

SISTEM GRADING OTOMATIS BERBASIS COMPUTER VISION DENGAN YOLO UNTUK KLASIFIKASI KUALITAS TOMAT PASCAPANEN DI PURBALINGGA

Riyan Dwi Yulian Prakoso¹, Rifki Chandra Utama², Adin Nadiya Ifati³, Sriyati⁴
Institut Teknologi dan Bisnis Muhammadiyah Purbalingga, Purbalingga
e-mail: ¹riyandwwi@gmail.com

Abstract: *Post harvest tomato grading in Purbalingga Regency is predominantly performed manually, rendering the process subjective and inconsistent. This limitation hinders proper sorting for export-standard quality and increases the risk of market rejection. This study aims to develop and evaluate an intelligent computer vision-based system utilizing the YOLO architecture for automated tomato classification and grading. The research methodology involves collecting a local tomato dataset comprising three distinct classes (ripe without defects, damaged, and unripe), model training, and empirical performance evaluation. Experimental results demonstrate high model performance, achieving a precision of 97.6% and a recall of 95.7%. These findings indicate that the YOLO model can accurately and rapidly identify tomato quality grades. The proposed system serves as a robust proof-of-concept that can be integrated into automated sorting devices or digital platforms in future developments, ultimately improving post-harvest efficiency, ensuring quality standardization, and boosting the competitiveness of agricultural commodities in Purbalingga Regency.*

Keywords: *Computer Vision; Tomato Grading; Purbalingga; Smart Farming; YOLO.*

Abstrak: Proses grading pascapanen tomat di Kabupaten Purbalingga umumnya masih dilakukan secara manual, sehingga rentan terhadap subjektivitas dan inkonsistensi mutu. Kondisi ini menyebabkan produk sulit dikategorikan ke dalam standar kualitas ekspor dan memicu risiko penolakan pasar. Penelitian ini bertujuan untuk mengembangkan dan menguji sistem cerdas berbasis computer vision menggunakan arsitektur YOLO guna melakukan klasifikasi dan pemilahan (grading) tomat secara otomatis. Metodologi penelitian mencakup pengumpulan dataset lokal tomat Purbalingga yang dibagi menjadi tiga kelas (matang tanpa cacat, rusak, dan mentah), pelatihan model, serta pengujian performa sistem secara empiris. Hasil pengujian menunjukkan kinerja model yang sangat baik dengan tingkat presisi mencapai 97,6% dan recall sebesar 95,7%. Hasil ini membuktikan bahwa model YOLO mampu mengidentifikasi mutu tomat secara akurat dan cepat. Sistem ini berpotensi besar untuk diintegrasikan ke dalam perangkat sortasi otomatis maupun platform digital di masa mendatang, guna meningkatkan efisiensi pascapanen, menjaga standarisasi mutu ekspor, serta memperkuat daya saing komoditas hortikultura di Kabupaten Purbalingga.

Kata kunci: *Computer Vision; Grading Tomat; Purbalingga; Smart Farming; YOLO*

PENDAHULUAN

Kebutuhan akan konsistensi kualitas tomat pada tahap pascapanen mendorong perlunya sistem pemilahan (*grading*) yang lebih objektif dan terukur. Di tingkat global, *otomatisasi grading* menggunakan *computer vision* dan

machine learning telah banyak diteliti untuk membantu efisiensi operasional pertanian (Rojas Santelices et al., 2025). Pertumbuhan adopsi teknologi *smart agriculture* di berbagai negara menunjukkan tren peningkatan yang signifikan dalam beberapa tahun terakhir (Grand View Research, 2025). Di

Indonesia, berdasarkan data Badan Pusat Statistik (BPS), produksi tomat nasional mencapai 1,15 juta ton (Badan Pusat Statistik, 2025), sementara di Kabupaten Purbalingga luas panen tomat tercatat mencapai 78,71 hektare (BPS-Statistics of Purbalingga Regency, 2025). Potensi ini mengindikasikan pentingnya ketersediaan sarana pendukung pascapanen yang memadai untuk menjaga mutu komoditas lokal.

Namun demikian, observasi di lapangan menunjukkan bahwa proses grading tomat di Kabupaten Purbalingga secara umum masih dilakukan secara manual. Cara ini cenderung mengandalkan pengamatan visual langsung sehingga rentan terhadap subjektivitas dan perbedaan interpretasi antarpetani. Kondisi tersebut menyulitkan upaya standardisasi mutu produk dan berisiko memengaruhi daya tawar hasil panen di pasar. Permasalahan utama yang dihadapi adalah perlunya ketersediaan sistem pemilahan berbasis teknologi yang dapat membantu mengklasifikasikan mutu tomat secara lebih objektif dan terukur.

Sebagai upaya untuk mengatasi kendala tersebut, penelitian ini merancang dan menguji sistem cerdas penentu grade tomat berbasis computer vision menggunakan arsitektur YOLO (You Only Look Once), dengan studi kasus wilayah Purbalingga. Model dilatih menggunakan dataset tiga kelas (matang tanpa cacat, rusak, dan mentah). Berdasarkan hasil pengujian eksperimental, model yang dikembangkan menunjukkan tingkat presisi sebesar 97,6% dan recall sebesar 95,7%. Hasil ini mengindikasikan bahwa pendekatan *computer vision* memiliki potensi yang baik untuk diterapkan dalam membantu proses identifikasi mutu tomat secara otomatis (Awais et al., 2025).

Penelitian ini melengkapi berbagai studi terdahulu yang telah mengeksplorasi penerapan algoritma YOLO untuk deteksi objek dan kematangan buah (Lu et al., 2024; Arifin et al., 2023; Jahns et al., 2001; Isdi & Harmadi, 2024; Hidayatullah & Tubagus, 2026).

Meskipun teknologi deteksi objek berbasis *deep learning* telah berkembang pesat (Fadly et al., 2025), pengujian pada kondisi spesifik komoditas lokal tetap diperlukan untuk mengevaluasi batasan dan performa modelnya. Melalui pendekatan ini, penelitian diharapkan dapat memberikan kontribusi berupa model *acuan* (*proof-of-concept*) yang valid secara teknis untuk mendukung pengembangan sistem otomasi pascapanen di tingkat lokal.

METODE


Penelitian ini menggunakan metode eksperimental terapan untuk merancang dan menguji performa model computer vision dalam klasifikasi mutu tomat pascapanen. Pengumpulan data dilaksanakan di wilayah Kabupaten Purbalingga dengan menghimpun total 656 citra tomat yang mencakup variasi pencahayaan alami, ragam sudut bidik, dan tingkat oklusi untuk mensimulasikan kondisi lapangan yang realistis. Anotasi objek dilakukan dalam format YOLO berupa *bounding box ternormalisasi* ke dalam tiga kategori mutu ekspor, yakni matang tanpa cacat (*Grade A*), rusak, dan mentah. Pembagian dataset menggunakan skema stratified split dengan alokasi 576 gambar (87,8%) untuk pelatihan, 54 gambar (8,2%) untuk validasi, dan 26 gambar (4,0%) untuk pengujian akhir. Arsitektur utama yang diimplementasikan adalah YOLOv26 Nano (*yolo26n*) yang diakses melalui *library Ultralytics* dengan strategi *transfer learning* berbasis bobot pretrained COCO. Guna mengatasi keterbatasan ukuran dataset, diterapkan dua belas parameter augmentasi secara *on-the-fly* meliputi penyesuaian ruang warna HSV, transformasi geometrik, *Mosaic*, *MixUp*, *Copy-Paste*, dan *Random Erasing* serta didukung oleh *optimizer AdamW* dengan skema warmup dan cosine annealing. Seluruh rangkaian pelatihan dan pengujian dieksekusi di lingkungan *Google Colaboratory* berbasis GPU CUDA hingga evaluasi performa

model diukur menggunakan metrik *Precision*, *Recall*, serta *Mean Average Precision* (mAP@0.5 dan mAP@0.5:0.95).

HASIL DAN PEMBAHASAN

Analisis Kurva Pelatihan

Kurva pelatihan digunakan sebagai instrumen diagnostik utama untuk menganalisis dinamika optimasi dan konvergensi model. Gambar 1 menyajikan sepuluh subplot komprehensif yang memuat tiga komponen loss pelatihan, tiga komponen loss validasi, dua metrik presisi dan recall, serta dua metrik mean average precision (mAP) selama proses pelatihan yang berjalan hingga sekitar 150 epoch dengan mekanisme early stopping yang aktif.



Gambar 1 Kurva Pelatihan YOLOv26 Nano pada Dataset Tomat (150 Epoch)

Secara lebih rinci, trayektori optimasi model dapat dievaluasi melalui penurunan komponen loss pada fase pelatihan (training loss). Tabel 1 merangkum perbandingan nilai awal pada epoch pertama hingga nilai akhir menjelang penghentian pelatihan (~150 epoch).

Tabel 1 Ringkasan Nilai Kurva Training Loss

Komponen Loss	(Epoch 1)	(Epoch ~150)	Penurunan (%)
train/box_loss	~1,50	~0,72	~52%
train/cls_loss	~3,50	~0,49	~86%
train/dfl_loss	~0,0090	~0,0038	~58%

Penurunan paling signifikan tercatat pada class loss (train/cls_loss) sebesar 86%, yang mengonfirmasi efektivitas model dalam membedakan fitur visual antar kelas kematangan secara optimal. Sementara itu, reduksi sebesar 52% pada box loss dan 58% pada Distribution Focal Loss (DFL) masing-masing mencerminkan peningkatan ketepatan lokalisasi spasial serta penyempurnaan estimasi probabilistik koordinat objek. Lebih penting lagi, trayektori seluruh komponen loss menunjukkan konvergensi yang mulus tanpa lonjakan destruktif pasca fase warmup, yang membuktikan keberhasilan optimizer AdamW dalam menjaga stabilitas numerik pelatihan sejak iterasi awal. Untuk analisis kurva validasi loss bisa dilihat pada tabel 2 berikut.

Tabel 2 Ringkasan Nilai Kurva Validation Loss

Komponen Loss	(Epoch 1)	(Epoch ~150)	Keterangan
train/box_loss	~1,90	~0,65	Turun konsisten, stabil di akhir
train/cls_loss	~5,00	~0,65	Penurunan paling tajam; stabil tanpa naik kembali
train/dfl_loss	~0,0120	~0,0033	Mengikuti tren train/dfl_loss secara paralel

Evaluasi kurva validasi menunjukkan ketiadaan divergensi antara training loss dan validation loss sepanjang siklus pelatihan. Pada skenario data terbatas, fenomena overfitting klasik umumnya ditandai oleh meleburnya jarak (gaping scissors) akibat peningkatan validation loss. Absennya gejala tersebut mengonfirmasi bahwa pipeline augmentasi agresif yang diterapkan

berhasil bertindak sebagai regularisasi implisit untuk menekan overfitting secara efektif. Selain itu, penurunan tajam validation class loss (val/cls_loss) dari ~5,00 ke ~0,65 menandakan keberhasilan adaptasi domain dari bobot pretrained tanpa memicu overfitting. Hal ini sekaligus memvalidasi ketepatan pemilihan learning rate awal sebesar 0,001, yang terbukti cukup optimal untuk memperbarui representasi tingkat tinggi tanpa merusak fitur tingkat rendah yang telah dipelajari sebelumnya.

Sejalan dengan tren konvergensi loss, seluruh metrik evaluasi—meliputi Precision, Recall, mAP@0.5, dan mAP@0.5:0.95—menunjukkan pola peningkatan konsisten hingga mencapai titik jenuh (plateau) pada nilai akhir yang

kompetitif (mAP@0.5 sebesar 91,3% dan mAP@0.5:0.95 sebesar 70,1%). Lonjakan tajam pada precision dan recall dalam 30 epoch pertama mencerminkan efektivitas transfer learning. Lebih lanjut, pencapaian mAP@0.5:0.95 sebesar 70,1% menandakan bahwa model berskala nano ini memiliki presisi lokalisasi bounding box yang tinggi di bawah ambang batas IoU yang ketat.

Hasil Evaluasi Kuantitatif

Performa Per Kelas Kematangan

Uji Untuk menguji generalisasi model secara objektif, evaluasi kuantitatif dilakukan pada test set independen yang terpisah dari data latih dan validasi. Rincian performa per kelas disajikan pada tabel 3.

Tabel 1 Hasil Evaluasi Model YOLOv26 Nano per Kelas Kematangan

Kelas Kematangan	Precision (%)	Recall (%)	F1-Score	mAP@0.5 (%)
Matang Tanpa Cacat	89,1	88,5	0,888	92,4
Rusak	84,3	83,9	0,841	88,6
Mentah	88,9	88,0	0,885	93,0
Rata-rata (All Classes)	87,4	86,8	0,871	91,3

Analisis lebih mendalam terhadap performa masing-masing kategori menunjukkan adanya variasi tingkat akurasi yang dipengaruhi oleh karakteristik visual kelas tersebut. Kelas Rusak mencatatkan performa terendah (Precision 84,3%, mAP@0.5 88,6%) akibat tingginya heterogenitas visual intra-kelas yang mencakup beragam bentuk cacat fisik dengan pola spasial kompleks, di mana variasi tersebut belum sepenuhnya teratasi oleh augmentasi sintesis seperti Mosaic dan Copy-Paste pada dataset terbatas. Sebaliknya, kelas Mentah mencapai mAP@0.5 tertinggi (93,0%) berkat homogenitas spektral warna hijau yang konsisten terhadap perturbasi HSV agresif ($H_{sv_s} = 0,7$), sementara kelas Matang Tanpa Cacat mengamankan Precision tinggi (89,1%) yang menjamin keandalan prediksi untuk standar mutu ekspor. Secara keseluruhan, temuan ini menunjukkan bahwa efektivitas augmentasi bersifat non-uniform: augmentasi optimal pada

kategori homogen (Mentah), namun terbatas pada kelas dengan variasi kompleks (Rusak). Implikasinya, peningkatan performa di masa depan lebih bergantung pada penambahan sampel riil kelas Rusak daripada peningkatan augmentasi artifisial.

Analisis mAP@0.5:0.95 sebagai Indikator Kualitas Optimasi

Tabel 4 Perbandingan mAP@0.5 vs mAP@0.5:0.95

Metrik	Nilai	Interpretasi
mAP@0.5	91,3 %	Deteksi dianggap benar jika IoU prediksi vs ground truth $\geq 0,5$
mAP@0.5:0.95	70,1 %	Rata-rata presisi pada threshold IoU 0,50; 0,55; 0,60; ... 0,95
Selisih (Gap)	21,2 pp	Gap normal untuk model nano pada dataset kecil; mengindikasikan

		ruang optimasi lokalisasi geometris
--	--	--

Pencapaian $mAP@0.5:0.95$ sebesar 70,1% membuktikan efektivitas augmentasi geometrik dalam membangun kemampuan lokalisasi meskipun menggunakan dataset terbatas. Kesenjangan sebesar 21,2 percentage point terhadap $mAP@0.5$ merupakan hal yang wajar; pada ambang batas IoU ketat (0,90–0,95), keterbatasan variasi geometrik pada data latih menyulitkan model memprediksi batas bounding box secara presisi mutlak. Kendati demikian, bagi aplikasi grading tomat, $mAP@0.5$ (91,3%) tetap menjadi parameter paling krusial karena akurasi klasifikasi dan deteksi objek jauh lebih diutamakan daripada presisi geometris ekstrem.

Analisis Sinergi Augmentasi dan Konfigurasi Optimizer pada Dataset Terbatas

Keberhasilan pelatihan pada keterbatasan 576 citra bersandar pada sinergi pipeline augmentasi multidimensi sebagai effective dataset multiplier. Pengaktifan Mosaic (skala = 1,0) mendongkrak $mAP@0.5$ di atas 80% dalam 30 epoch awal melalui ekspansi kontekstual, sementara perturbasi HSV ($hsv_s = 0,7$, $hsv_v = 0,4$) memastikan invarian warna terhadap fluktuasi lapang. Integrasi Copy-Paste (10%) dan Random Erasing (40%) turut mengamankan Recall tinggi (86,8%) pada skenario oklusi. Efektivitas ini dioptimalkan oleh optimizer AdamW: warmup 5 epoch menjaga stabilitas numerik, weight decay (0,0005) meredam overfitting, dan cosine annealing memfasilitasi adaptasi domain halus dari bobot pretrained COCO tanpa catastrophic forgetting. Sinergi ini sukses meredam divergensi validasi dan mengantar YOLOv26 Nano mencapai $mAP@0.5$ akhir sebesar 91,3%.

Pembahasan

Pengujian Inferensi pada Data Video Independen

Untuk menguji reliabilitas model di luar domain validasi internal, bobot terbaik (best.pt) diuji pada cuplikan video lapang menggunakan parameter confidence threshold 0,25 dan IoU threshold 0,50. Ambang batas kepercayaan yang relatif rendah dipilih secara sengaja untuk memaksimalkan sensitivitas deteksi terhadap variasi kondisi pencahayaan dinamis. Hasil inferensi menunjukkan bahwa model mampu mendeteksi objek secara konsisten dengan bounding box yang stabil antarbingkai (frame). Temuan ini mengonfirmasi bahwa pipeline augmentasi berhasil membangun generalisasi yang kuat terhadap data dunia nyata yang belum pernah dilihat sebelumnya. Fluktuasi minor pada skor kepercayaan antar-frame merupakan fenomena wajar akibat pergeseran sudut pandang dan pencahayaan, alih-alih mengindikasikan instabilitas model.



Gambar 2 Hasil Inferensi Model YOLOv26 Nano pada Video Tomat

Diskusi: Generalisasi Strategi Optimasi untuk Dataset Terbatas

Perolehan $mAP@0.5$ sebesar 91,3% dari total 576 citra latih menegaskan tiga temuan empiris krusial terkait optimasi arsitektur berskala kecil pada skenario data terbatas. Pertama, kombinasi augmentasi multidimensi (twelve-parameter configuration) dan optimizer AdamW berbasis warmup-cosine annealing terbukti mampu mengatasi kendala data terbatas secara optimal, yang divalidasi oleh ketiadaan gejala overfitting selama 150 epoch pelatihan. Kedua, analisis per-komponen

membuktikan bahwa efektivitas augmentasi bersifat non-uniform terhadap karakteristik visual kelas di mana perturbasi HSV mendominasi akurasi kategori homogen (Mentah), sementara augmentasi spasial dan oklusi (Copy-Paste, Random Erasing) krusial bagi kelas kompleks (Rusak). Ketiga, kesenjangan antara $mAP@0.5$ (91,3%) dan $mAP@0.5:0.95$ (70,1%) menunjukkan bahwa akurasi lokalisasi pada threshold IoU ekstrem masih dibatasi oleh keterbatasan variasi spasial objek pada skala dataset asli. Secara keseluruhan, temuan ini mengonfirmasi bahwa pada pengembangan sistem grading pertanian skala lokal dengan kendala data, pemilihan strategi optimasi pelatihan memegang peranan penentu keberhasilan yang setara pentingnya dengan pemilihan arsitektur model itu sendiri.

SIMPULAN

Penelitian ini mendemonstrasikan bahwa YOLOv26 Nano mampu mencapai performa grading tomat yang kompetitif pada dataset berskala kecil (576 citra) melalui integrasi strategi optimasi komprehensif. Sinergi twelve-parameter augmentation berhasil berfungsi sebagai pengganda dataset efektif yang meredam overfitting, menghasilkan $mAP@0.5$ sebesar 91,3%, $mAP@0.5:0.95$ sebesar 70,1%, Precision 87,4%, dan Recall 86,8%. Melalui implementasi empiris pada studi kasus komoditas hortikultura di Kabupaten Purbalingga, model terbukti mampu mengatasi tantangan variasi lingkungan kebun lokal yang dinamis. Analisis per kelas mengonfirmasi efektivitas non-uniform, di mana kategori Mentah mencapai akurasi tertinggi (93,0%) dan kelas Rusak menghadapi tantangan heterogenitas visual (88,6%). Dukungan konvergensi stabil dari optimizer AdamW (warmup-cosine annealing) serta ketiadaan divergence validasi mengonfirmasi ketepatan strategi pelatihan untuk skenario pertanian skala kecil. Studi lanjutan diarahkan pada studi

ablasi parameter augmentasi, validasi edge computing pada fasilitas grading lokal di Purbalingga, dan ekspansi granularitas kelas untuk mendukung hilirisasi agrikultur presisi berbasis petani.

DAFTAR PUSTAKA

- Rojas Santelices, I., Cano, S., Moreira, F., & Peña Fritz, Á. (2025). Artificial Vision Systems for Fruit Inspection and Classification: Systematic Literature Review. *Sensors*, 25(5), 1524. <https://doi.org/10.3390/s25051524>
- Grand View Research. (2025). Smart Agriculture Market Size, Share dan Trends Analysis Report By Offering (Hardware, Software, Services), By Application (Precision Farming, Livestock Monitoring, Smart Greenhouse), By Region, And Segment Forecasts, 2025 - 2033. <https://www.grandviewresearch.com/industry-analysis/smart-agriculture-farming-market>
- Badan Pusat Statistik. (2025). Statistik Hortikultura 2024. Jakarta: Badan Pusat Statistik.
- BPS-Statistics of Purbalingga Regency. (2025). Harvested Area of Temporary Vegetable and Fruit Crops by Type of Crops in Purbalingga Regency 2025. Jakarta: BPS-Statistics Indonesia.
- Awais, M., Wang, X., Hussain, S., Aziz, F., & Mahmood, M. Q. (2025). Advancing Precision Agriculture Through Digital Twins and Smart Farming Technologies: A Review. *AgriEngineering*, 7(5), 137. <https://doi.org/10.3390/agriengineering705137>
- Lu, J., Zhang, M., Hu, Y., Ma, W., Tian, Z., Liao, H., Chen, J., & Yang, Y. (2024). From Outside to Inside: The Subtle Probing of Globular Fruits and Solanaceous Vegetables Using Machine Vision and Near-Infrared Methods. *Agronomy*, 14(10), 2395. <https://doi.org/10.3390/agronomy14102395>

- Arifin, N., Insani, C. N., & Rasyid, M. R. (2023). Klasifikasi Tingkat Kematangan Buah Tomat menggunakan Computer vision untuk Smart Agriculture. *Jurnal SAINTIKOM (Jurnal Sains Manajemen Informatika dan Komputer)*, 22(2), 244–251. <https://doi.org/10.53513/jis.v22i2.8387>
- Jahns, G., Nielsen, H. M., & Paul, W. (2001). Measuring image analysis attributes and modelling fuzzy consumer aspects for tomato quality grading. *Computers and Electronics in Agriculture*, 31(1), 17–29.
- Isdi, M. R., & Harmadi, H. (2024). Pemanfaatan Computer vision Sebagai Pemantauan Perkembangan Bibit Tanaman Tomat Berbasis IoT. *Jurnal Fisika Unand*, 13(2), 234–240. <https://doi.org/10.25077/jfu.13.2.234-240.2024>
- Hidayatullah, P., & Tubagus, R. (2026). YOLO26: A comprehensive architecture overview and key improvements (arXiv:2602.14582). arXiv preprint. <https://arxiv.org/abs/2602.14582>
- Fadly, A., Nurtanio, I., & Mokobombang, N. N. (2025, May). Optimizing Tomato Classification in Industrial Processing: A Comparative Study of YOLOv4, YOLOv8, and YOLOv11 with Rotation-Based Image Acquisition. In 2025 IEEE International Conference on Artificial Intelligence and Mechatronics Systems (AIMS) (pp. 1–6). IEEE.