



Optimizing Coffee Ripeness Classification Using Yolov5 for Automated Detection and Sorting

Arfan Astaraja^{1*}, Bilal Shandyarta Syamsudin², Muhammad Diaz Maulana Dhafin³,
Fatkhul Hidayah⁴, Nicola Jody Setiawan⁵

¹⁻⁵Program Studi Teknik Informatika, Politeknik Negeri Jember, Indonesia

arfanraja89@gmail.com^{1*}, bilalshandy04@gmail.com², rizqiandi1310@gmail.com³,

fatkhulhidayah10@gmail.com⁴, nicolajodysetiawan@gmail.com⁵

Alamat: Jl. Mastrip, Lingkungan Panji, Tegalgede, Kec. Sumbersari, Kab. Jember, Jawa Timur 68124

Korespondensi penulis: arfanraja89@gmail.com*

Abstract. *The quality of agricultural products, particularly coffee beans, is crucial in today's global market, which demands precise ripeness classification due to its high commercial value. Traditional manual methods in coffee plantations, heavily reliant on human labor to determine quality, often result in inefficiencies and inaccuracies. To address this issue, this study developed an automated coffee ripeness detection system using the YOLOv5 machine learning algorithm, combined with Raspberry Pi, webcam, and servo motor. By integrating YOLOv5, the system enables real-time classification of coffee beans into three categories: ripe, unripe, and rotten, with an average accuracy of 90% during real-time testing. This system not only reduces dependence on manual labor but also improves process efficiency across various environmental conditions. The findings suggest that the application of this technology can significantly enhance productivity in the coffee industry, while providing a foundation for further advancements in automation and classification methodologies in the agricultural sector.*

Keywords: *Coffee classification, Object detection, Internet of Things, Deep learning, YOLOv5.*

Abstrak. Kualitas produk pertanian, khususnya biji kopi, sangat penting dalam pasar global saat ini, yang mengharuskan adanya klasifikasi kematangan yang presisi mengingat nilai komersialnya yang tinggi. Penggunaan metode manual tradisional di perkebunan kopi yang sangat bergantung pada tenaga kerja manusia untuk menentukan kualitas, sering kali menimbulkan ketidakefisienan dan ketidakakuratan. Untuk mengatasi masalah ini, penelitian ini mengembangkan sistem deteksi kematangan kopi otomatis menggunakan algoritma pembelajaran mesin YOLOv5, yang dipadukan dengan Raspberry Pi, webcam, dan motor servo. Dengan integrasi YOLOv5, sistem ini dapat mengklasifikasikan biji kopi secara real-time ke dalam tiga kategori: matang, tidak matang, dan busuk, dengan akurasi rata-rata mencapai 90% selama pengujian real-time. Sistem ini tidak hanya mengurangi ketergantungan pada tenaga kerja manual tetapi juga meningkatkan efisiensi proses dalam berbagai kondisi lingkungan. Temuan penelitian ini menunjukkan bahwa penerapan teknologi ini dapat secara signifikan meningkatkan produktivitas di industri kopi, sekaligus membuka peluang untuk kemajuan lebih lanjut dalam otomatisasi dan klasifikasi dalam sektor pertanian.

Kata kunci: klasifikasi kopi, deteksi objek, Internet of Things, Pembelajaran mendalam, YOLOv5.

1. LATAR BELAKANG

Pada masa kini aspek terpenting konsumen pada industri pertanian yaitu kualitas produk. Klasifikasi kematangan sangat berpengaruh dalam meningkatkan kualitas produk, terutama pada biji kopi spesial yang memiliki nilai komersial yang lebih tinggi karena kualitasnya lebih baik membutuhkan proses klasifikasi yang lebih ketat (Tamayo-Monsalve et al. 2022). Masalah dalam metode manual yang masih digunakan dalam banyak perkebunan kopi adalah ketergantungan pada tenaga manusia untuk menentukan kualitas biji kopi. Meskipun

sudah ada mesin yang mendukung pemisahan berdasarkan ukuran, proses klasifikasi kualitas biji kopi masih dilakukan secara manual, yang menghabiskan waktu, biaya, dan tenaga kerja, serta berpotensi mengurangi akurasi dalam penentuan kualitas biji kopi (Adiwijaya et al. 2022).

Berbagai penelitian telah mengusulkan metode berbasis pembelajaran mesin untuk meningkatkan akurasi klasifikasi kematangan kopi. Misalnya, kombinasi YOLOv5 dengan CNN telah digunakan untuk mengklasifikasikan kondisi tomat pada tanaman (Phan et al. 2023). Selain itu, perbandingan dengan metode lain, seperti K-Nearest Neighbor (KNN), Fuzzy C-Means, dan Principal Component Analysis (PCA), juga memberikan gambaran penting dalam klasifikasi kematangan kopi. Penelitian yang menggunakan KNN, menunjukkan akurasi hingga 100% dalam klasifikasi kematangan kopi berdasarkan citra dan warna buah (Damayanti and Michael 2024). Hal ini menunjukkan bahwa penggunaan algoritma pembelajaran mesin dapat sangat efektif dalam meningkatkan akurasi dan efisiensi dalam klasifikasi kematangan kopi.

Integrasi YOLOv5 dengan mekanisme perhatian koordinat dan arsitektur Transformer telah diterapkan dalam klasifikasi kualitas buah, seperti pada passion fruit, yang menunjukkan peningkatan mAP sebesar 95.36% dengan deteksi yang lebih efisien dan model yang lebih ringan dibandingkan metode sebelumnya (Liu et al. 2023). Selain itu, penerapan YOLOv5 dengan Raspberry Pi dan servo motor memungkinkan pemisahan otomatis biji kopi hijau secara real-time, meningkatkan efisiensi deteksi dan klasifikasi cacat biji kopi hijau (Gope et al. 2024).

Penerapan YOLOv5 dalam klasifikasi kematangan buah kopi telah menunjukkan akurasi tinggi serta memungkinkan pemisahan otomatis buah matang, mentah, dan busuk secara real-time menggunakan Raspberry Pi, webcam, dan servo motor. Teknologi ini berpotensi meningkatkan produktivitas industri kopi dengan mengurangi ketergantungan pada tenaga kerja manual serta mempercepat proses pengolahan kopi dalam berbagai kondisi lingkungan.

2. KAJIAN TEORITIS

Kopi

Kopi adalah salah satu minuman yang paling banyak dikonsumsi di dunia, termasuk di Indonesia. Proses pembuatannya melibatkan pemanggangan, penggilingan, dan penyeduhan biji, yang menghasilkan berbagai senyawa bioaktif seperti kafein, paraxanthine, asam klorogenat, dan flavonoid kopi (de Figueiredo Tavares and Mourad 2020). Di dalam tubuh, kafein dipecah menjadi paraxanthine yang memiliki efek serupa dalam meningkatkan

metabolisme. Konsumsi kopi diketahui dapat meningkatkan laju metabolisme sebesar 5–20% selama setidaknya tiga jam, meskipun respons tiap individu berbeda-beda tergantung faktor seperti metabolisme kafein, genetik, usia, jenis kelamin, dan komposisi tubuh (Zhang and Speakman 2024).

Objek Deteksi

Objek deteksi adalah teknik dalam computer vision untuk mengidentifikasi dan menentukan lokasi objek dalam gambar dengan menggambar kotak pembatas di sekelilingnya. Teknik ini menggabungkan image classification dan object localization. Dalam perkembangan teknologi, penggunaan alat otomatis semakin meningkatkan efisiensi dalam pemrosesan citra (Ridam Lokhande et al. 2023). Deteksi objek penting untuk aplikasi seperti pengenalan objek, segmentasi gambar, dan pelacakan visual. Metode deteksi objek dapat dibedakan menjadi pendekatan konvensional yang mengandalkan fitur visual dan model berbasis deep learning yang menggunakan jaringan saraf untuk ekstraksi fitur otomatis dan meningkatkan akurasi (Gupta et al. 2020).

Deep Learning

Deep learning adalah pendekatan komputasi dalam machine learning yang telah melampaui kemampuan manusia dalam beberapa tugas kognitif kompleks. Berasal dari artificial neural networks, deep learning mampu belajar dari data besar, membuatnya lebih unggul dibandingkan metode machine learning tradisional (Taye 2023). Teknologi ini secara otomatis mengekstrak pola kompleks tanpa memerlukan rekayasa fitur manual, cocok untuk tugas seperti deteksi objek dan pemrosesan bahasa alami. Pendekatan ini memungkinkan model untuk belajar secara hierarkis melalui jaringan saraf dalam, menghasilkan representasi data yang lebih abstrak dan bermakna dibandingkan metode konvensional (Janiesch, Zschech, and Heinrich 2021).

Internet of Things (IoT)

Internet of Things (IoT) adalah jaringan perangkat pintar yang terhubung untuk bertukar data secara otomatis menggunakan sensor, aktuator, dan protokol komunikasi seperti Wi-Fi, Zigbee, dan Bluetooth. IoT memungkinkan sistem seperti rumah dan industri menjadi lebih cerdas tanpa intervensi manusia. Dengan kemajuan wired, wireless, dan hybrid technologies, IoT meningkatkan konektivitas dan efisiensi, menyesuaikan kebutuhan berbagai sektor modern (Mansour et al. 2023). IoT melibatkan perangkat keras seperti sensor dan aktuator untuk

pengumpulan data, serta perangkat lunak yang memproses informasi. Data kemudian dianalisis melalui platform cloud computing dan fog computing untuk meningkatkan efisiensi dan skalabilitas. Fokus penelitian IoT saat ini meliputi peningkatan keamanan, efisiensi energi, dan pengoptimalan pengalaman pengguna (Laghari et al. 2022).

Roboflow

Roboflow adalah platform berbasis web untuk mengelola dataset dalam pengembangan model computer vision. Platform ini mendukung anotasi objek dengan bounding box, prapemrosesan seperti grayscale dan augmentasi data, serta mempermudah pelabelan guna meningkatkan akurasi deteksi objek. Tantangan utama bagi peneliti adalah mengumpulkan dataset berkualitas untuk mendukung model deteksi otomatis, seperti dalam identifikasi citra kendaraan (Hayati et al. 2023). Sebagai kerangka kerja computer vision, RoboFlow memfasilitasi seluruh proses pengolahan dataset, dari pengumpulan, anotasi, hingga prapemrosesan sebelum pelatihan model. Mendukung berbagai format seperti YOLO, COCO, dan Pascal VOC, serta terintegrasi dengan model deep learning, RoboFlow membantu meningkatkan efisiensi dan akurasi dalam pengembangan sistem deteksi objek (Ardra Prakash D 2024).

You Only Look Once (YOLO)

You Only Look Once (YOLO) adalah algoritma deteksi objek berbasis deep learning yang dirancang untuk mendeteksi dan mengenali objek dalam gambar atau video secara real-time. YOLO menggunakan pendekatan single-stage detection, yang berarti seluruh proses deteksi dilakukan dalam satu kali pemrosesan melalui jaringan saraf konvolusional (CNN), menjadikannya lebih cepat dibandingkan metode dua tahap seperti Faster R-CNN (Flores-Calero et al. 2024). Sejak pertama kali dikembangkan oleh Redmon et al. pada tahun 2016, YOLO telah mengalami berbagai peningkatan, dengan versi terbaru seperti YOLOv8 menawarkan akurasi yang lebih tinggi dan optimasi yang lebih efisien untuk berbagai aplikasi. YOLO telah diterapkan di berbagai bidang, termasuk deteksi lalu lintas, keamanan, serta analisis gambar medis, dengan keunggulan dalam kecepatan inferensi dan fleksibilitas dalam berbagai kondisi pencahayaan dan lingkungan (Ragab et al. 2024).

3. METODE PENELITIAN

Penelitian ini bertujuan untuk mengembangkan sistem deteksi kualitas biji kopi menggunakan teknologi YOLOv5 yang terintegrasi dengan Raspberry Pi dan motor servo untuk pemisahan otomatis. Pada bagian ini menjelaskan tentang tahapan penelitian, flowchart dan desain sistem.

Tahapan Penelitian

1. Pengumpulan Data (Data Acquisition)

Pada tahap ini, data dikumpulkan dalam bentuk gambar buah kopi dengan berbagai tingkat kematangan menggunakan kamera ponsel. Biji kopi yang digunakan berasal dari berbagai tingkat kematangan untuk memastikan variasi dataset yang lebih baik. Pengambilan gambar dilakukan dari berbagai sudut dan kondisi pencahayaan yang berbeda guna meningkatkan akurasi model dalam mengenali perbedaan kematangan buah kopi.

2. Pengolahan Data (Reprocessing)

Setelah data dikumpulkan, tahap pengolahan data dilakukan untuk membersihkan dan menyesuaikan gambar agar siap digunakan dalam proses pelatihan model. Pengolahan mencakup perubahan ukuran gambar, normalisasi warna, serta peningkatan kualitas gambar menggunakan teknik augmentasi data untuk meningkatkan variasi dan ketahanan model terhadap perubahan lingkungan.

3. Labelling

Labelling dilakukan dengan memberi anotasi pada setiap gambar dalam dataset untuk mengidentifikasi apakah buah kopi berada dalam kondisi matang, mentah, atau busuk. Proses ini sangat penting karena menentukan kualitas hasil deteksi model YOLOv5. Label dibuat menggunakan perangkat lunak anotasi seperti Roboflow untuk menandai bagian-bagian gambar yang relevan secara efisien dan memastikan kualitas anotasi yang optimal.

4. Data Split

Setelah proses labelling selesai, dataset dibagi menjadi tiga bagian utama: data pelatihan (train data), data validasi (validation data), dan data uji (test data). Umumnya, pembagian ini dilakukan dengan rasio 70:20:10 untuk memastikan model dapat belajar dari cukup banyak data sekaligus diuji dengan data yang belum pernah dilihat sebelumnya.

5. Modelling dan Training Data

Model YOLOv5 dilatih menggunakan dataset yang telah disiapkan. Proses pelatihan melibatkan beberapa parameter penting seperti jumlah epoch, batch size, dan learning rate yang disesuaikan untuk mendapatkan hasil optimal. Pelatihan dilakukan pada perangkat dengan GPU untuk mempercepat proses dan meningkatkan akurasi model dalam mendeteksi kematangan buah kopi.

6. Hasil dan Pengujian Sistem

Setelah model dilatih, pengujian dilakukan untuk mengevaluasi kinerjanya dalam kondisi nyata. Pengujian mencakup uji akurasi menggunakan confusion matrix, serta uji performa dalam lingkungan pertanian untuk memastikan sistem dapat bekerja secara real-time. Model yang telah diuji kemudian diimplementasikan pada Raspberry Pi untuk mendeteksi buah kopi dan mengontrol motor servo dalam proses pemilahan otomatis.

Confusion matrix adalah metode evaluasi yang membandingkan hasil prediksi model dengan nilai aktual untuk mengukur performanya. Dalam binary classification, confusion matrix berbentuk matriks 2x2 yang terdiri dari True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN). Untuk multi-class classification, matriks diperluas menjadi NxN untuk mencakup semua kemungkinan prediksi. Berbagai metrik seperti akurasi, presisi, recall, dan F1-score dihitung berdasarkan confusion matrix untuk memberikan gambaran kinerja model secara menyeluruh (Markoulidakis et al. 2021). Berikut adalah penjelasan dan rumus dari metrik evaluasi tersebut:

1. Akurasi (*Accuracy*)

Akurasi mengukur sejauh mana model dapat mengklasifikasikan data dengan benar. Akurasi merupakan rasio prediksi benar dengan keseluruhan data (Suci Amaliah, Nusrang, and Aswi 2022).

Rumus Akurasi:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2. Presisi (*Precision*)

Presisi mengukur tingkat keakuratan antara data positif dan hasil prediksi yang diberikan oleh model. Precision adalah ukuran ketepatan antara respons sistem dengan informasi yang diinginkan oleh pengguna (Hidayah 2024).

Rumus Presisi:

$$Precision = \frac{TP}{TP + FP}$$

3. Recall (True Positive Rate)

Recall adalah tingkat jumlah banyak dan sedikitnya kesesuaian informasi yang didapat dari hasil penelitian (Satria, Adikara, and Wihandika 2022). Recall sangat berguna ketika kita ingin memastikan bahwa model dapat mengidentifikasi sebanyak mungkin kasus positif.

Rumus *Recall*:

$$Recall = \frac{TP}{TP + FN}$$

4. F1-Score

F1-Score adalah metrik yang menggabungkan presisi dan recall dalam satu nilai, yang memberikan gambaran seimbang tentang kinerja model. F1-Score berguna ketika dataset memiliki jumlah false negatif dan false positif yang mendekati, karena F1-Score memperhatikan keseimbangan antara keduanya.

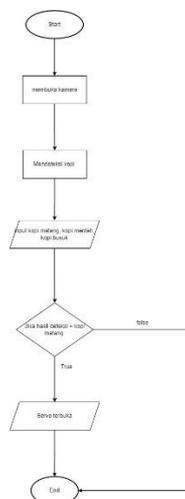
Rumus *F1-Score*:

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

atau dapat ditulis sebagai:

$$F1 - Score = \frac{2TP}{2TP + FP + FN}$$

Flowchart



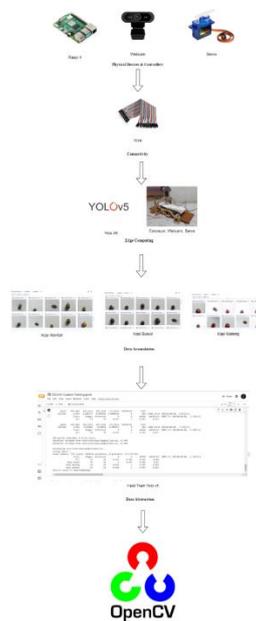
Gambar 1. Flowchart Sistem

Flowchart di atas adalah sistem berbasis Raspberry Pi untuk identifikasi tingkat kematangan buah kopi. Saat sistem dihidupkan, kamera mulai mengambil gambar buah kopi. Gambar ini kemudian diproses oleh model YOLOv5 yang telah dilatih untuk mengidentifikasi tingkat kematangan buah kopi. Model ini dapat membedakan antara buah kopi yang matang, mentah, dan busuk. Servo motor kemudian digunakan untuk memisahkan buah yang sudah matang.

Dengan implementasi ini, kami berharap dapat meningkatkan efisiensi dalam proses penggolongan kematangan buah kopi. Selain itu, sistem ini juga dapat membantu petani kopi dalam memantau dan mengelola panen mereka dengan lebih baik.

Desain Sistem

Sistem ini dirancang untuk mendeteksi tingkat kematangan buah kopi secara otomatis menggunakan algoritma YOLOv5 dan OpenCV. Berikut adalah tahapan utama dalam desain sistem:



Gambar 2. Desain Sistem

Physical Devices & Controllers

Sistem ini menggunakan beberapa perangkat keras utama untuk menjalankan proses deteksi, yaitu:

- Raspberry Pi 4 sebagai unit pemrosesan utama yang mengontrol keseluruhan sistem.
- Webcam yang digunakan untuk menangkap gambar biji kopi sebagai dataset untuk pelatihan YOLOv5.
- Servo Motor yang berfungsi sebagai aktuator untuk memisahkan kopi matang, mentah, dan busuk setelah diklasifikasikan.

Connectivity

Perangkat keras dihubungkan menggunakan kabel dan jalur komunikasi yang memastikan data dari webcam dapat diproses oleh Raspberry Pi. Koneksi ini juga memungkinkan pengendalian servo motor untuk mengatur pergerakan conveyor dan pemisahan biji kopi.

Edge Computing (YOLOv5 Implementation)

Model YOLOv5 digunakan untuk mendeteksi dan mengklasifikasikan biji kopi berdasarkan tingkat kematangan. Proses ini dilakukan dalam dua tahap:

- Akuisisi Gambar: Webcam mengambil gambar biji kopi yang berada di conveyor.
- Deteksi Objek: YOLOv5 memproses gambar untuk mengenali dan mengklasifikasikan biji kopi sebagai "Kopi Mentah", "Kopi Matang", atau "Kopi Busuk".

Data Accumulation

Gambar biji kopi yang diperoleh dikategorikan ke dalam tiga kelas utama:

- Kopi Mentah: Biji kopi yang masih hijau dan belum matang.
- Kopi Busuk: Biji kopi yang mengalami pembusukan atau kerusakan.
- Kopi Matang: Biji kopi berwarna merah yang siap untuk diproses lebih lanjut.

Dataset ini digunakan untuk melatih model YOLOv5 agar dapat mengenali perbedaan tingkat kematangan dengan lebih akurat.

Data Abstraction (Training YOLOv5)

Setelah dataset dikumpulkan dan dilabeli, model YOLOv5 dilatih menggunakan Google Colab. Proses pelatihan ini mencakup:

- Preprocessing Data: Data dibersihkan dan diaugmentasi untuk meningkatkan keakuratan deteksi.

- Pelatihan Model: Model YOLOv5 dilatih dengan parameter yang dioptimalkan untuk mendeteksi biji kopi secara real-time.
- Evaluasi Model: Hasil pelatihan dievaluasi dengan menggunakan metrik seperti mAP (Mean Average Precision) dan confusion matrix.

Data Implementation (OpenCV Integration)

Setelah model YOLOv5 dilatih, hasil deteksi diintegrasikan dengan OpenCV untuk memproses gambar secara langsung dari webcam. OpenCV digunakan untuk:

- Pengolahan Citra: Memperbaiki kualitas gambar sebelum dikirim ke model YOLOv5.
- Deteksi Real-Time: Menganalisis dan menampilkan hasil deteksi pada tampilan sistem.
- Kontrol Aktuator: Menggunakan hasil deteksi untuk menggerakkan servo motor agar memisahkan biji kopi berdasarkan tingkat kematangannya.

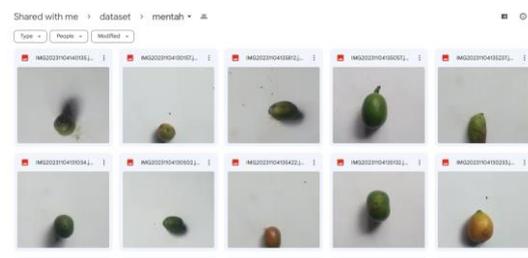
4. HASIL DAN PEMBAHASAN

Dataset Buah Kopi

Dataset yang digunakan dalam penelitian ini terdiri dari gambar buah kopi dalam tiga kondisi kematangan, yaitu mentah, matang, dan busuk. Setiap kondisi direpresentasikan oleh serangkaian gambar dengan variasi warna, ukuran, dan tekstur buah kopi. Dataset ini digunakan sebagai data pelatihan untuk melatih algoritma YOLOv5, memastikan model dapat mengenali dan membedakan kondisi buah kopi dengan akurasi tinggi. Berikut adalah deskripsi dataset yang digunakan.

a. Kopi Mentah

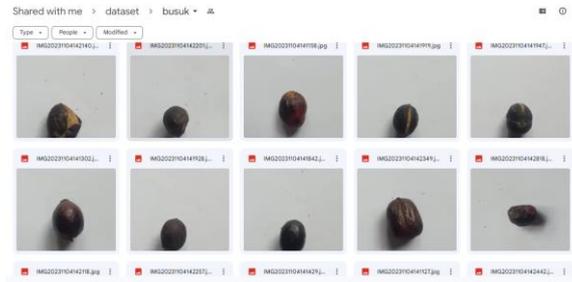
Gambar buah kopi mentah menunjukkan karakteristik warna hijau atau kuning yang khas. Variasi ini membantu model YOLOv5 untuk mempelajari ciri-ciri visual buah kopi mentah dengan lebih baik.



Gambar 3. Dataset Kopi Mentah

b. Kopi Busuk

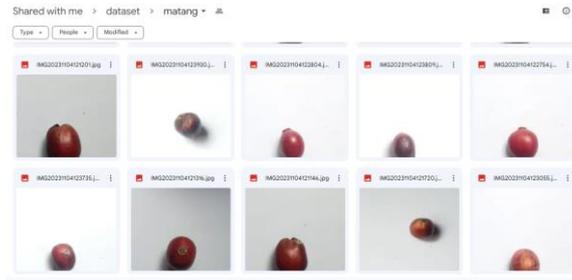
Gambar buah kopi busuk menunjukkan warna cenderung hitam dan tekstur yang tidak seragam. Dataset ini dirancang untuk memastikan model dapat membedakan buah kopi busuk dari kondisi lainnya.



Gambar 4. Dataset Kopi Busuk

c. Kopi Matang

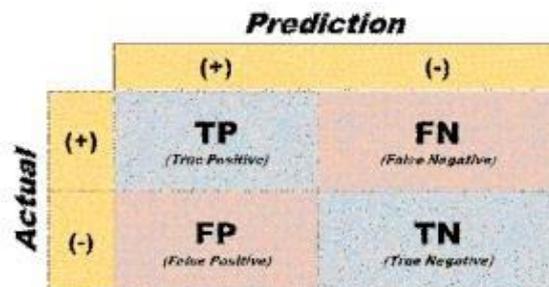
Gambar buah kopi matang menunjukkan warna merah yang khas. Variasi pencahayaan dan sudut pengambilan gambar digunakan untuk meningkatkan generalisasi model.



Gambar 5. Dataset Kopi Matang

d. Evaluasi Model Menggunakan Confusion Matrix

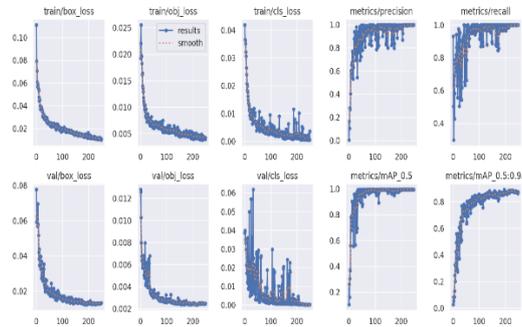
Evaluasi kinerja model dilakukan menggunakan Confusion Matrix, yang terdiri dari empat komponen utama: True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN). Berdasarkan Confusion Matrix, beberapa metrik evaluasi dihitung, yaitu Akurasi, Recall, Precision, dan F1-Score.



Gambar 6. Rumus Confusion Matrix

e. Akurasi

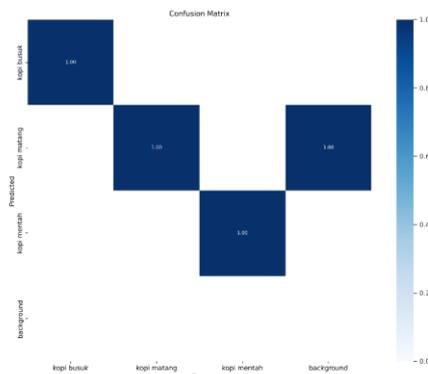
Akurasi juga dapat diinterpretasikan dari tingkat kehilangan (loss) deteksi model. Dalam sistem ini, tingkat kehilangan (loss) dari berbagai faktor seperti bounding box, object loss, dll., hanya mencapai 0.06 atau 6% potensi kegagalan dalam sistem deteksi. Di bawah ini adalah gambaran grafik kehilangan objek deteksi dari berbagai faktor.



Gambar 7. Grafik Train Data

f. Precision

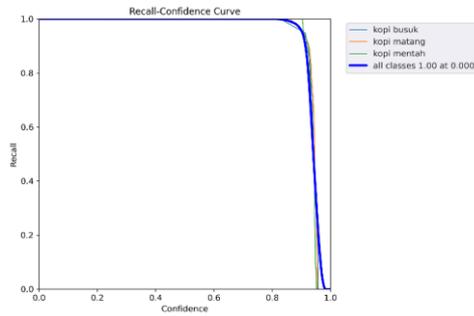
Precision mengukur seberapa akurat prediksi positif model. Berikut hasil precision dari Confusion Matrix



Gambar 8. Confusion Matrix Class

g. Recall

Berdasarkan hasil pelatihan data, diperoleh nilai Recall rata-rata antara 0.8 hingga 1.0. Hal ini menunjukkan bahwa setiap objek yang dapat dideteksi lebih dari satu akan sesuai dengan deskripsi objek yang sebenarnya. Berikut adalah gambaran grafik nilai Recall dari deteksi objek.



Gambar 9. Nilai Grafik Recall

Hasil Uji Coba Sistem Deteksi Buah Kopi

Pengujian sistem dilakukan secara real-time menggunakan Raspberry Pi, webcam, dan servo motor. Hasil uji coba menunjukkan bahwa sistem dapat mendeteksi dan mengklasifikasikan buah kopi dengan akurasi rata-rata 90%. Berikut adalah ringkasan hasil uji coba.

Tabel 1. Hasil Uji Coba Sistem Deteksi Buah Kopi

No.	Gambar	Perangkat	Target Hasil	Hasil Deteksi	Tingkat Akurasi
1.		Raspi	Buah kopi mentah	Buah kopi mentah	0.90
2.		Raspi	Buah kopi matang	Buah kopi matang	0.90
3.		Raspi	Buah kopi busuk	Buah kopi busuk	0.90

Berdasarkan hasil data uji coba diatas akurasi dari *object detection* berada pada rata rata 0.90 atau 90 persen dari berbagai kondisi lingkungan. Sehingga hasil *object detection* sudah baik dan sesuai. Selain output yang diberikan adalah *object detection* terdapat integrasi dengan sistem *Internet of Things (IoT)*.

Hasil Pelatihan Model

Proses pelatihan model dilakukan dengan dua tahap, yaitu 150 epoch dan 250 epoch. Hasil pelatihan menunjukkan peningkatan akurasi deteksi seiring dengan peningkatan jumlah epoch.

a. Pelatihan 150 Epoch

Pada tahap ini, hasil deteksi masih belum akurat karena model belum sepenuhnya mengenali objek di sekitarnya. Beberapa objek non-target terdeteksi sebagai false positive.

b. Pelatihan 250 Epoch

Setelah pelatihan ditingkatkan menjadi 250 epoch, model menunjukkan peningkatan signifikan dalam akurasi deteksi. Model dapat membedakan buah kopi matang, mentah, dan busuk dengan lebih baik.

No.	Gambar	Epoch	Hasil
1		150x	Hasil deteksi yang didapatkan masih belum akurat dikarenakan benda disekitarnya dapat terdeteksi juga
2		250x	Dengan ditrain sebanyak 250x menghasilkan data yang akurat.

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan sistem deteksi tingkat kematangan buah kopi menggunakan YOLOv5 yang terintegrasi dengan Raspberry Pi. Sistem menunjukkan akurasi tinggi dengan kemampuan deteksi mencapai 90%, serta tingkat kehilangan yang rendah (0.06), menunjukkan kemampuan model dalam mengenali perbedaan visual pada buah kopi dengan baik. Efisiensi real-time tercapai berkat penggunaan Raspberry Pi yang memungkinkan sistem beroperasi dengan latensi rendah, cocok untuk aplikasi di lapangan. Integrasi IoT yang efektif, termasuk penggunaan webcam dan motor servo untuk otomatisasi pemisahan buah kopi, meningkatkan efisiensi dan mengurangi ketergantungan pada tenaga manusia. Pengujian menunjukkan kemampuan adaptasi yang baik terhadap berbagai kondisi lingkungan, membuktikan keandalan model YOLOv5 dalam situasi nyata.

Meskipun sistem ini berhasil meningkatkan efisiensi proses sortir dan pemantauan panen, beberapa saran pengembangan adalah peningkatan akurasi deteksi dengan dataset yang lebih besar dan variasi lingkungan, serta optimasi proses pengolahan gambar dan algoritma untuk mempercepat sistem. Penelitian ini membuka peluang untuk diterapkan dalam skenario lebih kompleks, dengan perbaikan lebih lanjut pada variasi data dan kondisi operasional.

DAFTAR REFERENSI

- Adiwijaya, N. O., Romadhon, H. I., Putra, J. A., & Kuswanto, D. P. (2022). The quality of coffee bean classification system based on color by using K-nearest neighbor method. *Journal of Physics: Conference Series*, 2157(1), 012034. <https://doi.org/10.1088/1742-6596/2157/1/012034>
- Ardra Prakash, D. (2024). A comparative analysis of object identification labelling platforms: Basketball perspective. *International Journal of Media and Networks*, 2(3), 01–04. <https://doi.org/10.33140/IJMN.02.03.02>
- Damayanti, I. D., & Michael, A. (2024). Determination of coffee fruit maturity level using image histogram and K-nearest neighbor. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 18(2), 0785–0796. <https://doi.org/10.30598/barekengvol18iss2pp0785-0796>
- de Figueiredo Tavares, M. P., & Mourad, A. L. (2020). Coffee beverage preparation by different methods from an environmental perspective. *The International Journal of Life Cycle Assessment*, 25(7), 1356–1367. <https://doi.org/10.1007/s11367-019-01719-2>
- Flores-Calero, M., Astudillo, C. A., Guevara, D., Maza, J., Lita, B. S., Defaz, B., Ante, J. S., Zabala-Blanco, D., & Armingol Moreno, J. M. (2024). Traffic sign detection and recognition using YOLO object detection algorithm: A systematic review. *Mathematics*, 12(2), 297. <https://doi.org/10.3390/math12020297>

- Gope, H. L., Fukai, H., Ruhad, F. M., & Barman, S. (2024). Comparative analysis of YOLO models for green coffee bean detection and defect classification. *Scientific Reports*, 14(1), 28946. <https://doi.org/10.1038/s41598-024-78598-7>
- Gupta, A. K., Seal, A., Prasad, M., & Khanna, P. (2020). Salient object detection techniques in computer vision—a survey. *Entropy*, 22(10), 1174. <https://doi.org/10.3390/e22101174>
- Hayati, N. J., Singasatia, D., Muttaqin, M. R., Teknik Informatika, Sekolah Tinggi, & Teknologi Wastukencana. (2023). Object tracking menggunakan algoritma You Only Look Once (YOLO)v8 untuk menghitung kendaraan. *KOMPUTA: Jurnal Ilmiah Komputer dan Informatika*, 12(2).
- Hidayah, N. (2024). Implementasi algoritma multinomial naïve bayes, TF-IDF dan confusion matrix dalam pengklasifikasian saran monitoring dan evaluasi mahasiswa terhadap dosen teknik informatika Universitas Dayanu Ikhsanuddin. *Jurnal Akademik Pendidikan Matematika*, 10(1). <https://doi.org/10.55340/japm.v10i1.1491>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Laghari, A. A., Wu, K., Laghari, R. A., Ali, M., & Khan, A. A. (2022). RETRACTED ARTICLE: A review and state of art of Internet of Things (IoT). *Archives of Computational Methods in Engineering*, 29(3), 1395–1413. <https://doi.org/10.1007/s11831-021-09622-6>
- Liu, C., Lin, W., Feng, Y., Guo, Z., & Xie, Z. (2023). ATC-YOLOv5: Fruit appearance quality classification algorithm based on the improved YOLOv5 model for passion fruits. *Mathematics*, 11(16), 3615. <https://doi.org/10.3390/math11163615>
- Mansour, M., Gamal, A., Ahmed, A. I., Said, L. A., Elbaz, A., Herencsar, N., & Soltan, A. (2023). Internet of things: A comprehensive overview on protocols, architectures, technologies, simulation tools, and future directions. *Energies*, 16(8), 3465. <https://doi.org/10.3390/en16083465>
- Markoulidakis, I., Kopsiaftis, G., Rallis, I., & Georgoulas, I. (2021). Multi-class confusion matrix reduction method and its application on Net Promoter Score classification problem. In *Proceedings of the 14th Pervasive Technologies Related to Assistive Environments Conference* (pp. 412–419). New York, NY, USA: ACM.
- Phan, Q.-H., Nguyen, V.-T., Lien, C.-H., Duong, T.-P., Hou, M. T.-K., & Le, N.-B. (2023). Classification of tomato fruit using YOLOv5 and convolutional neural network models. *Plants*, 12(4), 790. <https://doi.org/10.3390/plants12040790>
- Ragab, M. G., Abdulkadir, S. J., Muneer, A., Alqushaibi, A., Sumiea, E. H., Qureshi, R., Al-Selwi, S. M., & Alhussian, H. (2024). A comprehensive systematic review of YOLO for medical object detection (2018 to 2023). *IEEE Access*, 12, 57815–57836. <https://doi.org/10.1109/ACCESS.2024.3386826>
- Ridam Lokhande, Y., Nakhale, N., Petkar, N., Sheikh, T., Janwe, N., & Lichode, R. V. (2023). Object detection. *International Journal of Advanced Research in Science, Communication and Technology*, 316–320. <https://doi.org/10.48175/IJARSCT-14042>

- Satria, G. J., Adikara, P. P., & Wihandika, R. C. (2022). Klasifikasi pertanyaan COVID-19 bahasa Indonesia menggunakan Naïve Bayes. Vol. 6.
- Suci Amaliah, M., Nusrang, M., & Aswi, A. (2022). Penerapan metode random forest untuk klasifikasi varian minuman kopi di Kedai Kopi Konijiwa Bantaeng. *VARIANSI: Journal of Statistics and Its Application on Teaching and Research*, 4(3), 121–127. <https://doi.org/10.35580/variansiunm31>
- Tamayo-Monsalve, M. A., Mercado-Ruiz, E., Villa-Pulgarin, J. P., Bravo-Ortiz, M. A., Arteaga-Arteaga, H. B., Mora-Rubio, A., Alzate-Grisales, J. A., Arias-Garzon, D., Romero-Cano, V., Orozco-Arias, S., Gustavo-Osorio, G., & Tabares-Soto, R. (2022). Coffee maturity classification using convolutional neural networks and transfer learning. *IEEE Access*, 10, 42971–42982. <https://doi.org/10.1109/ACCESS.2022.3166515>
- Taye, M. M. (2023). Understanding of machine learning with deep learning: Architectures, workflow, applications and future directions. *Computers*, 12(5), 91. <https://doi.org/10.3390/computers12050091>
- Zhang, H., & Speakman, J. R. (2024). The complexity of coffee and its impact on metabolism. *Journal of Endocrinology*, 262(3). <https://doi.org/10.1530/JOE-24-0075>