, yang secara signifikan lebih cepat dibandingkan metode penyortiran manual. Ringkasan metrik agregat hasil validasi dan inferensi model YOLOv8-L disajikan pada Tabel 2.

TABEL 2
RINGKASAN METRIK AGREGAT HASIL VALIDASI DAN INFERENSI MODEL YOLOV8-L.

Metrik	Nilai
<i>Precision</i>	93,3%
<i>Recall</i>	91,6%
<i>F1-Score</i>	92,5%

Metrik	Nilai
mAP@0,5	97,5%
mAP@0,5:0,95	95,2%
Inference Time	62,7 ms/gambar
FPS	±15,9
Waktu per wadah (40 tomat)	±2,5 detik

Pola konvergensi model selama proses pelatihan dianalisis melalui kurva *training* dan *validation loss* serta evolusi metrik evaluasi, Gambar 8 menunjukkan pola konvergensi model selama 50 *epoch* pelatihan, yang terdiri dari kurva *training* dan *validation loss* (*train/box_loss*, *train/cls_loss*, *train/dfl_loss*) serta evolusi metrik evaluasi (*metrics/precision(B)*, *metrics/recall(B)*, *metrics/mAP50(B)*, dan *metrics/mAP50-95(B)*). Semua komponen *loss* pelatihan menunjukkan penurunan tajam pada *epoch* awal (1-15) dan mencapai stabilitas pada *epoch* akhir (40-50). *Loss* validasi (*val/box_loss*, *val/cls_loss*, *val/dfl_loss*) mengikuti pola serupa dengan *gap* yang relatif kecil terhadap *loss* pelatihan, mengindikasikan tidak adanya *overfitting* yang signifikan.



Gambar 8. Konvergensi *Loss* dan Metrik Evaluasi Model YOLOv8-L Selama 50 *Epoch*.


Metrik presisi dan *recall* pada set validasi menunjukkan peningkatan progresif dari *epoch* awal hingga stabil di kisaran 90-98% pada *epoch* akhir. Kurva mAP@0,5 dan mAP@0,5:0,95 memperlihatkan tren peningkatan yang konsisten, mencapai *plateau* pada *epoch* 35-50 dengan nilai di atas 95%, menandakan model telah konvergen dengan baik. Tabel 3 menyajikan dinamika reduksi *loss* pada fase awal (*epoch* 6-10) dan fase akhir (*epoch* 46-50) pelatihan, menunjukkan efektivitas pembelajaran.

TABEL 3
DINAMIKA PELATIHAN DAN KONVERGENSI MODEL.

Phase	Train Box Loss	Train Cls Loss	Val Box Loss	Val Cls Loss
Epoch Awal (6-10)	0,4817	0,8422	0,5573	1,2523
Epoch Akhir (46-50)	0,1534	0,2307	0,1739	0,2879
Reduksi Loss	68,1%	72,6%	68,8%	77,0%

Reduksi *loss* yang signifikan pada semua komponen (68-77%) menunjukkan proses pembelajaran yang efektif. *Gap* antara *training* dan *validation loss* pada *epoch* akhir relatif kecil *box loss gap* 0,0205 (13,4% dari *training loss*) dan *cls loss gap* 0,0573 (24,8% dari *training loss*) mengonfirmasi bahwa model tidak mengalami *overfitting* dan mampu generalisasi dengan baik pada data yang belum pernah dilihat.


Gambar 9 menampilkan *labels correlogram* yang menunjukkan distribusi spasial dan dimensi *bounding box* dari kedua kelas (Grade A dan Grade B). *Scatter plot* menunjukkan bahwa kedua kelas memiliki distribusi posisi *x* dan *y* yang tersebar merata di seluruh area citra, mengindikasikan variasi sudut pengambilan gambar dan komposisi objek yang beragam sesuai dengan kondisi lapangan. Histogram *width* dan *height* menunjukkan distribusi ukuran *bounding box* yang relatif normal dengan sedikit variasi, mencerminkan ukuran tomat yang cukup homogen dalam *dataset*.



Gambar 9. Korelogram Label *Dataset* Kelas Grade A dan Grade B.

Korelasi positif antara *width* dan *height* mengindikasikan konsistensi rasio aspek objek tomat, yang membantu model mempelajari pola bentuk dengan lebih baik. Distribusi ini juga menunjukkan bahwa *dataset* mencakup variasi skala yang memadai untuk melatih model agar *robust* terhadap perbedaan jarak dan perspektif pengambilan citra.


Gambar 10 menampilkan kurva *Precision-Recall* (*PR Curve*) yang menunjukkan performa model untuk masing-masing kelas. Grade A mencapai mAP 0,987 dengan kurva yang mendekati sudut kanan atas, mengindikasikan *precision* dan *recall* yang tinggi di berbagai *threshold confidence*. Grade B memiliki mAP 0,963, sedikit lebih rendah namun masih menunjukkan performa yang sangat baik. mAP agregat untuk seluruh kelas adalah 0,975 pada IoU 0,5, mengonfirmasi konsistensi model dalam mendeteksi kedua *grade* tomat.



Gambar 10. Kurva *Precision-Recall* Per Kelas (Grade A dan Grade B).

Performa Grade A yang sedikit lebih tinggi diduga disebabkan oleh karakteristik visual yang lebih konsisten dengan warna oranye-kemerahan yang merata, permukaan mengkilap, dan bentuk yang proporsional yang lebih mudah dipelajari model. Sebaliknya, Grade B memiliki variasi warna hijau-kekuningan, permukaan kusam, dan bentuk yang kurang simetris, sehingga memerlukan representasi fitur yang lebih kompleks.


Pola kesalahan klasifikasi dianalisis menggunakan *confusion matrix* ternormalisasi sebagaimana ditunjukkan pada Gambar 11 menampilkan *confusion matrix ternormalisasi* yang menunjukkan pola klasifikasi model pada set validasi dengan 3 kelas: Grade B, Grade A, dan *background*. Grade B terdeteksi dengan akurasi 92%, sementara Grade A mencapai 91%. Model mampu membedakan kedua kelas dengan sangat baik, ditunjukkan oleh nilai diagonal yang tinggi (>90%).



Gambar 11. *Normalized Confusion Matrix* Klasifikasi Grade Tomat.

Misklasifikasi yang terjadi relatif kecil, Grade B diprediksi sebagai Grade A 8% dan 9% Grade A diprediksi sebagai Grade B. Kesalahan ini kemungkinan disebabkan oleh tomat yang berada di perbatasan antara kedua *grade*. Misalnya, tomat Grade B dengan warna yang sudah mulai memerah atau tomat Grade A dengan sedikit cacat permukaan. Tingkat kesalahan pada kelas *background* (40%) menunjukkan bahwa model masih kesulitan membedakan latar belakang dengan objek tomat dalam beberapa kasus, terutama pada kondisi pencahayaan alami dan latar kompleks yang khas di lapangan [7].

Gambar 12 menampilkan kurva *F1-Confidence* yang menunjukkan hubungan antara *threshold confidence* dan nilai *F1-score*. Model mencapai *F1-score* maksimal 0,92 pada *confidence threshold* 0,687. Kurva menunjukkan bahwa *F1-score* relatif stabil pada rentang *confidence* 0,5–0,85, mengindikasikan *robustness* model terhadap variasi *threshold*.



Gambar 12. Kurva *F1-Confidence* Model YOLOv8-L.

Pada *confidence* di bawah 0,5, *F1-score* menurun drastis karena meningkatnya *false positive*. Sebaliknya, pada *confidence* di atas 0,9, *F1-score* juga menurun akibat meningkatnya *false negative* karena model terlalu konservatif dalam memprediksi. Berdasarkan analisis ini, rentang *confidence threshold* operasional yang direkomendasikan adalah 0,65–0,75 untuk menjaga keseimbangan antara *precision* dan *recall* dalam aplikasi lapangan.

Kurva per kelas menunjukkan bahwa Grade A lebih stabil pada berbagai *threshold confidence* dibandingkan Grade B, konsisten dengan temuan sebelumnya bahwa karakteristik visual Grade A lebih mudah dipelajari model.

Gambar 13 menunjukkan dokumentasi proses penyortiran tomat secara manual yang dilakukan petani di lokasi pascapanen. Terlihat petugas melakukan penyortiran satu per satu dengan menempatkan tomat yang sudah dipilah ke dalam keranjang sesuai *grade* masing-masing. Proses ini bergantung pada penilaian visual subjektif yang dilakukan satu per satu, memerlukan waktu rata-rata 90 detik per wadah berisi 40 tomat. Metode manual ini rentan terhadap inkonsistensi karena faktor kelelahan, perbedaan interpretasi antara petugas, dan kondisi pencahayaan yang berubah-ubah.



Gambar 13. Proses Penyortiran Tomat Secara Manual.

Sistem YOLOv8-L mampu memproses tomat 36 kali lebih cepat dibandingkan metode manual, dengan peningkatan efisiensi waktu sebesar 97,2%. *Throughput* sistem mencapai ± 960 tomat per menit, jauh melampaui kapasitas manual yang hanya ± 27 tomat per menit. Konsistensi sistem juga unggul karena tidak dipengaruhi faktor manusia seperti kelelahan atau bias subjektif. Perbandingan efisiensi penyortiran manual dan sistem YOLOv8-L berdasarkan waktu pemrosesan, konsistensi, skalabilitas, *throughput*, dan ketergantungan terhadap sumber daya manusia disajikan pada Tabel 4.

TABEL 4
PERBANDINGAN EFISIENSI PENYORTIRAN MANUAL DAN YOLOv8-L.

Aspek	Manual	YOLOv8-L
Waktu per wadah (40 tomat)	± 90 detik	$\pm 2,5$ detik
Konsistensi	Subjektif, bervariasi antar petugas	Objektif, <i>confidence score</i> stabil
Skalabilitas	Terbatas tenaga manusia	Otomatisasi penuh
<i>Throughput</i>	± 27 tomat/menit	± 960 tomat/menit
Ketergantungan SDM	Tinggi (kelelahan, bias)	Rendah (hanya setup awal)


Perhitungan efisiensi waktu dapat dinyatakan sebagai:

$$\text{Peningkatan Efisiensi Waktu} = \left(1 - \frac{2,5}{90} \times 100\%\right) = 97,2\% \quad (6)$$

$$\text{Speed up Factor} = \frac{90}{2,5} = 36 \text{ Kali lebih cepat} \quad (7)$$

Namun, perlu dicatat bahwa estimasi waktu 2,5 detik per wadah hanya mencakup proses inferensi model dan belum termasuk waktu akuisisi citra otomatis serta mekanisme sortir fisik (misalnya, sistem konveyor). Implementasi sistem penuh memerlukan integrasi perangkat keras tambahan yang dapat menambah latensi operasional, namun tetap jauh lebih efisien dibandingkan metode manual.

Gambar 14 menunjukkan hasil inferensi model pada data uji lapangan nyata. Pada gambar terlihat dua buah tomat dengan *bounding box* dan label prediksi yang dihasilkan model. Tomat atas diprediksi sebagai Grade B dengan *confidence* 0,83, sementara tomat bawah diprediksi sebagai Grade A dengan *confidence* 0,92. *Bounding box* yang dihasilkan mengikuti kontur objek dengan presisi tinggi, menunjukkan efektivitas anotasi *polygon* yang dilakukan pada tahap persiapan data.



Gambar 14. Contoh Hasil Inferensi Deteksi *Grade* Tomat.

Hasil inferensi menunjukkan bahwa model mampu membedakan *grade* berdasarkan karakteristik visual yang konsisten dengan definisi operasional, memberikan *confidence score* yang tinggi ($>0,80$) untuk prediksi yang akurat, dan menghasilkan *bouding box* yang mengikuti kontur objek dengan presisi. Visualisasi ini mengkonfirmasi bahwa model telah belajar pola diskriminatif yang relevan untuk klasifikasi *grade* tomat dalam kondisi lapangan yang kompleks.

Hasil penelitian menunjukkan bahwa sistem klasifikasi berbasis YOLOv8-L mampu mencapai performa yang sangat baik ($mAP@0,5$ 97,5%, $mAP@0,5:0,95$ 95,3%) pada data tomat lokal dengan kondisi pencahayaan alami dan latar belakang kompleks. Hal ini mengkonfirmasi bahwa algoritma *deep learning* modern dapat diadaptasi secara efektif untuk tugas klasifikasi spesifik pada konteks pertanian skala kecil.

Keunggulan performa Grade A dibandingkan Grade B (mAP 0,987 vs 0,963) mencerminkan karakteristik visual yang lebih konsisten pada Grade A, berupa warna yang merata dan bentuk yang proporsional. Sementara itu, variabilitas visual pada Grade B (warna tidak merata, bentuk irregular) memerlukan representasi fitur yang lebih kompleks, namun model tetap mencapai performa sangat baik ($mAP>0,96$). Temuan ini menunjukkan bahwa definisi operasional *grade* yang jelas dan konsistensi anotasi data merupakan faktor kritis dalam keberhasilan *training* model deteksi objek.

Peningkatan efisiensi waktu sebesar 97,2% (dari 90 detik menjadi 2,5 detik untuk 40 tomat) menunjukkan potensi signifikan sistem dalam mendukung optimalisasi rantai nilai pascapanen. Namun, implementasi operasional penuh memerlukan integrasi dengan mekanisme akuisisi citra otomatis dan sistem penyortiran fisik, yang merupakan topik untuk penelitian lanjutan.

Tingkat kesalahan yang relatif rendah pada misklasifikasi antar *grade* (8-9%) menunjukkan bahwa sistem dapat digunakan sebagai alat bantu yang andal dalam penyortiran, dengan potensi untuk mengurangi variabilitas subjektif yang inherent pada metode manual. Akan tetapi, tingkat kesalahan pada kelas *background* (40%) mengindikasikan perlu untuk meningkatkan *robustness* model terhadap latar belakang kompleks atau menerapkan *preprocessing* yang lebih canggih pada tahap akuisisi citra. Untuk meminimalkan kesalahan klasifikasi pada kelas *background*, pengembangan penelitian selanjutnya dapat dilakukan dengan menambahkan *empty images* ke dalam *dataset* agar model lebih terlatih dalam mengenali area latar tanpa objek tomat. Selain itu, penerapan teknik *preprocessing* seperti filter warna, peningkatan kontras, dan normalisasi pencahayaan berpotensi meningkatkan kemampuan model dalam memisahkan objek tomat dari latar belakang kompleks. Pendekatan tersebut diharapkan dapat memperkuat *robustness* model serta menurunkan *false positive* pada proses inferensi di lingkungan lapangan.

IV. SIMPULAN

Penelitian ini telah berhasil mengembangkan dan mengevaluasi sistem klasifikasi *grade* tomat berbasis YOLOv8-L untuk mengoptimalkan pemilahan hasil panen di tingkat petani. Hasil evaluasi menunjukkan bahwa model mencapai performa yang sangat baik dengan $mAP@0,5$ sebesar 97,5%, $mAP@0,5:0,95$ sebesar 95,3%, *precision* 93,3%, dan *recall* 91,6%. Sistem mampu memproses sekitar 40 tomat dalam waktu $\pm 2,5$ detik per wadah, meningkatkan efisiensi pemilahan hingga $\pm 97,2\%$ dibandingkan metode manual yang memerlukan sekitar 90 detik. Kecepatan inferensi mencapai $\pm 15,9$ FPS pada GPU Tesla T4, menunjukkan kemampuan sistem untuk beroperasi secara *real-time* dalam skenario lapangan. Performa Grade A (mAP 0,987) lebih tinggi dibandingkan Grade B (mAP 0,963), mencerminkan konsistensi visual yang lebih mudah dipelajari pada karakteristik warna merata, permukaan mengkilap, dan bentuk proporsional pada Grade A. Analisis *confusion matrix* menunjukkan tingkat misklasifikasi antar *grade* yang relatif rendah (8-9%), mengindikasikan reliabilitas sistem sebagai alat bantu penyortiran. Tingkat kesalahan pada kelas *background* (40%) menunjukkan masih ada ruang untuk peningkatan dalam *robustness* model terhadap latar belakang kompleks yang khas di lingkungan lapangan. Penelitian ini mengkonfirmasi bahwa

algoritma *deep learning* modern dapat diadaptasi secara efektif untuk tugas klasifikasi spesifik dalam konteks pertanian lokal Indonesia dengan kondisi pencahayaan alami dan latar kompleks. Pemanfaatan *dataset* lokal dengan definisi operasional *grade* yang jelas dan konsistensi anotasi data menggunakan *polygon tool* pada Roboflow telah terbukti menjadi faktor kritis dalam kesuksesan *training* model. *Pipeline* YOLOv8-L yang disesuaikan dengan karakteristik data lokal, meliputi konfigurasi parameter pelatihan (*AdamW optimizer*, *cosine annealing learning rate*, augmentasi Mosaic, AutoAugment, dan penyesuaian HSV), telah menghasilkan model yang mampu generalisasi dengan baik pada kondisi lapangan yang beragam. Kontribusi utama penelitian ini adalah penyediaan sistem berbasis *deep learning* yang praktis dan andal untuk mendukung *precision agriculture* di sektor pertanian tomat Indonesia, khususnya dalam mengoptimalkan penyortiran hasil panen di tingkat petani skala kecil hingga menengah.

Penelitian lanjutan perlu fokus pada tiga aspek pengembangan. Pertama, integrasi sistem dengan mekanisme akuisisi citra otomatis dan perangkat hardware penyortir fisik seperti *conveyor sorting system* untuk menciptakan solusi *end-to-end* yang *fully automated*. Kedua, ekspansi domain aplikasi ke varietas tomat lain dan komoditas hortikultura serupa seperti jeruk, apel, mangga untuk mendemonstrasikan skalabilitas pendekatan ini. Ketiga, peningkatan *robustness* model terhadap variasi latar belakang dan kondisi pencahayaan ekstrim melalui teknik *domain adaptation*, *transfer learning* dari model yang dilatih pada *dataset* yang lebih besar, atau penerapan *preprocessing* yang lebih canggih pada tahap akuisisi citra. Dengan realisasi pengembangan lanjutan tersebut, sistem klasifikasi berbasis YOLOv8 memiliki potensi signifikan untuk meningkatkan efisiensi, konsistensi, dan skalabilitas dalam rantai pascapanen pertanian Indonesia.

DAFTAR PUSTAKA

- [1] A. Subu, Y. Y. Da Rato, and S. Noni, "Analisis Faktor-Faktor Yang Mempengaruhi Perilaku Konsumen Dalam Keputusan Pembelian Produk Holtikultura di Kebun Praktek Universitas Nusa Nipa," *J. Ilm. Wahana Pendidikan, Februari*, vol. 2023, no. 3, pp. 651–660, 2023, [Online]. Available: <https://doi.org/10.5281/zenodo.7692384>
- [2] N. Hayati, R. I. Mahendra, K. T. Putra, E. Prasetyo, and C. K. Setiawan, "Developing an Automatic Tomato Ripeness Sorting Prototype to Enhance Post Harvest Efficiency," in *IOP Conference Series: Earth and Environmental Science*, Institute of Physics, 2024.
- [3] G. Firgiawan, N. L. Seina, and P. Rosyani, "Implementasi Metode You Only Look Once (YOLO) untuk Pendeteksi Objek dengan Tools OpenCV," 2024. [Online]. Available: <https://jurnalmahasiswa.com/index.php/aidanspk>
- [4] Yanto, F. Aziz, and Irmawati, "YOLO-V8 Peningkatan Algoritma untuk Deteksi Pemakaian Masker Wajah," *J. JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 3, pp. 1437–1444, 2023.
- [5] 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.
- [6] B. Xiao, M. Nguyen, and W. Q. Yan, "Fruit ripeness identification using YOLOv8 model," *Multimed. Tools Appl.*, vol. 83, no. 9, pp. 28039–28056, 2024.
- [7] H. Li, X. Wang, Y. Bu, C. C. David, and X. Chen, "YOLOv8-Orah: An Improved Model for Postharvest Orah Mandarin (*Citrus reticulata* cv. Orah) Surface Defect Detection," *Agronomy*, vol. 15, no. 4, 2025.
- [8] G. Liu, J. C. Nouaze, P. L. T. Mbouembe, and J. H. Kim, "YOLO-tomato: A robust algorithm for tomato detection based on YOLOv3," *Sensors (Switzerland)*, vol. 20, no. 7, 2020.
- [9] M. Nahiduzzaman *et al.*, "Deep learning-based real-time detection and classification of tomato ripeness stages using YOLOv8 on raspberry Pi," *Eng. Res. Express*, vol. 7, no. 1, 2025.
- [10] L. Da Quach, K. N. Quoc, A. N. Quynh, H. T. Ngoc, and N. Thai-Nghe, "Tomato Health Monitoring System: Tomato Classification, Detection, and Counting System Based on YOLOv8 Model With Explainable MobileNet Models Using Grad-CAM++," *IEEE Access*, vol. 12, pp. 9719–9737, 2024.
- [11] X. Liang *et al.*, "ASE-YOLOv8n: A Method for Cherry Tomato Ripening Detection," *Agronomy*, vol. 15, no. 5, 2025.
- [12] T. M. P. Dao, N. K. Nguyen, and V. K. Nguyen, "CNN-YOLOv8-Based Tomato Quality Inspection System-A Case Study in Vietnam," *SSRG Int. J. Electr. Electron. Eng.*, vol. 10, no. 7, pp. 31–40, 2023.
- [13] V. Moya, M. Guerra, K. Pazmiño, F. Abedrabbo, F. A. Chicaiza, and D. Pozo-Espin, "Tomato classification with YOLOv8: Enhancing automated sorting and quality assessment," *Smart Agric. Technol.*, vol. 12, 2025.
- [14] Y. Huang *et al.*, "Overview of Deep Learning and Nondestructive Detection Technology for Quality Assessment of Tomatoes," *Foods*, vol. 14, no. 2, p. 286, 2025.
- [15] P. Li, J. Zheng, P. Li, H. Long, M. Li, and L. Gao, "Tomato Maturity Detection and Counting Model Based on MHSA-YOLOv8," *Sensors*, vol. 23, no. 15, 2023.
- [16] S. M. Saranya, R. R. Rajalaxmi, R. Prabavathi, T. Suganya, S. Mohanapriya, and T. Tamilselvi, "Deep Learning Techniques in Tomato Plant - A Review," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, 2021.
- [17] H.-T. Vo, K. C. Mui, N. N. Thien, and P. P. Tien, "Automating Tomato Ripeness Classification and Counting with YOLOv9," 2024. [Online]. Available: www.ijacsa.thesai.org
- [18] Z. Fan, Y. Wu, W. Liu, M. Chen, and Z. Qiu, "LG-YOLOv8: A Lightweight Safety Helmet Detection Algorithm Combined with Feature Enhancement," *Appl. Sci.*, vol. 14, no. 22, 2024.
- [19] Ultralytics, "YOLOv5 vs. YOLOv8 Comparison." [Online]. Available: <https://docs.ultralytics.com/compare/yolov5-vs-yolov8/>
- [20] Ultralytics, "YOLOv8 vs. YOLOv7 Comparison." [Online]. Available: <https://docs.ultralytics.com/compare/yolov8-vs-yolov7/>