

DETEKSI KEMATANGAN TOMAT MENGGUNAKAN ALGORITMA DETEKSI OBJEK (YOLO) 11

Lutfi Alfian^{1*}, Irving Vitra Paputungan²

^{1,2}Universitas Islam Indonesia, Indonesia

*Corresponding author: lutfialfian@students.uii.ac.id

Abstract: Manual tomato sorting in Indonesia inhibits the efficiency of agricultural supply chain due to its subjectivity and time-consuming process, thus demanding technological innovation to minimize post-harvest losses. This research developed a tomato ripeness detection system with three categories: unripe, half-ripe, and ripe, using (YOLO) 11. YOLO11 uses an architecture and training methods that have been improved from previous versions, thereby enhancing feature extraction for more precise object detection and better performance. The dataset consisting of 1088 images, was labeled using Roboflow and augmented to 2610 images, subsequently four YOLO11 variants (n, s, m, and l) were trained using the Google Colab platform. Model training was conducted with 100 epochs, resulting in high detection performance on the YOLO11m variant with the highest mAP50 value of 89.1%, a precision of 85.9%, and a recall of 84.1%. This model was successfully tested on new images and achieved an inference speed of 16 fps on real-time video input. The results of this research are expected to be a solution for increasing efficiency in the tomato sorting process, while also opening opportunities for the application of systems using YOLO based systems to other agricultural commodities.

Keywords: Fruit Ripeness Detection, Deep Learning, YOLO11

Abstrak: Penyortiran manual buah tomat di Indonesia menjadi salah satu penghambat efisiensi rantai pasok pertanian akibat subjektivitas dan proses yang memakan waktu, sehingga menuntut inovasi teknologi untuk meminimalkan kerugian pascapanen. Penelitian ini mengembangkan sistem deteksi tingkat kematangan tomat dengan tiga kategori, yaitu mentah, setengah matang dan matang menggunakan (YOLO) 11. YOLO11 menggunakan arsitektur dan metode pelatihan yang telah disempurnakan dari versi sebelumnya, sehingga dapat meningkatkan ekstraksi fitur untuk deteksi objek yang lebih presisi dan kinerja yang lebih baik. Dataset terdiri dari 1088 citra, di labeli menggunakan Roboflow dan augmentasi menjadi 2610 citra, serta pelatihan empat varian YOLO11 (n, s, m, dan l) menggunakan platform Google Colab. Pelatihan model dilakukan dengan 100 epoch, menghasilkan kinerja deteksi yang tinggi pada varian YOLO11m dengan nilai mAP50 tertinggi sebesar 89.1%, precision 85.9% dan recall 84.1%. Model ini berhasil diuji pada citra baru dan mencapai kecepatan inferensi 16 fps pada input video real-time. Hasil penelitian ini diharapkan dapat menjadi solusi untuk meningkatkan efisiensi pada proses penyortiran tomat, sekaligus membuka peluang untuk penerapan sistem menggunakan YOLO pada komoditas pertanian lainnya.

Kata kunci: Deteksi Kematangan Buah, Deep Learning, YOLO11

Copyright (c) 2025 The Authors. This is an open-access article under the CC BY-SA 4.0 license (<https://creativecommons.org/licenses/by-sa/4.0/>)

PENDAHULUAN

Tomat (*Solanum lycopersicum*) merupakan salah satu tanaman buah yang penting dan paling populer di dunia (Hu et al., 2019). Tomat kaya akan nutrisi penting yang

mencakup karbohidrat, protein, dan lipid serta beragam mineral seperti kalsium, magnesium, kalium, vitamin A dan C (Salehi et al., 2019). Data statistik menunjukkan pada tahun 2023 diperkirakan sebanyak 192 juta ton tomat telah diproduksi di dunia (FAO, 2024).

Sebagai salah satu negara agraris, Indonesia masih mengandalkan sektor pertanian yang memiliki peran penting dalam memajukan perekonomian negara (Anwar et al., 2022). Sektor pertanian memiliki kontribusi terbesar kedua terhadap PDB pada triwulan II-2024 (Badan Pusat Statistik, 2024b). Namun, kondisi ini tidak sejalan dengan keadaan beberapa tanaman hortikultura seperti tomat yang mengalami penurunan sebesar 2.14% pada tahun 2023 (Badan Pusat Statistik, 2024a). Penurunan ini sangat kontras dengan tingkat konsumsi tomat di tingkat rumah tangga yang terus meningkat, sehingga menciptakan kesenjangan antara pasokan dan permintaan di pasar. Salah satu tantangan yang berkontribusi pada masalah ini terletak pada proses pascapanen, khususnya dalam kegiatan penyortiran.

Penyortiran merupakan kegiatan dalam proses produksi dan distribusi di sektor pertanian maupun industri berdasarkan kategori tertentu seperti warna, suhu, bentuk dan bau (Yanti et al., 2024). Akan tetapi, metode yang digunakan saat ini masih bersifat tradisional yang masih mengandalkan keahlian visual individu untuk memilah setiap tomat secara manual. Pendekatan ini memiliki kelemahan di antaranya membutuhkan waktu yang lama dan jumlah tenaga kerja yang besar. Ketergantungan pada tenaga manusia membuat proses ini tidak efisien dan berbiaya tinggi, terutama saat menangani volume produksi skala besar. Kinerja penyortiran juga dapat dipengaruhi oleh faktor subjektif seperti kelelahan dan perbedaan penilaian antar pekerja yang menurunkan konsistensi. Inefisiensi inilah yang menjadi salah satu hambatan dalam upaya meningkatkan produktivitas dan memenuhi permintaan pasar yang terus meningkat (Mputu et al., 2024).

Perkembangan teknologi *deep learning* telah mendorong penerapannya dalam deteksi objek untuk pertanian digital, khususnya pada deteksi buah. Implementasi ini merupakan komponen penting untuk meningkatkan produktivitas dan hasil produksi pertanian (Badgajar et al., 2024). Di antara berbagai metode, *You Only Look Once* (YOLO) lebih banyak dipilih karena efisiensi dan kesesuaiannya untuk lingkungan pertanian yang kompleks dengan arsitektur berbasis Jaringan Saraf Konvolusional


(Hatami et al., 2023). YOLO mampu mengakomodasi pengambilan keputusan yang cepat dan tepat dalam kondisi lapangan yang dinamis. Selain itu, ukuran model yang relatif kecil dengan jumlah parameter yang lebih sedikit menjadikannya ideal untuk diimplementasikan pada perangkat berdaya komputasi terbatas, seperti *mobile devices* dan *embedded systems* yang umum digunakan dalam aplikasi pertanian (Zhao et al., 2024).

Beberapa penelitian terdahulu telah menguji potensi penerapan YOLO untuk deteksi dan klasifikasi buah. Penelitian oleh Wibowo et al. (2023) menggunakan YOLOv5 untuk deteksi buah segar dan busuk mendapatkan akurasi sebesar 0,84 atau 84%. Meskipun demikian, penelitian tersebut menyarankan perlunya penggunaan data set yang lebih beragam dan berkualitas untuk meningkatkan performa model karena akurasi sangat dipengaruhi oleh kualitas gambar dan sudut pengambilan objek. Selanjutnya, penelitian oleh (Muarofah et al., 2023) menggunakan YOLOv7 untuk deteksi kualitas tomat dan memperoleh hasil akurasi sebesar 90.6% pada gambar asli. Namun, penelitian tersebut mengungkapkan beberapa kelemahan seperti penurunan akurasi yang terjadi saat gambar mengalami distorsi blur dan potensi kurangnya ketahanan model pada kondisi latar belakang yang terlalu terang. Peneliti tersebut bahkan merekomendasikan penggunaan versi YOLO yang lebih baru untuk menyempurnakan kemampuan deteksi.

Menanggapi tantangan dan celah dari penelitian sebelumnya, penelitian ini bertujuan untuk mengembangkan model deteksi tingkat kematangan buah tomat dengan memanfaatkan *You Only Look Once* (YOLO) 11. Dipilihnya YOLO11 didasarkan pada potensinya untuk menawarkan peningkatan lebih lanjut dalam hal akurasi dan kecepatan deteksi dibandingkan dengan pendahulunya. Adanya penelitian ini, diharapkan dapat membantu meningkatkan efisiensi dan menurunkan biaya operasional serta dapat memberikan kontribusi terhadap pengembangan pertanian digital di Indonesia.

METODE

Penelitian ini menggunakan alur terstruktur yang berperan sebagai panduan untuk menyelesaikan permasalahan yang dihadapi. Rangkaian tahapan tersebut akan memandu proses penelitian secara sistematis sehingga memudahkan pencapaian tujuan penelitian. Secara umum, terdapat empat tahapan dalam kerangka penelitian ini, yaitu pengumpulan data, persiapan data, pelatihan model dan evaluasi. Keempat tahapan tersebut dapat diilustrasikan pada Gambar 1.



Gambar 1. Alur tahapan penelitian

You Only Look Once

YOLO (*You Only Look Once*) merupakan algoritma pendeteksi objek yang pertama kali diperkenalkan pada tahun 2015. Algoritma ini dikembangkan oleh Joseph Redmon dan Ali Farhadi (Yanto et al., 2023). Metode ini memanfaatkan satu jaringan konvolusional (*convolutional network*) untuk memprediksi objek apa saja yang ada pada citra. Hal ini dapat terjadi karena YOLO membagi citra menjadi beberapa sel atau *grid*. Setiap sel bertanggung jawab memprediksi jumlah *bounding box*, *confidence score* dan probabilitas kelas (Daniels et al., 2021).

Ultralytics mengembangkan varian lain, yaitu YOLO11. Versi tersebut menawarkan peningkatan akurasi dan efisiensi dibandingkan dari versi-versi sebelumnya. Arsitektur YOLO11 menggunakan pendekatan *single stage* detektor yang memungkinkan pemrosesan citra dalam satu *forward pass*. Pemrosesan menghasilkan prediksi lebih cepat dibandingkan dengan metode *two stage detector*. YOLO11 juga memberikan lima model dengan skala yang berbeda-beda mulai dari *nano* hingga *extra large* untuk memenuhi berbagai kebutuhan. Seperti YOLOv8, YOLO11 mencakup berbagai kegunaan seperti deteksi objek, segmentasi, klasifikasi, estimasi pose dan OBB.

Pengumpulan Data

Pada tahap ini dilakukan proses pengumpulan data set berupa data citra yang diperoleh dengan cara mencari data citra dengan kriteria gambar buah tomat yang tersedia di internet dan menggunakan platform Roboflow guna menambah data set agar lebih bervariasi. Total data set mencakup 1088 data citra tomat dengan berbagai tingkat kematangan tomat. Pada Gambar 2 dan Gambar 3 merupakan contoh data citra yang akan digunakan untuk deteksi objek pada penelitian ini.



Gambar 2. Gambar Tomat pada Dataset




Gambar 3. Kategori Kematangan Tomat

Persiapan Data

Tahap persiapan data (*Data Preparation*) merupakan fase penting dalam penelitian ini yang bertujuan untuk mengubah dan mempersiapkan data set citra buah tomat yang telah dikumpulkan menjadi data yang siap, terstruktur dan optimal untuk digunakan dalam proses pelatihan deteksi objek menggunakan YOLO11. Tahap ini meliputi dua langkah yang akan dilakukan yaitu *preprocessing* dan augmentasi data. Proses *preprocessing* yang dilakukan pada data citra meliputi beberapa langkah dengan memanfaatkan platform roboflow, yaitu Pelabelan dengan anotasi berupa *bounding box* pada objek, pembagian data set menjadi beberapa bagian, penggunaan *auto orient*, dan menyesuaikan resolusi citra (*resize*).


Proses pelabelan objek pada keseluruhan data set citra tomat dilakukan secara manual oleh peneliti menggunakan fitur anotasi yang tersedia pada platform Roboflow. Terdapat dua pedoman yang menjadi acuan utama dalam proses pelabelan yang dilakukan. Pedoman pertama menekankan pada identifikasi pada buah tomat yang tampak dalam masing-masing citra. Untuk setiap buah tomat yang terdeteksi, peneliti membuat sebuah anotasi berupa *bounding box* atau kotak pembatas seperti pada Gambar

4. Pemberian *bounding box* ini dilakukan dengan presisi untuk memastikan bahwa kotak tersebut akurat pada keseluruhan area visual dari buah tomat. Upaya ini bertujuan untuk meminimalisir area latar belakang yang tidak relevan atau bagian lain dari tanaman tomat seperti daun atau batang.



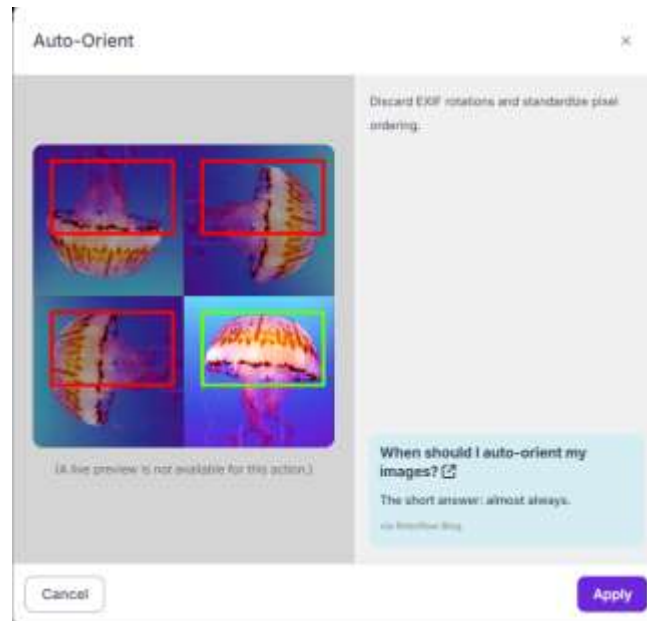
Gambar 4. Proses Pelabelan Objek

Tahapan selanjutnya, yaitu pembagian dataset yang dikelompokkan menjadi tiga subset berbeda, yaitu *train*, *valid* dan *test* yang dilakukan melalui platform Roboflow dengan perbandingan 70% *train* : 20% *valid* : 10% *test* pada masing-masing bagian seperti pada Gambar 5. Komposisi ini dirancang untuk menyeimbangkan kebutuhan pelatihan yang efektif, validasi untuk optimalisasi dan pencegahan *overfitting* serta evaluasi akhir untuk melihat kemampuan yang sebenarnya.



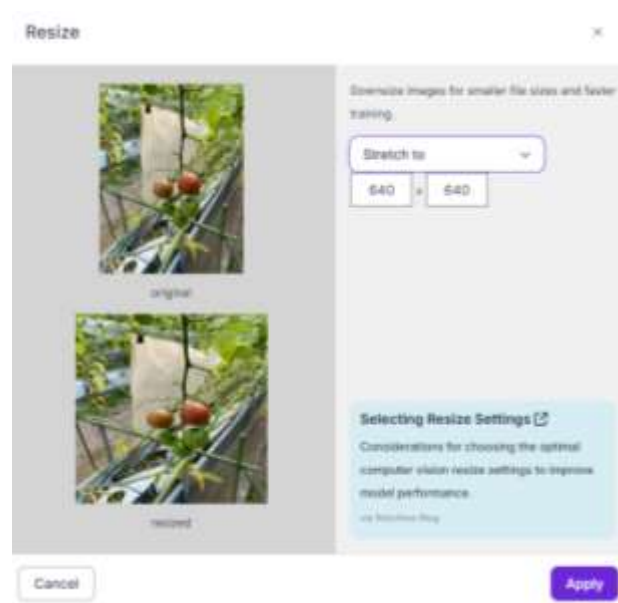
Gambar 5. Pembagian Dataset

Auto Orient digunakan untuk menangani perbedaan orientasi objek pada citra dalam data set penelitian. Fitur ini secara otomatis mengatur orientasi objek dalam data set, sehingga menciptakan konsistensi dan akurasi penempatan posisi objek.



Gambar 6. Penerapan *Auto-Orient*

Tahapan *resize* dilakukan untuk menyesuaikan ukuran resolusi menjadi 640×640 piksel menggunakan platform Roboflow. Perubahan ini bertujuan untuk menyeragamkan resolusi pada seluruh data citra yang telah dikumpulkan.



Gambar 7. Penyesuain Resolusi pada Citra (*Resize*)

Tahapan Augmentasi yang ditambahkan pada data citra setelah melakukan *preprocessing* berupa *Horizontal Flip*, *Rotation* antara -15° dan $+15^\circ$, *Shear* $\pm 15^\circ$ horizontal dan vertikal. Augmentasi ini bertujuan untuk meningkatkan variabilitas data set dan memperkuat model untuk dijalankan menghadapi variasi visual yang kompleks

secara real-time. Setelah dilakukan proses augmentation pada data set yang telah dikumpulkan, total dari data set yang akan digunakan untuk pelatihan menjadi 2610 data citra dengan penambahan data citra tanpa anotasi yang berguna untuk melatih model dalam mengenali apa yang bukan objek target seperti latar belakang. Perbandingan dataset menjadi 87% *train* : 8% *valid* : 4% *test* untuk masing-masing bagian. Penambahan data melalui augmentation hanya difokuskan pada subset *train*. Berdasarkan informasi pada platform Roboflow yang menyatakan bahwa augmentation pada subset *valid* dan *test* dapat membebani kinerja model.

Pelatihan Model

Tahapan ini memiliki fokus utama pada pengembangan dan pelatihan model berdasarkan dataset yang telah disiapkan sebelumnya. Dalam penelitian ini, arsitektur model yang digunakan adalah YOLO11 yang dikembangkan oleh Ultralytics. Pemilihan ini didasarkan pada performa yang ditawarkan untuk deteksi objek secara *real-time*. Performa yang ditawarkan tersebut merupakan hasil penerapan inovasi terkini pada *deep learning* sehingga menjadikannya pilihan serbaguna untuk berbagai tugas visual.

Arsitektur YOLO11 dipilih karena kemampuannya pada keseimbangan yang superior antara kecepatan dan akurasi yang merupakan faktor krusial untuk aplikasi pertanian secara *real-time*. Berbeda dengan arsitektur *two-stage* seperti *Faster R-CNN* yang memisahkan proses proposal wilayah (*region proposal*) dan klasifikasi, YOLO mengintegrasikan keduanya dalam satu jaringan tunggal (*single neural network*). Pendekatan ini dapat mengurangi latensi komputasi dan menjadikannya lebih unggul untuk tugas penyortiran tomat yang menuntut kecepatan inferensi tinggi seperti pada input video. Sementara itu, jika dibandingkan dengan detektor satu tahap lainnya seperti SSD, arsitektur YOLO11 menggunakan *anchor-free detector* yang dioptimalkan untuk kecepatan dan presisi. Hal ini memungkinkan model untuk menangkap informasi kontekstual yang lebih kaya dari skala fitur dalam sebuah citra sehingga menghasilkan presisi deteksi yang lebih tinggi terutama untuk objek dengan ukuran sangat kecil.

Setelah menetapkan YOLO11, tahap selanjutnya adalah menentukan varian model yang paling optimal untuk data set yang digunakan. Penelitian ini akan melakukan pelatihan pada varian model YOLO11 seperti varian *n (nano)*, *s (small)*, *m (medium)*, dan *l (large)*. Peneliti tidak menggunakan varian *x (extra-large)* karena kurang cocok untuk mayoritas deteksi objek yang memerlukan performa *real-time* dan berjalan pada

hardware yang umum dan terbatas. Setiap varian model dilatih menggunakan dataset buah tomat yang telah melalui beberapa tahapan sebagaimana yang telah diuraikan pada bagian sebelumnya. Tabel 1 memperlihatkan *hyperparameter* pada model untuk deteksi tingkat kematangan menggunakan YOLO11.

Tabel 1. Konfigurasi parameter untuk pelatihan model

Parameter	Nilai
<i>Batch-size</i>	16
<i>Epochs</i>	100
<i>Image-Size</i>	640 × 640
<i>Learning Rate (LR)</i>	0.01
<i>Momentum</i>	0.937
<i>Warmup Epochs</i>	3.0
<i>Weight Decay</i>	0.0005
<i>Optimizer</i>	SGD

Evaluasi Model

Tahap ini bertujuan untuk mengukur kemampuan setiap varian model yang telah dilatih dalam menjalankan tugas deteksi tingkat kematangan buah tomat. Proses ini menggunakan dataset *valid* yang telah dipisahkan sebelumnya untuk memastikan objektivitas penilaian dan validitas hasil. Kinerja model diukur secara kuantitatif menggunakan beberapa metrik standar dalam deteksi objek.

Metrik pertama adalah *precision*, yang menilai tingkat keakuratan prediksi dengan mengukur seberapa banyak objek yang dideteksi sebagai tomat matang, setengah matang dan mentah yang benar-benar sesuai dengan label sebenarnya. Metrik kedua *recall*, yang mengevaluasi kemampuan model untuk mengenali semua objek tomat yang relevan dalam sebuah citra. Nilai *recall* yang tinggi menandakan bahwa model mampu menemukan mayoritas tomat tanpa banyak yang terlewat. Sebagai metrik evaluasi utama yang menyimpulkan performa model secara keseluruhan, penelitian ini menggunakan *mean Average Precision (mAP50)*.

Metrik ini memberikan gambaran kinerja yang komprehensif karena menyeimbangkan *precision* dan *recall*. Istilah mAP50 merujuk pada nilai rata-rata dari *Average Precision (AP)* untuk semua kelas kematangan yang dihitung pada ambang batas *Intersectin over Union (IoU)* sebesar 0.5. Ambang batas IoU 0.5 mengindikasikan bahwa sebuah deteksi dianggap benar jika area tumpang tindih antara *bounding box* dan kotak

pembatas label asli (*ground truth*) mencapai minimal 50%. Varian model yang berhasil mencapai nilai mAP50 tertinggi akan dianggap sebagai model dengan keseimbangan deteksi terbaik dan dipilih untuk pengujian lebih lanjut.


HASIL DAN PEMBAHASAN

Pada bagian ini, disajikan analisis mendalam mengenai hasil evaluasi empat varian model YOLO11, yaitu YOLO11n (*nano*), YOLO11s (*small*), YOLO11m (*medium*) dan YOLO11l (*large*) untuk tugas deteksi tingkat kematangan tomat. Evaluasi ini tidak hanya membandingkan metrik kuantitatif tetapi juga membahas implikasi arsitektural, signifikansi praktis dan kontribusi temuan terhadap bidang keilmuan terkait.

Pelatihan keempat varian model YOLO11 menghasilkan performa yang bervariasi sebagaimana dirangkum pada Tabel 2. Hasil menunjukkan bahwa mode YOLO11m mencapai keseimbangan terbaik antara akurasi dan kemampuan generalisasi dengan nilai mAP50 pada ambang batas IoU 0.5 tertinggi sebesar 89.1%, disertai nilai *precision* 85.9% dan nilai *recall* 84.1%. Keunggulan performa YOLO11m dapat didistribusikan secara langsung pada arsitekturnya. Varian 'm' (*medium*) memiliki kedalaman (*depth*) dan lebar (*width*) jaringan yang lebih besar dibandingkan varian 'n' dan 's'. Hal ini memungkinkannya untuk membentuk representasi visual yang lebih kaya dan diskriminatif yang penting untuk membedakan nuansa warna dan tekstur halus antar kelas kematangan tomat. Meskipun Model YOLO11l memiliki kapasitas arsitektur terbesar, model tidak menunjukkan peningkatan mAP50 yang sepadan. Fenomena ini mengindikasikan bahwa peningkatan kompleksitas model tidak selalu berbanding lurus dengan peningkatan performa pada data set spesifik ini. Kapasitas model yang terlalu besar pada YOLO11l berisiko mengalami *overfitting* ringan dengan model mulai menghafal data latih alih-alih belajar pola yang dapat digeneralisasi. Dengan demikian, arsitektur YOLO11m mempresentasikan titik optimal (*sweet spot*) antara kapasitas representasi fitur yang kuat dan kemampuan generalisasi yang efisien untuk tugas deteksi kematangan tomat.

Tabel 2. Perbandingan Hasil Performa Model


Varian Model	Kelas	Precision	Recall	mAP50
YOLO11n	Seluruh Kelas	0.859	0.810	0.881
	Matang	0.910	0.888	0.945
	Setengah Matang	0.741	0.638	0.776
	Mentah	0.924	0.904	0.921
YOLO11s	Seluruh Kelas	0.856	0.834	0.889
	Matang	0.900	0.891	0.937
	Setengah Matang	0.741	0.680	0.808
	Mentah	0.928	0.930	0.932
YOLO11m	Seluruh Kelas	0.859	0.841	0.891
	Matang	0.923	0.914	0.931
	Setengah Matang	0.753	0.730	0.821
	Mentah	0.900	0.880	0.921
YOLO11l	Seluruh Kelas	0.862	0.843	0.881
	Matang	0.906	0.924	0.933
	Setengah Matang	0.746	0.745	0.810
	Mentah	0.934	0.860	0.902



Gambar 8. Grafik Metrik Validasi Model YOLO11m

Gambar 8 memperlihatkan grafik metrik validasi model YOLO11m selama 100 *epoch*. Grafik ini esensial untuk mendiagnosis proses pembelajaran model. Terlihat bahwa kurva *loss* untuk *box_loss*, *cls_loss* dan *dfl_loss* menunjukkan tren penurunan yang konsisten dan konvergen baik pada data. Pola ini menandakan bahwa model belajar secara efektif untuk meminimalkan kesalahan prediksi tanpa mengalami *overfitting* yang biasanya ditandai dengan peningkatan *loss* pada data validasi. Secara simultan, metrik evaluasi seperti *precision*, *recall* dan mAP50 menunjukkan tren

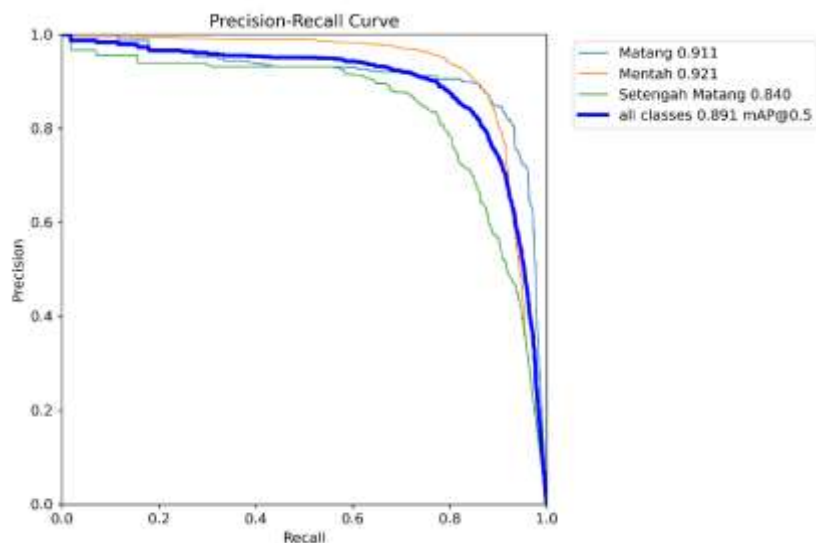
peningkatan yang stabil sebelum mencapai fase datar menjelang akhir pelatihan. Hal ini mengonfirmasi bahwa model telah mencapai konvergensi yang optimal.



Gambar 9. *Confusion Matrix normalized* dari Model YOLO11m

Meskipun performa keseluruhan model YOLO11m sangat baik, analisis lebih dalam pada metrik per kelas mengungkapkan beberapa tantangan. Gambar 9 menunjukkan secara visual memetakan akurasi klasifikasi dan kebingungan model. Terlihat bahwa model paling sering mengalami kesalahan pada kelas setengah matang dengan akurasi prediksi yang benar sebesar 77%. Sebagian besar kesalahan klasifikasi terjadi di antara kelas setengah matang dan matang serta setengah matang dan *background*.

Kesulitan ini dapat dijelaskan oleh dua faktor. Pertama, tingginya variasi visual di dalam kelas itu sendiri karena warna tomat pada tahap transisi ini sangat beragam. Kedua, kemiripan visualnya dengan kelas lain sehingga batas antara tomat mentah, setengah matang dan matang menjadi ambigu. Fenomena ini diperkuat dengan Gambar 10 pada kurva untuk setengah matang berada sedikit di bawah dua kelas lainnya yang menandakan tingkat kesulitan yang lebih tinggi bagi model dalam menyeimbangkan presisi dan kelengkapan deteksi yang lebih tinggi secara bersamaan pada kelas tersebut.



Gambar 10. Kurva *Precision-Recall* Untuk Setiap Kelas

Keberhasilan model YOLO11m dalam pengujian *real-time* dengan kecepatan inferensi 16 *frames per second* (fps) menegaskan potensi untuk aplikatifnya untuk mendukung operasional penyortiran tomat pada skala komersial. Kinerja ini secara langsung menjawab tantangan pada proses pascapanen yang selama ini bergantung pada penyortiran manual yang lama dan subjektif.

Gambar 11 menunjukkan kemampuan deteksi model pada citra uji baru dalam skenario yang mendekati kondisi nyata. Terlihat bahwa model mampu mendeteksi beberapa tomat dalam satu *frame* dengan tingkat keyakinan (*confidence score*) yang tinggi baik pada objek yang bergerombol maupun yang terisolasi dengan latar belakang yang bervariasi. Kemampuan ini mengonfirmasi bahwa model yang dilatih tidak hanya unggul secara statistik, tetapi juga ketahanan dan fungsional di lapangan. Dengan demikian, implementasi sistem ini berpotensi meningkatkan proses pascapanen dengan meningkatkan efisiensi operasional, menekan biaya tenaga kerja dan meningkatkan konsistensi kualitas hasil panen sebagai langkah penting dalam modernisasi rantai pasok pertanian di Indonesia.



Gambar 11. Contoh Hasil Deteksi Model YOLO11m pada Citra Uji

SIMPULAN

Penelitian ini berhasil mengembangkan sebuah sistem deteksi kematangan tomat melalui evaluasi empat varian model YOLO11. Model YOLO11m menunjukkan kinerja paling optimal dengan nilai precision sebesar 85.9%, recall 84.1% dan nilai mAP50 tertinggi pada 89.1%. Keberhasilan model ini divalidasi melalui kemampuannya beroperasi pada input video secara real-time dengan kecepatan inferensi sebesar 16 fps yang menegaskan potensinya untuk aplikasi praktis. Meskipun performanya kuat, teridentifikasi tantangan dalam membedakan kelas setengah matang secara akurat akibat tingginya variasi visual pada tahap transisi kematangan. Oleh karena itu, penelitian selanjutnya direkomendasikan untuk memperkaya dataset dengan kondisi pencahayaan yang lebih beragam serta mencoba menerapkan model ini pada mesin penyortiran nyata untuk menguji kinerjanya di lapangan.

UCAPAN TERIMA KASIH

Penulis ingin menyampaikan terima kasih pada dosen pembimbing atas bimbingan dan arahan yang berharga selama proses penelitian ini. Apresiasi juga disampaikan kepada Universitas Islam Indonesia yang telah menyediakan fasilitas pendukung. Terakhir, terima kasih yang tulus penulis sampaikan kepada keluarga dan seluruh pihak yang telah memberikan doa dan dukungan moril yang tidak dapat disebutkan satu per satu.

DAFTAR PUSTAKA

- Anwar, A., Giono, B., & Idrus, Muh. (2022). Respons Pertumbuhan dan Produksi Tanaman Tomat (*Lycopersicum esculentum* Mill.) terhadap Pupuk NPK dan Kompos. *J. Agrotan*, 8(2).
- Badan Pusat Statistik. (2024a). *Statistik Hortikultura 2023*. 21–22. <https://www.bps.go.id/id/publication/2024/06/10/790c957ba8892f9771aeefb7/statistik-hortikultura-2023.html>
- Badan Pusat Statistik. (2024b, August 5). *Ekonomi Indonesia Triwulan II-2024 Tumbuh 3,79 Persen (Q-to-Q), Ekonomi Indonesia Triwulan II-2024 Tumbuh 5,05 Persen (Y-on-Y), dan Ekonomi Indonesia Semester I-2024 Tumbuh 5,08 Persen (C-to-C)*. <https://www.bps.go.id/id/pressrelease/2024/08/05/2381/ekonomi-indonesia-triwulan-ii-2024-tumbuh-3-79-persen--q-to-q---ekonomi-indonesia-triwulan-ii-2024-tumbuh-5-05-persen--y-on-y---dan-ekonomi-indonesia-semester-i-2024-tumbuh-5-08-persen--c-to-c-.html>
- Badgujar, C. M., Poulouse, A., & Gan, H. (2024). Agricultural object detection with You Only Look Once (YOLO) Algorithm: A bibliometric and systematic literature review. *Computers and Electronics in Agriculture*, 223. <https://doi.org/10.1016/j.compag.2024.109090>
- Daniels, S., Suciati, N., & Fathichah, C. (2021). Indonesian Sign Language Recognition using YOLO Method. *IOP Conference Series: Materials Science and Engineering*, 1077(1), 012029. <https://doi.org/10.1088/1757-899X/1077/1/012029>
- FAO. (2024, October 30). *Countries by commodity*. FAOSTAT. https://www.fao.org/faostat/en/#rankings/countries_by_commodity
- Hatami, M., Tukino, T., Nurapriani, F., Widiyawati, W., & Andriani, W. (2023). DETEKSI HELMET DAN VEST KESELAMATAN SECARA REALTIME MENGGUNAKAN METODE YOLO BERBASIS WEB FLASK. *EDUSAINTEK: Jurnal Pendidikan, Sains Dan Teknologi*, 10(1), 221–233. <https://doi.org/10.47668/edusaintek.v10i1.651>
- Hu, C., Liu, X., Pan, Z., & Li, P. (2019). Automatic detection of single ripe tomato on plant combining faster R-CNN and intuitionistic fuzzy set. *IEEE Access*, 7, 154683–154696. <https://doi.org/10.1109/ACCESS.2019.2949343>
- Yanti, L., Hanafi, H., & Yassir, Y. (2024). Rancang Bangun Sistem Penyortiran Kematangan Buah Tomat Berbasis Internet of Things. *Jurnal Litek : Jurnal Listrik Telekomunikasi Elektronika*, 21(2), 89–94. <https://doi.org/10.30811/litek.v21i2.40>
- Mputu, H. S., Abdel-Mawgood, A., Shimada, A., & Sayed, M. S. (2024). Tomato Quality Classification Based on Transfer Learning Feature Extraction and Machine Learning Algorithm Classifiers. *IEEE Access*, 12, 8283–8295. <https://doi.org/10.1109/ACCESS.2024.3352745>
- Muarofah, I. A., Jauhar Vikri, M., & Sa'ida, I. A. (2023). Real-Time Tomato Quality Detection System Using You Only Look Once (YOLOv7) Algorithm. *Ultimatics : Jurnal Teknik Informatika*, 15(2), 89.
- Salehi, B., Sharifi-Rad, R., Sharopov, F., Namiesnik, J., Roointan, A., Kamle, M., Kumar, P., Martins, N., & Sharifi-Rad, J. (2019). Beneficial effects and potential risks of

tomato consumption for human health: An overview. In *Nutrition* (Vol. 62, pp. 201–208). Elsevier Inc. <https://doi.org/10.1016/j.nut.2019.01.012>

Wibowo, A., Lusiana, L., & Dewi, T. K. (2023). Implementasi Algoritma Deep Learning You Only Look Once (YOLOv5) Untuk Deteksi Buah Segar Dan Busuk. *Paspalum: Jurnal Ilmiah Pertanian*, 11(1), 123. <https://doi.org/10.35138/paspalum.v11i1.489>

Yanto, Y., Aziz, F., & Irmawati, I. (2023). YOLO-V8 PENINGKATAN ALGORITMA UNTUK DETEKSI PEMAKAIAN MASKER WAJAH. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(3), 1437–1444.

Zhao, J., Du, C., Li, Y., Mudhsh, M., Guo, D., Fan, Y., Wu, X., Wang, X., & Almodfer, R. (2024). YOLO-Granada: a lightweight attentioned Yolo for pomegranates fruit detection. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-67526-4>