

PENERAPAN DETEksi KECACATAN BUAH JERUK MENGGUNAKAN MODEL DEEP LEARNING YOLOv5

Aldi Febriansyah¹, Noorman Rinanto^{2*}, Adianto³, Muhammad Khoirul Hasin⁴, Putri Nur Rahayu⁵

^{1,2*,3,4,5}Politeknik Perkapalan Negeri Surabaya, Jl. Teknik Kimia, Keputih, Kec. Sukolilo, Surabaya 60111, Indonesia, telp: (031) 5947186

Keywords:
Deep Learning;
YOLOv5;
Deteksi Citra;
Kecacatan Buah.

Corespondent Email:
noorman.rinanto@ppns.ac.id

Abstrak. Penentuan kualitas buah jeruk secara manual cenderung tidak konsisten serta memerlukan waktu dan tenaga yang signifikan. Oleh karena itu, penelitian ini bertujuan untuk merancang sistem otomatis dalam mendeteksi kecacatan buah jeruk dengan memanfaatkan model deep learning YOLOv5. Dataset citra buah jeruk dikumpulkan berdasarkan variasi tingkat kematangan, yaitu matang, asam, dan busuk, kemudian diberi label menggunakan platform Roboflow dan dibagi menjadi data pelatihan, validasi, serta pengujian. Proses pelatihan dilakukan melalui *platform* Google Colab dengan menerapkan dua varian model, yaitu YOLOv5s dan YOLOv5n. Berdasarkan hasil evaluasi, model YOLOv5s menunjukkan akurasi deteksi yang sangat tinggi dengan nilai mAP@0.5 di atas 99% dan mAP@0.5:0.95 mendekati 98%. Sementara itu, YOLOv5n memiliki keunggulan dalam hal kecepatan inferensi meskipun akurasinya sedikit lebih rendah. Pengujian secara *real-time* menggunakan *webcam* menunjukkan bahwa kedua model mampu mengenali serta mengklasifikasikan buah jeruk secara tepat. Pengujian *real-time* menggunakan kamera menghasilkan akurasi 93,33% untuk YOLOv5s dan 86,67% untuk YOLOv5n, sistem ini memiliki potensi besar dalam mendukung proses otomatisasi penilaian mutu buah, meningkatkan efisiensi kerja, dan mengurangi *human error* dalam proses sortasi.



Copyright © [JITET](#) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

Abstract. Manual determination of citrus fruit quality tends to be inconsistent and requires significant time and effort. Therefore, this study aims to design an automated system to detect citrus fruit defects by utilizing the YOLOv5 deep learning model. A dataset of citrus fruit images was collected based on variations in ripeness levels, namely ripe, sour, and rotten, then labeled using the Roboflow platform and divided into training, validation, and testing data. The training process is carried out through the Google Colab platform by applying two model variants, namely YOLOv5s and YOLOv5n. Based on the evaluation results, the YOLOv5s model shows very high detection accuracy with mAP@0.5 values above 99% and mAP@0.5:0.95 close to 98%. Meanwhile, YOLOv5n has an advantage in terms of inference speed although the accuracy is slightly lower. Real-time testing using a webcam shows that both models are able to accurately recognize and classify citrus fruits. Real-time testing using a webcam resulted in an accuracy of 93.33% for YOLOv5s and 86.67% for YOLOv5n. This system has great potential in supporting the automation of fruit quality assessment, improving work efficiency, and reducing human error in the sorting process.

1. PENDAHULUAN

Pertanian merupakan sektor fundamental yang berperan penting dalam pembangunan

ekonomi dan sosial di Indonesia. Perannya tidak hanya sebagai penyedia kebutuhan pangan utama, tetapi juga sebagai sumber penghidupan bagi sebagian besar penduduk, terutama di wilayah pedesaan. Sektor ini memiliki kontribusi nyata terhadap pertumbuhan ekonomi nasional. Berdasarkan data dari Badan Pusat Statistik (BPS), sektor pertanian menyumbang sekitar 11-13% terhadap Produk Domestik Bruto (PDB) Indonesia, menempatkannya sebagai salah satu sektor utama yang menopang ekonomi negara [1]. Dengan cakupan yang luas, mulai dari subsektor tanaman pangan, hortikultura, perkebunan, hingga peternakan dan perikanan, pertanian memiliki potensi besar untuk terus dikembangkan melalui pemanfaatan teknologi.

Jeruk manis (*Citrus sinensis*), yang merupakan varietas populer di Indonesia, secara umum dapat diklasifikasikan berdasarkan indikator visual seperti warna kulit—yang mencerminkan tingkat kematangan—yakni hijau, oranye, dan kuning. Sayangnya, kualitas fisik buah sangat rentan mengalami penurunan akibat berbagai faktor, mulai dari bintik hitam yang disebabkan oleh patogen, memar akibat proses pemanenan atau pengangkutan, hingga luka gores akibat gesekan antar buah atau dengan permukaan kasar [2], [3]. Penurunan kualitas tersebut tidak hanya menurunkan nilai jual dan daya saing produk di pasar, tetapi juga berdampak pada umur simpan, kandungan nutrisi, serta persepsi konsumen terhadap kualitas dan keamanan produk [4].

Dalam praktik di lapangan, proses seleksi dan klasifikasi mutu buah jeruk masih dilakukan secara manual, mengandalkan tenaga kerja manusia yang menilai kualitas berdasarkan pengamatan visual. Proses ini bersifat subjektif, tidak konsisten antarindividu, dan memakan waktu serta tenaga dalam jumlah besar [5]. Selain tidak efisien, pendekatan manual juga meningkatkan risiko kesalahan klasifikasi, yang berdampak pada ketidakakuratan distribusi buah berdasarkan kualitasnya. Hal ini menjadi tantangan tersendiri bagi petani maupun pelaku industri yang ingin meningkatkan efisiensi produksi dan daya saing di era industri 4.0.

Seiring dengan berkembangnya teknologi digital, kecerdasan buatan (Artificial Intelligence/AI) telah menjadi solusi potensial untuk mengatasi keterbatasan metode

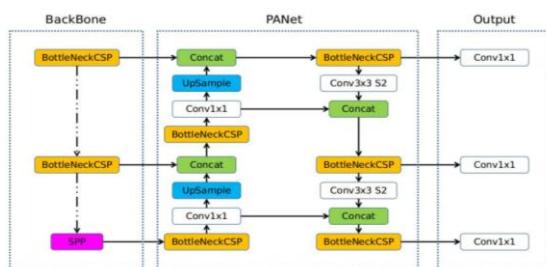
konvensional. Dalam konteks pertanian modern, teknologi AI dapat dimanfaatkan untuk otomasi proses, salah satunya melalui computer vision, yaitu teknologi yang memungkinkan sistem komputer untuk memproses dan menganalisis citra visual secara otomatis [6]. Salah satu algoritma populer dalam deteksi objek menggunakan pendekatan deep learning adalah YOLO (You Only Look Once), yang mampu melakukan klasifikasi dan prediksi posisi objek dalam citra secara cepat dan akurat [7]. YOLOv5, sebagai versi pengembangan dari YOLO, memiliki keunggulan dalam hal efisiensi komputasi, kecepatan inferensi, ukuran model yang ringan, dan kemampuan bekerja secara real-time, bahkan pada perangkat berdaya rendah seperti Raspberry Pi dan Jetson Nano [8], [9].

Penelitian sebelumnya telah membuktikan bahwa YOLOv5 efektif diterapkan dalam berbagai bidang pertanian, seperti klasifikasi tingkat kematangan buah tomat [10], deteksi penyakit daun tanaman [11], dan pengelompokan kualitas hasil panen berdasarkan tingkat kerusakan [12]. Penerapan teknologi ini tidak hanya mampu mengurangi ketergantungan pada tenaga kerja manual, tetapi juga meningkatkan presisi dan kecepatan proses klasifikasi produk, serta mengurangi risiko kontaminasi silang antarbuah. Integrasi sistem seperti ini juga mendukung visi besar pertanian presisi (precision agriculture), yang menekankan pemanfaatan teknologi digital untuk meningkatkan hasil, efisiensi, dan keberlanjutan produksi pertanian.

Dengan sistem deteksi otomatis yang dibangun, diharapkan dapat terwujud proses penilaian mutu yang lebih cepat, konsisten, dan efisien, yang merupakan langkah penting menuju implementasi pertanian presisi di Indonesia [13]. Penelitian ini ditujukan untuk mengembangkan sistem otomatis yang mampu mendeteksi cacat pada buah jeruk menggunakan model YOLOv5. Penerapan teknologi ini diharapkan dapat memberikan hasil deteksi yang lebih cepat, akurat, dan konsisten dibandingkan metode manual. Selain meningkatkan efisiensi kerja, pendekatan ini juga menjadi kontribusi nyata dalam mendorong pemanfaatan teknologi cerdas di bidang pertanian, khususnya sebagai bagian dari transformasi menuju sistem pertanian presisi di Indonesia.

2. TINJAUAN PUSTAKA

YOLO (You Only Look Once) merupakan sebuah arsitektur jaringan saraf yang dirancang khusus untuk melakukan deteksi objek secara real-time, sedangkan YOLOv5 merupakan versi terbaru dari metode ini yang telah mengalami sejumlah peningkatan dalam hal efisiensi dan akurasi. Deteksi objek sendiri memiliki peran penting dalam bidang pengolahan citra digital, di mana tugas utamanya adalah mengidentifikasi posisi (lokasi spasial) objek yang terdapat di dalam suatu gambar atau citra, serta menentukan kategori atau kelas dari objek tersebut. Dalam proses ini, gambar atau citra digunakan sebagai data input, kemudian algoritma akan menghasilkan keluaran berupa vektor yang merepresentasikan kotak pembatas (bounding box) dan label prediksi dari kelas objek yang terdeteksi [14].



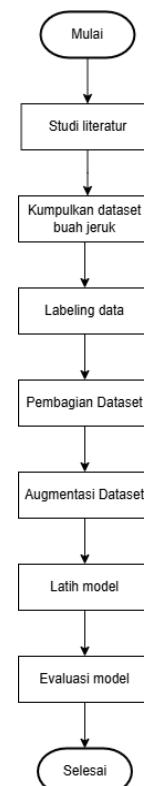
Gambar 1. Arsitektur algoritma YOLO

YOLOv5 pengembangan lanjutan dari arsitektur You Only Look Once, yang saat ini telah mencapai versi kelima dengan peningkatan signifikan dalam hal akurasi dibandingkan versi-versi sebelumnya. Salah satu keunggulan utama YOLOv5 adalah ketersediaan sembilan model pra-latih (pre-trained models) yang memungkinkan pengguna untuk memilih model yang paling sesuai dengan spesifikasi perangkat keras (hardware) yang digunakan, sehingga dapat mengoptimalkan performa sistem secara keseluruhan. Selain itu, pada tahap praproses input, YOLOv5 mengintegrasikan berbagai teknologi canggih seperti *Mosaic data augmentation*, *adaptive anchor computation*, dan *adaptive image scaling*, yang secara kolektif meningkatkan efisiensi pelatihan serta kemampuan generalisasi model terhadap berbagai variasi data citra [15]. Arsitektur

YOLOv5 yang digunakan pada studi ini seperti ditunjukkan pada Gambar 1.

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental berbasis deep learning untuk mendeteksi kecacatan pada buah jeruk secara otomatis. Tahapan metode mencakup studi literatur untuk memahami konsep deteksi objek berbasis citra digital dan algoritma YOLOv5, pengumpulan dataset buah jeruk dengan berbagai kondisi, serta labeling data menggunakan perangkat lunak anotasi. Data kemudian dibagi menjadi data pelatihan dan pengujian, dilanjutkan dengan proses augmentasi untuk memperkaya variasi data. Selanjutnya, model dilatih menggunakan YOLOv5 dan dievaluasi.



Gambar 2. Alur Metode Penelitian Deteksi Kecacatan Buah Jeruk

Untuk memperkuat validitas hasil penelitian, setiap tahapan dilakukan secara sistematis dengan memperhatikan kualitas data serta parameter pelatihan yang digunakan. Proses ini bertujuan untuk memastikan bahwa model tidak hanya mampu mengenali pola pada data pelatihan, tetapi juga memiliki kemampuan generalisasi yang baik ketika diterapkan pada

data baru. Dengan demikian, metode yang diusulkan diharapkan dapat memberikan kontribusi signifikan dalam pengembangan sistem deteksi kualitas buah jeruk secara otomatis berbasis teknologi deep learning. Selain itu, pendekatan ini juga dapat menjadi acuan untuk penelitian lanjutan pada komoditas pertanian lain yang memiliki karakteristik serupa. Implementasi sistem ini diharapkan dapat mendukung proses penyortiran buah secara lebih efisien, akurat, dan konsisten dibandingkan metode manual. Seluruh tahapan tersebut ditunjukkan pada Gambar 2.

3.1. Pengumpulan Data

Penelitian ini menggunakan total 45 buah jeruk yang diklasifikasikan ke dalam tiga tingkat kematangan, yaitu matang (orange), belum matang (hijau), dan busuk (coklat), dengan masing-masing kategori terdiri dari 15 buah. Klasifikasi ini bertujuan untuk mencakup berbagai kondisi buah secara menyeluruh. Setiap buah didokumentasikan dengan rata-rata 33 gambar menggunakan kamera beresolusi tinggi dan pencahayaan yang seragam guna menjaga konsistensi visual dalam dataset. Seluruh gambar yang terkumpul berjumlah 1.499 citra, yang kemudian dibagi ke dalam tiga kelompok untuk keperluan pelatihan, validasi, dan evaluasi performa model deteksi tingkat kematangan jeruk. Contoh citra buah jeruk berdasarkan variasi tingkat kematangannya ditunjukkan pada Gambar 3.

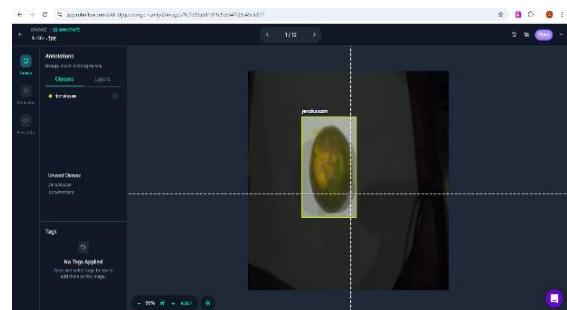


Gambar 3. Sampel Dataset Buah Jeruk

3.2. Pelabelan Data

Setelah proses pengumpulan dataset, gambar-gambar dilabeli menggunakan platform Roboflow. Dataset yang terdiri dari

1.049 data pelatihan dan 150 data pengujian, mencakup kondisi jeruk segar dan busuk, diproses dengan cara menandai area-area penting yang merepresentasikan tingkat kualitas buah. Proses pelabelan melalui Roboflow sangat membantu dalam mengklasifikasikan citra sesuai dengan kategori yang telah ditentukan. Gambar 4 di bawah menunjukkan proses pelabelan yang dilakukan sebagai bagian dari tahap persiapan dataset.



Gambar 4. Pelabelan Dataset

3.3. Pembagian Dataset

Setelah proses pelabelan selesai menggunakan platform Roboflow, dataset buah jeruk dibagi menjadi tiga bagian, yaitu 1.049 gambar (78%) untuk pelatihan, 300 gambar (20%) untuk validasi, dan 150 gambar (10%) untuk pengujian. Pembagian ini bertujuan untuk memastikan proses pelatihan model YOLOv5 berlangsung optimal sekaligus memungkinkan evaluasi kinerja model secara objektif. Proses ini juga membantu dalam menguji kemampuan model mendeteksi kecacatan pada buah jeruk secara akurat. Gambar 5 menunjukkan rincian pembagian dataset yang digunakan dalam penelitian ini.



Gambar 5. Komposisi Pembagian Dataset

3.4. Augmentasi Dataset

Proses augmentasi dilakukan pada dataset buah jeruk menggunakan Roboflow dengan teknik flipping, cropping, dan rotasi untuk memperkaya variasi data dan meningkatkan akurasi deteksi model YOLOv5 terhadap berbagai kondisi buah. Setelah proses augmentasi, dataset dibagi menjadi tiga bagian, yaitu data pelatihan

sebanyak 8.392 gambar (78%), data validasi sebanyak 2.400 gambar (20%), dan data pengujian sebanyak 1.200 gambar (10%). Dataset yang telah diproses kemudian diunggah ke Google Drive untuk memudahkan akses selama proses pelatihan model di Google Colab secara efisien.

3.5. Pelatihan Model

Setelah mempersiapkan dataset, langkah selanjutnya adalah menginstal library Ultralytics di Google Colab menggunakan perintah `!pip install ultralytics`, yang berfungsi untuk mempersiapkan lingkungan pelatihan model YOLO. Instalasi ini diikuti dengan perintah import ultralytics dan ultralytics.checks() untuk memastikan sistem siap digunakan. Kemudian, model diimpor menggunakan from ultralytics import YOLO, dan model YOLOv5 pralatih dimuat melalui model = YOLO('yolov5n.pt') untuk mempercepat proses pelatihan.

Pelatihan dilakukan menggunakan dataset buah jeruk sebanyak 11.992 gambar yang telah diunggah ke Google Drive dan dibagi menjadi 85% data pelatihan, 10% validasi, dan 5% pengujian. Selama pelatihan, model memperbarui bobot-bobotnya untuk meningkatkan akurasi dalam mendekripsi objek. Proses pelatihan berlangsung selama kurang lebih 1 jam.

3.6. Evaluasi Model

Tahap evaluasi model dilakukan menggunakan gambar buah jeruk yang telah melalui proses segmentasi. Hasil pengujian dianalisis menggunakan confusion matrix untuk menghitung metrik evaluasi seperti akurasi, presisi, dan recall. Proses ini memberikan gambaran menyeluruh terhadap kinerja model dalam mengidentifikasi tingkat kematangan buah jeruk, serta mengukur sejauh mana model dapat memberikan prediksi yang akurat dan relevan. Kinerja model ini diukur dengan menggunakan metrik mAP@0.5 dan mAP@0.5:0.95.

mAP@0.5 singkatan dari mean Average Precision (mAP) pada IoU (Intersection over Union) sebesar 0.5 merupakan metrik pengukuran presisi obyek deteksi dengan toleransi tumpang tindih minimal 50%.

Persamaan (1) dipakai untuk menghitung metrik mAP.

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

Dengan N adalah jumlah kelas, AP_i merupakan nilai Average Precision per kelas i. Secara khusus AP adalah area di dalam kurva Precision-Recall (P-R) yang dihitung dengan menggunakan formulasi (2). Dimana P(R) merupakan presisi sebagai fungsi dari recall, dan R = Recall.

$$AP = \int_0^1 P(R)dR \quad (2)$$

Untuk mencari nilai Presisi (P) dan Recall (R) pada persamaan diatas dapat mengikuti aturan (3) dan (4) berikut ini.

$$P = \frac{TP}{TP+FP} \quad (3)$$

$$R = \frac{TP}{TP+FN} \quad (4)$$

Adapun TP = True Positives, FP = False Positives, dan FN = False Negatives.

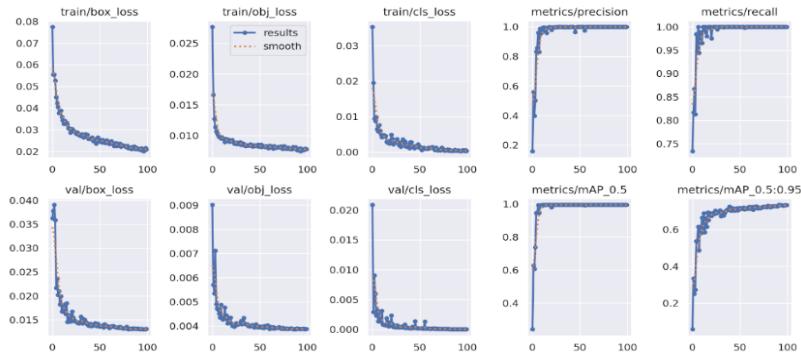
Sedangkan metrik mAP@0.5:0.95 digunakan untuk mengukur akurasi obyek yang lebih ketat dengan IoU antara 0.5 sampai 0.95. Dimana persamaan (5) merupakan rumus untuk mencari nilai IoU ini. Dengan B_{pred} merupakan *bounding box* hasil prediksi model, B_{gt} adalah *bounding box ground truth* (label asli), \cap adalah irisan area, dan \cup adalah gabungan area.

$$IoU = \frac{\text{Luas}(B_{pred} \cap B_{gt})}{\text{Luas}(B_{pred} \cup B_{gt})} \quad (5)$$

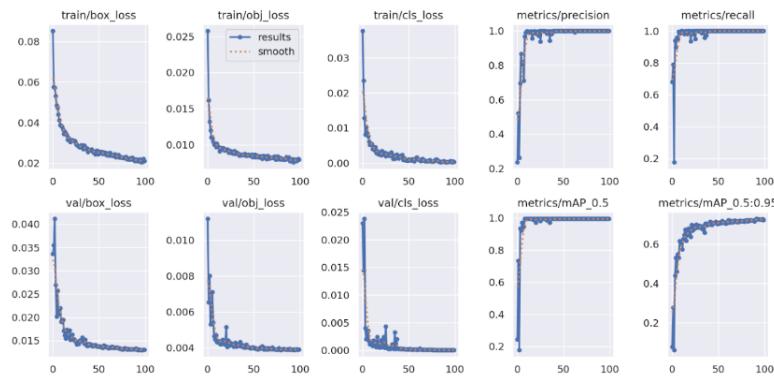
4. HASIL DAN PEMBAHASAN

4.1. Hasil Pelatihan Model

Pada tahap ini model YOLOv5s telah dilatih selama 100 epoch menggunakan 70% dari 11.992 gambar buah jeruk dengan batch size



Gambar 6. Hasil Evaluasi Model YOLOv5s



Gambar 7. Hasil Evaluasi Model YOLOv5n

16, dan hasil pelatihan menunjukkan performa yang sangat baik. Grafik pada Gambar 6 memperlihatkan penurunan yang konsisten pada nilai box loss, objectness loss, dan classification loss untuk data pelatihan maupun validasi, menandakan proses pembelajaran yang stabil tanpa indikasi overfitting. Selain itu, nilai precision dan recall mencapai lebih dari 99%, dengan mAP@0.5 juga melebihi 99% dan mAP@0.5:0.95 mendekati 98%, yang mencerminkan akurasi deteksi dan klasifikasi objek yang sangat tinggi pada berbagai tingkat ketelitian.

Sedangkan pada Gambar 7, model YOLOv5n yang menggunakan arsitektur lebih ringan juga menunjukkan tren positif, dengan loss yang menurun dan nilai mAP yang meningkat secara progresif. Namun, dibandingkan YOLOv5s, nilai mAP@0.5:0.95 pada YOLOv5n cenderung lebih rendah dan kurang stabil, mengindikasikan performa deteksi yang sedikit lebih rendah. Meskipun

demikian, model ini tetap memberikan hasil yang efisien dengan kecepatan inferensi lebih tinggi, cocok untuk perangkat dengan keterbatasan sumber daya

4.2. Hasil Pengujian Model YOLOv5s

Proses testing pada YOLOv5s dilakukan secara real time dengan menggunakan webcam untuk menangkap frame buah jeruk secara langsung, lalu setiap frame diproses untuk prediksi. Pada tahap ini, model YOLOv5s diuji dengan data baru input langsung dari webcam untuk mendeteksi tiga kelas kematangan buah jeruk: jerukasam, jerukmatang, dan jerukbusuk. Dengan demikian, hasil pengujian ini dapat menggambarkan kemampuan generalisasi serta performa YOLOv5s dalam kondisi operasi real time. Gambar 8, 9, dan 10 menampilkan contoh deteksi secara langsung yang menunjukkan bahwa YOLOv5s mampu mengklasifikasikan tingkat kematangan, keasaman dan kebusukan jeruk dengan keakuratan tinggi dan kecepatan

inferensi yang memadai. Sedangkan untuk kinerja model tersebut dapat disajikan dalam Tabel 1.

Berdasarkan hasil pengujian secara realtime menggunakan webcam pada table tersebut, dapat diketahui bahwa YOLOv5s yang diterapkan telah berhasil melakukan prediksi terhadap input gambar secara langsung dengan tingkat rata-rata akurasi keberhasilan sebesar 93.33%.



Gambar 8. Hasil deteksi buah jeruk kelas matang pada model YOLOv5s



Gambar 9. Hasil deteksi buah jeruk kelas asam pada model YOLOv5s



Gambar 10. Hasil deteksi buah jeruk kelas busuk pada model YOLOv5s

Tabel 1. Hasil Pengujian Realtime YOLOv5s

Kategori Jeruk	Jumlah Sampel	Deteksi Benar	Deteksi Salah	Akurasi %
Matang	5	5	0	100%
Asam	5	4	1	80%
Busuk	5	5	0	100%
Rata-Rata Keberhasilan %				93.33%

4.3. Hasil Pengujian Model YOLOv5n

Pengujian YOLOv5n dilakukan secara real time menggunakan webcam untuk mendeteksi tiga kelas kematangan buah jeruk: jeruk asam, jeruk matang, dan jeruk busuk. Setiap frame yang ditangkap diproses langsung untuk prediksi. Dibandingkan YOLOv5s, YOLOv5n lebih cepat dalam inferensi karena arsitekturnya lebih ringan, meskipun dengan akurasi sedikit lebih rendah. Hasil deteksi yang ditampilkan pada Gambar 11, 12, dan 13 menunjukkan bahwa YOLOv5n tetap mampu mengklasifikasikan buah jeruk secara cepat dan konsisten dalam kondisi operasional real time. Sedangkan Tabel 2 menunjukkan kinerja model YOLOv5n dengan menggunakan 5 (lima) sampel buah jeruk di tiap kelas.



Gambar 11. Hasil deteksi buah jeruk kelas matang pada model YOLOv5n



Gambar 12. Hasil deteksi buah jeruk kelas asam pada model YOLOv5n



Gambar 13. Hasil deteksi buah jeruk kelas busuk pada model YOLOv5n

Tabel 2. Hasil Pengujian Realtime YOLOv5n

Kategori Jeruk	Jumlah Sampel	Deteksi Benar	Deteksi Salah	Akurasi %
Matang	5	5	0	100%
Asam	5	4	1	80%
Busuk	5	1	1	80%
Rata-Rata Keberhasilan %				86.67%

Berdasarkan hasil pengujian secara realtime menggunakan webcam pada tabel, dapat diketahui bahwa YOLOv5n yang diterapkan telah berhasil melakukan prediksi terhadap input gambar secara langsung dengan tingkat rata-rata akurasi keberhasilan sebesar 86.67%.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil merancang dan menerapkan sistem deteksi otomatis untuk mengidentifikasi kecacatan pada buah jeruk dengan memanfaatkan model deep learning YOLOv5. Sistem tersebut menggunakan dataset citra buah jeruk yang diklasifikasikan ke dalam tiga kategori kualitas, yaitu matang, asam, dan busuk, serta mampu melakukan klasifikasi secara real-time dengan tingkat akurasi yang tinggi. Model YOLOv5s memberikan performa terbaik dengan nilai mAP@0.5 melebihi 99% dan mAP@0.5:0.95 mendekati 98%, serta mencatatkan dengan tingkat rata-rata akurasi keberhasilan sebesar 93.33%. Dalam pengujian langsung menggunakan webcam. Sementara itu, model YOLOv5n yang memiliki arsitektur lebih ringan menunjukkan keunggulan dalam kecepatan inferensi, meskipun dengan akurasi yang sedikit lebih tinggi dan dengan tingkat rata-rata akurasi keberhasilan sebesar 86.67%. Penerapan teknik augmentasi data, seperti flipping, cropping, dan rotasi, terbukti mampu

meningkatkan kemampuan generalisasi model terhadap variasi data. Secara keseluruhan, hasil penelitian ini menegaskan bahwa penggunaan teknologi YOLOv5 merupakan solusi yang efektif dan andal dalam proses deteksi kecacatan buah secara otomatis, serta memiliki potensi besar untuk meningkatkan efisiensi dan konsistensi sistem penilaian mutu di sektor pertanian dalam rangka mendukung implementasi pertanian presisi.

Penelitian selanjutnya disarankan untuk menguji sistem dalam cakupan yang lebih luas dengan jumlah data citra buah jeruk yang lebih besar dan beragam, mencakup berbagai jenis jeruk serta kondisi pencahayaan alami di lapangan, guna meningkatkan ketahanan dan akurasi model. Selain itu, pengembangan lebih lanjut dapat difokuskan pada penerapan model deteksi ke dalam perangkat keras embedded, seperti Raspberry Pi atau Jetson Nano, untuk menguji kinerja sistem secara langsung di lingkungan pertanian yang nyata. Pengayaan fungsi sistem melalui penambahan fitur klasifikasi berdasarkan tipe kecacatan, seperti bintik hitam, memar, atau luka gores, dinilai mampu meningkatkan ketelitian penilaian mutu buah. Di samping itu, integrasi dengan teknologi Internet of Things (IoT) maupun pengembangan aplikasi berbasis perangkat bergerak dapat menjadi alternatif pengembangan guna meningkatkan kemudahan akses dan pemanfaatan sistem oleh para petani maupun pelaku industri pertanian.

DAFTAR PUSTAKA

- [1] C. Samu, M. Anggraeni, A. Ratih, and G. Atiqasani, “The Contribution of Agricultural Crop Production towards the Economic Growth of Indonesia’s Agricultural Sector,” E3S Web of Conferences, vol. 444, 02034, 2023.
- [2] M. Al-Dairi, P. B. Pathare, R. Al-Yahyai, and U. L. Opara, “Mechanical damage of fresh produce in postharvest transportation: Current status and future prospects,” *Trends in Food Science & Technology*, vol. 124, pp. 195–207, 2022
- [3] L. Lusiana, A. Wibowo, and T. K. Dewi, “Implementasi algoritma deep learning You Only Look Once (YOLOv5) untuk deteksi buah segar dan busuk,” *Paspalum: Jurnal Ilmiah Pertanian*, vol. 11, no. 1, pp. 123–130, 2023

- [4] J. Luis Valenzuela, "Advances in Postharvest Preservation and Quality of Fruits and Vegetables," *Foods*, vol. 12, no. 9, art. 1830, Apr. 2023, doi:10.3390/foods12091830.
- [5] S. Rajmohan, M. T. Mendem, S. S. Vanam, and P. K. Thalapally, "Online grading of fruits using deep learning models and computer vision," in *Proc. 4th Int. Conf. Information Management & Machine Intelligence (ICIMMI)*, Dec. 2022, pp. 1–8.
- [6] Q. Mohti, R. Wahyudi, and H. Mustofa, "Penerapan metode YOLOv5 dalam mendekripsi penyakit tanaman buah naga," in *Proc. Seminar Nasional Teknologi & Sains*, vol. 3, no. 1, Jan. 2024, pp. 318–323.
- [7] S. Aras, P. Tantra, and M. Bazhar, "Deteksi tingkat kematangan buah tomat menggunakan YOLOv5," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 2, pp. 623–628, 2024.
- [8] D. Minott, S. Siddiqui, dan R. J. Haddad, "Benchmarking Edge AI Platforms: Performance Analysis of NVIDIA Jetson and Raspberry Pi 5 with Coral TPU," in *Proc. IEEE SoutheastCon 2025*, pp. 1384–1389, 2025.
- [9] R. Khanam, T. Asghar, and M. Hussain, "Comparative performance evaluation of YOLOv5, YOLOv8, and YOLOv11 for solar panel defect detection," *Solar*, vol. 5, no. 1, p. 6, Feb. 2025.
- [10] H. Wang, Z. Xie, Y. Yang, J. Li, Z. Huang, and Z. Yu, "Fast identification of tomatoes in natural environments by improved YOLOv5s," *Journal of Agricultural Engineering*, vol. 55, no. 3, 2024.
- [11] Z. Liu dan X. Li, "An improved YOLOv5-based apple leaf disease detection method," *Scientific Reports*, vol. 14, 17508, 2024.
- [12] Z. Liu, L. Wang, Z. Liu, X. Wang, C. Hu, and J. Xing, "Detection of cotton seed damage based on improved YOLOv5," *Processes*, vol. 11, no. 9, Art. no. 2682, 2023, doi: 10.3390/pr11092682.
- [13] E. Tapia-Mendez, M. Hernandez-Sandoval, S. Salazar-Colores, I. A. Cruz-Albaran, dan L. A. Morales-Hernandez, "A Novel Deep Learning Approach for Precision Agriculture: Quality Detection in Fruits and Vegetables Using Object Detection Models," *Agronomy*, vol. 15, no. 6, Art. no. 1307, May 2025, doi: 10.3390/agronomy15061307.
- [14] L. Liu, W. Ouyang, X. Wang, et al., "Deep Learning for Generic Object Detection: A Survey," *International Journal of Computer Vision*, vol. 128, pp. 261–318, Feb. 2020.
- [15] J. Chen, S. Pan, Y. Chan, Y. Ni, and D. Ye, "A new method based on YOLOv5 and multiscale data augmentation for visual inspection in substation," *Scientific Reports*, vol. 14, no. 1, Art. no. 9362, 2024.