

Implementasi Yolov11 pada Sistem Deteksi Cacat Biji Kopi Pasca-Roasting

Dwi Octavia Ramadhani Rahman ^{*1}, Andi Tenriawaru ², Gunawan ³

^{1,2,3} Jurusan Ilmu Komputer, Universitas Halu Oleo, Indonesia

¹ dwioctviaa@gmail.com, ² andi.tenriawaru@uho.ac.id, ³ gunawan@uho.ac.id

Diajukan: 7/5/2026 | Direvisi: 26/5/2026 | Diterima: 26/5/2026 | Diterbitkan: 30/6/2026

Abstrak

Kualitas biji kopi pasca-roasting merupakan salah satu faktor penting dalam menentukan mutu produk kopi. Proses identifikasi dan sortasi cacat biji kopi masih umumnya dilakukan secara manual sehingga berpotensi menimbulkan ketidakkonsistenan dan kesalahan pengamatan. Penelitian ini bertujuan untuk mengimplementasikan metode You Only Look Once versi 11 (YOLOv11) berbasis Convolutional Neural Network (CNN) dalam sistem deteksi dan klasifikasi cacat biji kopi pasca-roasting secara otomatis. Tahapan penelitian meliputi pengumpulan data citra, preprocessing, pelabelan objek, pembagian dataset menjadi data latih, validasi, dan uji, serta pelatihan model menggunakan beberapa konfigurasi *hyperparameter*. Pengujian dilakukan dengan variasi data splitting, optimizer, learning rate, dan *confidence threshold* untuk memperoleh performa model yang optimal. Dataset yang digunakan terdiri dari 694 citra, meliputi 290 citra primer dan 404 citra hasil augmentasi. Hasil penelitian menunjukkan bahwa skenario pembagian dataset 90:5:5 menghasilkan nilai *mAP@50* tertinggi sebesar 0.948. Namun, konfigurasi 70:20:10 dipilih sebagai konfigurasi yang lebih stabil dan representatif karena memberikan keseimbangan yang lebih baik antara data pelatihan, validasi, dan pengujian. Penggunaan *optimizer* SGD dengan *learning rate* 0.01 serta *confidence threshold* 0.5 menghasilkan performa deteksi yang lebih stabil. Model yang dihasilkan memperoleh nilai Mean Average Precision (*mAP@50*) sebesar 0.946 dan mampu mendeteksi serta mengklasifikasikan cacat biji kopi secara otomatis dengan baik pada berbagai kondisi pengujian.

Kata Kunci: CNN, deteksi cacat biji kopi, deteksi objek, kualitas kopi pasca-roasting, yolov11.

Abstract

Coffee bean quality after roasting is one of the important factors in determining the quality of coffee products. The process of identifying and sorting defective coffee beans is generally still performed manually, which may lead to inconsistencies and observation errors. This study aims to implement the You Only Look Once version 11 (YOLOv11) method based on Convolutional Neural Network (CNN) in an automatic post-roasting coffee bean defect detection and classification system. The research stages include image data collection, preprocessing, object labeling, dataset splitting into training, validation, and testing data, as well as model training using several hyperparameter configurations. Testing was conducted using variations in data splitting, optimizer, learning rate, and confidence threshold to obtain optimal model performance. The dataset used consisted of 694 images, including 290 primary images and 404 augmented images. The results showed that the 90:5:5 dataset splitting scenario achieved the highest *mAP@50* value of 0.948. However, the 70:20:10 configuration was selected as a more stable and representative configuration because it provided a better balance between training, validation, and testing data. The use of the SGD optimizer with a learning rate of 0.01 and a confidence threshold of 0.5 produced more stable detection performance. The resulting model achieved a Mean Average Precision (*mAP@50*) value of 0.946 and was able to automatically detect and classify coffee bean defects effectively under various testing conditions.

Keywords: CNN, Coffee Bean Defect Detection, Object Detection, Post-Roasting Coffee Quality, YOLOv11.



This work is an open access article and licensed under a Creative Commons Attribution-NonCommercial ShareAlike 4.0 International (CC BY-NC-SA 4.0). Copyright (C) Authors.

1. PENDAHULUAN

Perkembangan industri kopi di era modern ditandai dengan meningkatnya jumlah kedai kopi yang tidak hanya berperan sebagai penyedia minuman, tetapi juga sebagai pelaku pengolahan kopi secara mandiri. Tren konsumsi kopi berkualitas mendorong pelaku usaha, termasuk skala kecil dan menengah, untuk melakukan proses *roasting* sendiri guna mempertahankan karakter rasa dan identitas produk. Kondisi ini menjadikan kualitas biji kopi sebagai faktor krusial dalam

menentukan mutu produk akhir sehingga pengendalian kualitas pada setiap tahapan pengolahan menjadi semakin penting.

Data Dinas Perkebunan dan Hortikultura Sulawesi Tenggara menunjukkan bahwa produksi kopi robusta dalam tiga tahun terakhir relatif stabil, yaitu sebesar 2.799 ton pada tahun 2023, 2.602 ton pada tahun 2024, dan meningkat menjadi 2.612 ton pada tahun 2025. Kondisi ini menunjukkan bahwa ketersediaan bahan baku kopi cukup melimpah dan mendukung perkembangan industri pengolahan kopi di tingkat lokal.

Proses *roasting* merupakan tahapan penting yang menentukan aroma, rasa, dan warna biji kopi, namun tidak selalu menghasilkan kualitas yang seragam. Berbagai cacat seperti *underdeveloped*, *scorching*, dan *broken* masih sering ditemukan dan berdampak pada mutu produk. Tingkat kecacatan biji kopi *roasted* pada skala UMKM dapat mencapai 12–15% per batch[1]. Proses sortasi manual cenderung bergantung pada ketelitian manusia sehingga berpotensi menimbulkan kesalahan dan inkonsistensi hasil [2]. Kecacatan biji kopi seperti biji pecah juga dilaporkan sebagai defect dominan yang dipengaruhi oleh kelemahan proses sortasi [3].

Perkembangan teknologi pengolahan citra dan kecerdasan buatan memberikan peluang untuk mengatasi permasalahan tersebut. Citra digital merupakan representasi visual dalam bentuk piksel yang dapat diolah secara komputasi [4]. Pengolahan citra digital bertujuan meningkatkan kualitas visual sehingga informasi dapat dianalisis dengan lebih baik [5]. Teknik segmentasi digunakan untuk mengekstraksi informasi penting dari citra berdasarkan keseragaman karakteristik piksel [6]. Tahap *preprocessing* berperan dalam meningkatkan kualitas data sebelum pelatihan model dilakukan[7]. Teknik *augmentasi* digunakan untuk menambah variasi data sehingga meningkatkan kemampuan generalisasi model[8].

Pendekatan *deep learning* mampu mengekstraksi fitur secara otomatis dari data citra tanpa memerlukan perancangan fitur manual [9]. CNN merupakan arsitektur yang banyak digunakan dalam analisis citra karena mampu mengenali pola visual kompleks[10]. CNN mampu mempelajari karakteristik visual secara bertahap sehingga meningkatkan akurasi klasifikasi [11]. Model CNN juga terbukti efektif dalam menangani variasi objek dengan karakteristik visual yang beragam [12].

Perkembangan deteksi objek berbasis *deep learning* menunjukkan peningkatan performa yang signifikan dibandingkan metode konvensional [13]. Metode berbasis CNN mampu menghasilkan akurasi dan kecepatan yang lebih baik dalam berbagai skenario deteksi objek [14]. Pendekatan modern juga terbukti lebih stabil terhadap variasi kondisi lingkungan dibandingkan metode tradisional [15].

Algoritma *You Only Look Once* (YOLO) merupakan salah satu metode deteksi objek yang mampu melakukan lokalisasi dan klasifikasi dalam satu proses prediksi [16]. Model YOLO memiliki keunggulan dalam kecepatan dan efisiensi komputasi dibandingkan metode berbasis region proposal. Penelitian menunjukkan bahwa keluarga YOLO mengalami peningkatan performa hingga 10–18% dibandingkan generasi sebelumnya [17]. YOLOv11 sebagai pengembangan terbaru menawarkan peningkatan stabilitas fitur dan efisiensi model [18]. Model YOLO yang ringan juga mendukung implementasi sistem real-time pada perangkat dengan sumber daya terbatas [19].

Pengaturan *hyperparameter* berperan penting dalam menentukan performa model deteksi [20]. Kombinasi *hyperparameter* dan *augmentasi* data mampu meningkatkan akurasi pada kondisi kompleks seperti variasi pencahayaan[21]. Evaluasi model deteksi objek umumnya menggunakan metrik *precision*, *recall*, dan *mean Average Precision (mAP)* untuk mengukur kinerja secara komprehensif.


Penelitian sebelumnya menunjukkan bahwa metode *deep learning* dan keluarga YOLO telah banyak digunakan dalam deteksi kualitas dan cacat biji kopi. Penelitian pada [22] menerapkan YOLOv8 untuk klasifikasi cacat *green coffeebean* secara real-time dan memperoleh performa

yang tinggi, namun pengujian masih dilakukan pada kondisi objek yang relatif terkontrol. Studi pada [23] juga mengembangkan improved YOLOv8 untuk meningkatkan deteksi cacat berukuran kecil pada *green coffee bean* dengan nilai *mAP* yang tinggi, tetapi penelitian tersebut masih difokuskan pada kondisi visual yang lebih seragam dan belum membahas kompleksitas *overlapping* antarobjek dalam satu citra. Selain itu, sebagian besar penelitian terdahulu masih berfokus pada *green bean* atau klasifikasi citra tunggal dengan latar belakang yang bersih sehingga belum sepenuhnya merepresentasikan kondisi nyata pada proses sortasi *roasted coffee beans*.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengimplementasikan model YOLOv11 berbasis *Convolutional Neural Network* (CNN) dalam mendeteksi dan mengklasifikasikan cacat biji kopi pasca-*roasting* secara otomatis. Kontribusi penelitian ini terletak pada pengembangan sistem deteksi yang mampu mengenali beberapa jenis cacat biji kopi pada kondisi objek yang kompleks, seperti tumpang tindih, variasi pencahayaan, dan perbedaan sudut pengambilan gambar. Kebaruan penelitian ini terletak pada penerapan YOLOv11 untuk mendeteksi cacat biji kopi pasca-*roasting* pada kondisi objek yang kompleks, seperti ukuran objek yang kecil, saling tumpang tindih, serta kemiripan karakteristik visual antar kelas cacat pada lingkungan nyata. Penelitian ini juga mengevaluasi pengaruh variasi *hyperparameter* dan kondisi pengujian terhadap kemampuan generalisasi model.

2. METODE PENELITIAN

Metode penelitian disusun secara sistematis sehingga setiap tahapan terlaksana secara terstruktur dan saling berkaitan. Metode penelitian yang digunakan dalam studi ini adalah pendekatan eksperimen dengan membangun sistem deteksi cacat biji kopi berbasis YOLOv11. Seluruh langkah penelitian mengikuti kebutuhan pengembangan dan evaluasi sistem yang telah diimplementasikan. Alur lengkap tahapan penelitian ditampilkan pada Gambar 1.



Gambar 1. Metode Penelitian

2.1. Pengumpulan Data

Pengumpulan data dilakukan melalui studi pustaka, observasi, dan wawancara di Coffee Mujur & Roaster serta Coffee Mondae. Observasi digunakan untuk memahami kondisi biji kopi dan jenis cacat yang muncul, sedangkan wawancara dengan praktisi kopi menghasilkan empat kelas data, yaitu *Normal*, *Underdeveloped*, *Scorching*, dan *Broken*.

2.2. Preprocessing Data

Preprocessing dilakukan menggunakan Roboflow yang meliputi anotasi *bounding box*, penyeragaman orientasi (*auto-orient*), perubahan ukuran citra menjadi 640×640 piksel, serta normalisasi. Augmentasi data diterapkan melalui *flip*, rotasi, *crop*, *shear*, serta penyesuaian pencahayaan untuk meningkatkan variasi dataset. Pembagian dataset dilakukan menjadi data latih, validasi, dan uji dengan rasio awal 70:20:10, serta beberapa skenario variasi yang disajikan pada tabel skenario *splitting data*.

Proses augmentasi dilakukan setelah pembagian dataset untuk mencegah terjadinya data leakage antara data latih, validasi, dan data uji. Augmentasi hanya diterapkan pada data latih sehingga model tidak mempelajari pola identik pada data evaluasi. Pendekatan ini bertujuan meningkatkan variasi visual data serta membantu model memperoleh kemampuan generalisasi yang lebih baik terhadap data baru. Meskipun demikian, penggunaan augmentasi dalam jumlah besar tetap berpotensi menimbulkan bias sintetis apabila digunakan secara berlebihan. Oleh karena itu, evaluasi model dilakukan menggunakan data validasi dan pengujian yang terpisah untuk meminimalkan risiko *overfitting*.

2.3. Pelatihan Model

Model yang digunakan adalah YOLOv11n berbasis *transfer learning* dengan bobot *pretrained*. Pelatihan dilakukan menggunakan GPU di Google Colab dengan penyesuaian beberapa *hyperparameter* seperti *learning rate*, *optimizer*, *epoch*, dan *batch size*. Rincian konfigurasi parameter pelatihan disajikan pada tabel skenario *hyperparameter*.

2.4. Skenario Pengujian Model

Pengujian dilakukan melalui beberapa skenario untuk memperoleh konfigurasi terbaik. Variasi *data splitting* diuji dalam lima skenario untuk menganalisis pengaruh proporsi data latih terhadap performa model yang disajikan pada Tabel 1.

Tabel 1. Skenario Pengujian Model

Skenario	<i>Train</i>	<i>Valid</i>	<i>Test</i>
A	50%	30%	20%
B	60%	30%	10%
C	70%	20%	10%
D	80%	10%	10%
E	90%	5%	5%

Selanjutnya, pengujian *hyperparameter* dilakukan menggunakan dua *optimizer* (SGD dan Adam) dengan variasi *learning rate*. Pengujian juga mencakup variasi nilai *confidence threshold* pada rentang 0.1 hingga 0.9 untuk menganalisis sensitivitas deteksi. Skenario *hyperparameter* disajikan pada Tabel 2.

Tabel 2. Pengujian *Hyperparameter*

Skenario	<i>Optimizer</i>	<i>lr</i>	<i>Epoch</i>	<i>Patience</i>
A	SGD	0.1	100	50
B	SGD	0.01	100	50
C	SGD	0.001	100	50
D	SGD	0.0001	100	50
E	Adam	0.1	100	50
F	Adam	0.01	100	50
G	Adam	0.001	100	50
H	Adam	0.0001	100	50

Nilai *epoch* dan *patience* dibuat sama pada seluruh skenario pengujian untuk menjaga konsistensi proses pelatihan model. Penggunaan parameter yang beragam bertujuan agar perbandingan performa model lebih berfokus pada pengaruh variasi *optimizer* dan *learning rate*.


Parameter *patience* sebesar 50 digunakan untuk menghentikan proses pelatihan secara otomatis apabila tidak terjadi peningkatan performa model dalam sejumlah iterasi tertentu.

2.5. Evaluasi Model

Evaluasi model dilakukan menggunakan metrik *mean Average Precision* ($mAP@0.5:0.95$), *precision*, dan *recall* untuk menilai performa deteksi dan klasifikasi. Analisis *confusion matrix* digunakan untuk melihat distribusi kesalahan pada setiap kelas. Evaluasi ini bertujuan memastikan model mampu mengenali kategori cacat sekaligus menentukan lokasi objek secara akurat.

2.6. Perancangan Sistem

Perancangan sistem menggambarkan alur kerja aplikasi deteksi, mulai dari input citra hingga output hasil deteksi. Alur sistem secara keseluruhan disajikan pada gambar 2 perancangan sistem.



Gambar 2. Perancangan sistem

Gambar 2 menunjukkan alur kerja aplikasi deteksi cacat biji kopi berbasis YOLOv11. Proses dimulai ketika pengguna mengunggah citra biji kopi atau menggunakan fitur *real-time* melalui kamera sebagai data masukan sistem. Selanjutnya, model YOLOv11 melakukan proses deteksi dan klasifikasi terhadap setiap biji kopi ke dalam beberapa kategori, seperti *Normal*, *Scorching*, *Broken*, dan *Underdeveloped*. Hasil deteksi kemudian ditampilkan dalam bentuk *bounding box*, label kelas, serta ringkasan jumlah dan persentase setiap kategori untuk mendukung proses evaluasi kualitas biji kopi secara otomatis.

3. HASIL PENELITIAN DAN PEMBAHASAN

3.1. Hasil Pengumpulan Data

Dataset yang digunakan terdiri dari 694 citra biji kopi, meliputi 290 citra primer dan 404 citra hasil augmentasi. Meskipun jumlah citra primer relatif terbatas, setiap citra memuat banyak objek biji kopi dengan jumlah 50-200 objek per gambar sehingga total anotasi objek yang digunakan dalam pelatihan tetap cukup besar. Penggunaan transfer learning pada model YOLOv11n juga membantu model dalam mempelajari karakteristik objek secara efektif meskipun menggunakan

dataset terbatas. Seluruh data dianotasi menggunakan *bounding box* melalui *Roboflow* sesuai dengan empat kelas yang ditentukan.

Tahap *preprocessing* menghasilkan citra berukuran seragam 640×640 piksel serta variasi visual melalui augmentasi seperti rotasi, *flip*, dan penyesuaian pencahayaan. Proses ini meningkatkan keragaman data dan membantu model dalam mengenali objek pada berbagai kondisi lingkungan.

3.2. Hasil Pengujian Skenario Model

Pengujian skenario data *splitting* menunjukkan bahwa proporsi data latih berpengaruh terhadap performa model deteksi cacat biji kopi. Hasil pengujian pada Tabel 3 menunjukkan bahwa peningkatan jumlah data latih cenderung meningkatkan nilai *precision*, *recall*, dan *mAP*. Nilai terbaik diperoleh pada skenario E dengan pembagian data 90:5:5 yang menghasilkan *mAP@50* sebesar 0.948. Namun, skenario 70:20:10 dipilih sebagai konfigurasi yang lebih representatif dalam mengevaluasi kemampuan generalisasi model karena proporsi data validasi dan pengujian lebih memadai dibandingkan skenario 90:5:5. Pada skenario 90:5:5, jumlah data validasi dan pengujian yang sangat kecil berpotensi menghasilkan evaluasi performa yang kurang stabil dan meningkatkan risiko *overfitting*.

Meskipun skenario 90:5:5 menghasilkan nilai *mAP@50* yang lebih tinggi, proporsi data validasi dan pengujian yang terlalu kecil berpotensi menyebabkan evaluasi performa menjadi kurang stabil dan meningkatkan risiko *overfitting*. Kondisi tersebut dapat menyebabkan model terlalu menyesuaikan diri terhadap karakteristik data pelatihan sehingga performa yang diperoleh belum sepenuhnya merepresentasikan kemampuan model pada data baru. Oleh karena itu, konfigurasi 70:20:10 dipilih karena memberikan distribusi evaluasi yang lebih seimbang untuk menilai kemampuan generalisasi model.

Tabel 3. Hasil Pengujian *Splitting* Data

Skenario	<i>Precision</i>	<i>Recall</i>	<i>mAP@50</i>	<i>mAP@50-95</i>
A	0.854	0.862	0.916	0.767
B	0.869	0.865	0.924	0.772
C	0.874	0.881	0.933	0.800
D	0.883	0.885	0.937	0.774
E	0.878	0.908	0.948	0.810

Tabel 3 menunjukkan bahwa model mampu mencapai performa deteksi yang tinggi pada berbagai skenario pembagian data. Nilai *mAP@50* yang diperoleh menunjukkan bahwa model YOLOv11 mampu mengenali karakteristik visual setiap kelas cacat biji kopi dengan baik, termasuk pada kondisi objek yang saling berdekatan dan tumpang tindih. Hasil ini sejalan dengan penelitian [17] menyatakan bahwa keluarga YOLO memiliki peningkatan performa yang signifikan dalam deteksi objek berbasis citra. Peningkatan performa pada penelitian ini dipengaruhi oleh penggunaan augmentasi data, pengaturan *hyperparameter*, serta variasi kondisi pengujian yang membantu model mengenali objek secara lebih robust.

Penggunaan variasi kondisi pengujian seperti perbedaan pencahayaan, sudut pengambilan citra, jarak kamera, serta kondisi objek yang saling berdekatan dan tumpang tindih bertujuan untuk mengevaluasi kemampuan generalisasi model terhadap data baru. Hasil pengujian menunjukkan bahwa model tetap mampu mendeteksi objek pada berbagai kondisi lingkungan meskipun terjadi sedikit penurunan performa pada kondisi pencahayaan rendah dan *overlapping* yang tinggi. Hal ini menunjukkan bahwa model tidak hanya mempelajari pola spesifik pada data pelatihan, tetapi juga mampu beradaptasi terhadap variasi kondisi nyata.

Pengujian *hyperparameter* menunjukkan bahwa penggunaan *optimizer* berpengaruh signifikan terhadap performa model. Pengujian *hyperparameter* menunjukkan bahwa *optimizer* SGD dengan *learning rate* 0.01 menghasilkan performa terbaik dengan nilai *mAP@50* sebesar 0.946 serta keseimbangan *precision* dan *recall* yang baik. Hal ini menunjukkan bahwa metode optimasi adaptif lebih efektif dalam menangani kompleksitas visual pada data.


Tabel 4. Hasil Skenario *Hyperparameter*




Skenario	<i>Precision</i>	<i>Recall</i>	<i>mAP@50</i>	<i>mAP@50-95</i>
A	0.835	0.871	0.918	0.778
B	0.893	0.893	0.946	0.816
C	0.881	0.886	0.936	0.804
D	0.879	0.887	0.935	0.801
E	0.735	0.792	0.813	0.674
F	0.866	0.879	0.931	0.786
G	0.899	0.896	0.945	0.812
H	0.881	0.89	0.937	0.803


Pada *optimizer* Adam, performa model cenderung lebih konsisten pada beberapa variasi *learning rate* karena mekanisme pembaruan bobot yang bersifat adaptif. Nilai terbaik pada *optimizer* Adam diperoleh pada *learning rate* 0.001 dengan nilai *mAP@50* sebesar 0.945, namun performanya masih sedikit berada di bawah *optimizer* SGD. Hasil ini menunjukkan bahwa pemilihan *hyperparameter* yang tepat berperan penting dalam meningkatkan kemampuan model dalam mendeteksi objek dengan karakteristik visual yang beragam serta mengurangi kesalahan klasifikasi antar kelas.

Pengujian *confidence threshold* dilakukan pada rentang 0.1 hingga 0.9 untuk menganalisis sensitivitas model terhadap deteksi objek. Hasil pengujian menunjukkan bahwa nilai *threshold* 0.5 memberikan keseimbangan terbaik antara jumlah objek terdeteksi dan tingkat kesalahan klasifikasi. Nilai *threshold* yang terlalu rendah cenderung menghasilkan deteksi berlebih (*double detection*), sedangkan *threshold* yang terlalu tinggi menyebabkan sensitivitas model menurun sehingga beberapa objek gagal terdeteksi. Secara keseluruhan, model mampu bekerja dengan baik pada berbagai kondisi, termasuk variasi jarak, tumpang tindih objek, serta perbedaan pencahayaan.

Tabel 5. Hasil Pengujian Variasi Kondisi

Hasil Deteksi	Total Aktual Biji	Total Deteksi
	60	60

Hasil Deteksi	Total Aktual Biji	Total Deteksi
	60	59
	50	48
	15	15
	100	95
	150	148

Hasil Deteksi	Total Aktual Biji	Total Deteksi
	200	195


Pengujian pada berbagai kondisi menunjukkan bahwa pada *threshold* 0.5 model memberikan performa yang paling stabil dalam mendeteksi objek. Pada kondisi objek berjarak, seluruh objek berhasil terdeteksi dengan baik karena tidak adanya tumpang tindih sehingga fitur visual dapat dikenali secara jelas. Pada kondisi objek berdekatan, model masih mampu mendeteksi hampir seluruh objek dengan hanya sedikit kehilangan deteksi akibat batas antar objek yang kurang tegas, sedangkan pada kondisi tumpang tindih jumlah objek yang terdeteksi mengalami penurunan (misalnya 48 dari 50) karena sebagian fitur tertutup.

Variasi sudut pengambilan gambar, jarak kamera, dan pencahayaan memberikan pengaruh signifikan terhadap performa model, terutama pada tahap klasifikasi. Pengambilan citra dari sudut atas (*top view*) memberikan hasil terbaik karena distribusi dataset didominasi oleh sudut tersebut. Sebaliknya, penggunaan sudut miring dari arah kanan maupun kiri menyebabkan peningkatan kesalahan klasifikasi, meskipun objek masih dapat terdeteksi. Kondisi ini semakin diperburuk ketika pencahayaan tidak memadai, di mana model tetap mampu mendeteksi objek, namun gagal membedakan kelas secara akurat.

Secara umum, performa optimal diperoleh pada kondisi pencahayaan yang cukup, jarak kamera yang proporsional, dan sudut pengambilan tegak lurus terhadap objek. Nilai *threshold* yang terlalu rendah cenderung menghasilkan deteksi berlebih, sedangkan nilai yang terlalu tinggi menyebabkan beberapa objek tidak terdeteksi. Berdasarkan konfigurasi terbaik, model yang dihasilkan mampu mencapai tingkat akurasi hingga lebih dari 96% pada kondisi pengujian yang optimal.

3.3. Implementasi Sistem

Halaman hasil deteksi menampilkan keluaran sistem setelah citra dianalisis oleh model YOLOv11. Citra ditampilkan kembali dengan penandaan *bounding box* dan label kelas pada setiap biji kopi yang terdeteksi, sehingga pengguna dapat melihat lokasi dan jenis cacat secara langsung.



Gambar 3. Tampilan Deteksi

Sistem juga menyajikan ringkasan jumlah objek terdeteksi, nilai *confidence threshold*, serta perbandingan dengan jumlah objek aktual. Selain itu, distribusi klasifikasi ditampilkan dalam bentuk grafik dan tabel, serta tersedia fitur unduh dalam format gambar anotasi, CSV, dan ZIP.

4. KESIMPULAN

Berdasarkan hasil penelitian, model YOLOv11 berhasil diimplementasikan dalam sistem yang mampu mendeteksi dan mengklasifikasikan cacat biji kopi pasca-roasting secara otomatis dengan performa yang baik. Konfigurasi pembagian data 70:20:10 dipilih sebagai konfigurasi yang lebih representatif dalam mengevaluasi kemampuan generalisasi model, sedangkan penggunaan *optimizer* SGD dengan *learning rate* 0.01 serta *confidence threshold* 0.5 memberikan keseimbangan yang baik antara precision dan recall. Hasil pengujian menunjukkan bahwa faktor lingkungan seperti sudut pengambilan citra, jarak kamera, dan pencahayaan memengaruhi performa deteksi, di mana kondisi *top view* dengan pencahayaan yang cukup menghasilkan performa yang paling optimal. Secara keseluruhan, sistem mampu menangani variasi kondisi objek, termasuk objek yang saling berdekatan dan tumpang tindih, sehingga berpotensi diterapkan sebagai sistem pendukung inspeksi mutu biji kopi pada lingkungan UMKM.

Penelitian ini masih memiliki keterbatasan pada jumlah citra primer yang digunakan serta variasi jenis cacat yang masih terbatas pada empat kategori. Penggunaan data augmentasi dalam jumlah yang cukup besar juga berpotensi menimbulkan bias terhadap pola sintesis tertentu meskipun proses augmentasi telah dilakukan setelah pembagian dataset untuk meminimalkan data leakage. Penelitian selanjutnya dapat dikembangkan dengan menambah variasi data dan jenis cacat seperti *quaker*, *black bean*, *baked*, *overdevelopment*, dan *tipping*, serta mengeksplorasi arsitektur model lain atau versi YOLO terbaru untuk meningkatkan performa dan kemampuan generalisasi sistem.

DAFTAR PUSTAKA

- [1] S. Z. Shofa, S. W. Tjondro, dan N. H. I. Fitriana, "Analisis Pengendalian Kualitas Produk Arabica Roasted Coffee Beans Pada Drama Coffee Roastery," *Forum Agribisnis*, vol. 15, no. 1, hlm. 138–153, 2025, doi: 10.29244/fagb.15.1.138-153.

- [2] H. Muhammad, A. Meri, dan Dewiyana, "Penerapan Metode Seven Tools Untuk Pengendalian Kualitas Biji Kopi Arabika (Studi Kasus Grand Melati Coffee & Roastery Di Kota Langsa)," *Jurnal Industri Samudra*, vol. 11, no. 1, hlm. 1–14, 2025, [Daring]. Tersedia pada: http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484_SISTEM_PEMBETUNGAN_TERPUSAT_STRATEGI_MELESTARI
- [3] R. Iqbal, I. Heru, dan Q. R., "Analisis Pengendalian Mutu Kopi Dengan Menggunakan Diagram Fishbone Berdasarkan Standar Sca (Specialty Coffee Association) Pada Kopi Arabika Palintang, Bandung Timur," *AGRISTA*, vol. 2, no. 4, hlm. 31–41, 2023.
- [4] R. Dijaya, *Buku Ajar Pengolahan Citra Digital*. 2023.
- [5] S. Ashillah, S. Adventino Gulo, Y. Rahmi, dan D. Yandra Niska, "Implementasi Algoritma Pengolahan Citra Digital untuk Perbaikan Kualitas Gambar," *Jurnal SISKOM-KB (Sistem Komputer dan Kecerdasan Buatan)*, vol. 8, no. 3, hlm. 274–280, 2025, doi: 10.47970/siskom-kb.v8i3.823.
- [6] A. A. Kusmareni, A. Desiani, S. Yahdin, M. Saviera, A. I. Putri, dan D. A. Zayanti, "Segmentasi Paru-Paru pada Citra Thorax Dada Dengan Menggunakan Metode CNN U-Net," *JSI: Jurnal Sistem Informasi (E-Journal)*, vol. 14, no. 2, hlm. 2666–2676, 2022, doi: 10.18495/jsi.v14i2.76.
- [7] A. M. Simarmata, A. Z. Putra, dan A. M. Husein, "Penerapan Metode Computer Vision Dalam Klasifikasi Buah Jeruk Menggunakan Teknik Image Pre-Processing," *Data Sciences Indonesia (DSI)*, vol. 3, no. 2, hlm. 108–114, 2024, doi: 10.47709/dsi.v3i2.4010.
- [8] D. P. Ayuni, Jasril, M. Irsyad, F. Yanto, dan S. Sanjaya, "Data Augmentation on the Implementation of Convolutional Neural Network Architecture Efficientnet-B3 for Classification of Rice Leaf Diseases," *Jurnal Sistem Informasi (Zonasi)*, vol. 5, no. 2, hlm. 2023, 2023.
- [9] I. D. Mienye dan T. G. Swart, "A Comprehensive Review of Deep Learning Methods and Applications," *Deep learning for visual understanding*, vol. 15, no. 2, hlm. 7–58, 2024.
- [10] F. Badri, M. T. Alawiy, dan E. M. Yuniarno, "Deep Learning Architecture Based on Convolutional Neural Network (Cnn) on Animal Image Classification," *Jurnal Ilmiah KURSOR*, vol. 12, no. 2, hlm. 83–92, 2023.
- [11] M. H. V. Sinaga, M. Albirra, dan M. F. Sidiq, "Klasifikasi Gambar Pemandangan dengan Kecerdasan Buatan Berbasis CNN," *Jurnal JTik (Jurnal Teknologi Informasi dan Komunikasi)*, vol. 8, no. 2, hlm. 412–417, 2024, doi: 10.35870/jtik.v8i2.1424.
- [12] F. Elfaladonna, M. Kusnandar, F. K. Puja, dan A. P. Mariza, "Implementasi Convolutional Neural Network Untuk Klasifikasi Jenis Beras Berdasarkan Citra Digital," *Indonesian Journal of Computer Science*, vol. 12, no. 6, hlm. 4657–4663, 2025, doi: 10.33022/ijcs.v12i6.3520.
- [13] J. Pan, "Recent Deep Neural Networks for Object Detection," *Highlights in Science, Engineering and Technology*, vol. 31, no. 2, hlm. 268–273, 2023, doi: 10.54097/hset.v31i.5153.
- [14] S. Reddy, N. Pillay, dan N. Singh, "Comparative Evaluation of Convolutional Neural Network Object Detection Algorithms for Vehicle Detection," *J. Imaging*, vol. 10, no. 7, hlm. 1–12, 2024, doi: 10.3390/jimaging10070162.
- [15] M. U. Nasution, L. S. Harahap, dan F. Syakbani, "Tinjauan Metode Pengolahan Citra Digital Untuk Deteksi Objek Otomatis," *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 13, no. 3, hlm. 1020–1028, 2025.

- [16] Q. Aini, N. Lutfiani, H. Kusumah, dan M. S. Zahran, "Deteksi dan Pengenalan Objek dengan Model Machine Learning: Model Yolo," *CESS (Journal of Computer Engineering System and Science)*, vol. 6, no. 2, hlm. 2502–714, 2021.
- [17] H. L. Gope, H. Fukai, F. M. Ruhad, dan S. Barman, "Comparative analysis of YOLO models for green coffee bean detection and defect classification," *Sci. Rep.*, vol. 14, no. 1, hlm. 1–16, 2024, doi: 10.1038/s41598-024-78598-7.
- [18] F. Chen, Y. Zhang, L. Fu, R. Hua, Q. Zhang, dan S. Bi, "A Comparative Review of the Next-Generation YOLO Models: YOLOv10 and YOLO11," *Journal of Computer Science and Artificial Intelligence*, vol. 3, no. 2, hlm. 1–6, 2025, doi: 10.54097/22zsmc10.
- [19] I. Ashari, I. S. M. Negara, dan A. S. S. A, "Lightweight YOLO Models for Real-Time Multi-Vehicle Detection," *Sinkron*, vol. 9, no. 3, hlm. 1795–1810, 2025, doi: 10.33395/sinkron.v9i3.15071.
- [20] A. M. Moraes, L. F. Pugliese, R. F. dos Santos, G. B. Vitor, R. A. da S. Braga, dan F. R. da Silva, "Effectiveness of YOLO Architectures in Tree Detection: Impact of Hyperparameter Tuning and SGD, Adam, and AdamW Optimizers," *Standards*, vol. 5, no. 1, hlm. 9, 2025, doi: 10.3390/standards5010009.
- [21] I. A. Zulkarnain dan Kusrini, "Yolov11 Optimization Through Hyperparameter Tuning and Data Augmentation to Improve Vehicle Detection Accuracy at Night Optimasi Yolov11 Melalui Hyperparameter Tuning dan Data Augmentasi untuk Meningkatkan Akurasi Deteksi Kendaraan pada Kondisi Malam Hari," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 5, no. October, hlm. 1294–1303, 2025.
- [22] H. D. Thai, H. J. Ko, dan J. H. Huh, "Coffee Bean Defects Automatic Classification Realtime Application Adopting Deep Learning," *IEEE Access*, vol. 12, no. August, hlm. 126503–126517, 2024, doi: 10.1109/ACCESS.2024.3452552.
- [23] Y. Ji, J. Xu, dan B. Yan, "Coffee Green Bean Defect Detection Method Based on an Improved YOLOv8 Model," *J. Food Process. Preserv.*, vol. 2024, no. 1, 2024, doi: 10.1155/2024/2864052.