

ANALISIS PERFORMA YOLOV8 PADA DETEKSI KEMATANGAN BIJI KOPI DENGAN BERBAGAI KONFIGURASI PELATIHAN

[Performance Analysis of YOLOv8 in Coffee Seed Detection with Various Training Configuration]

Roma Rio Simbolon¹⁾, Muhammad Faza Hanifan²⁾, Mohamad Khoirun Najib^{3)*},
Elis Khatizah⁴⁾, Sri Nurdianti⁵⁾

Sekolah Sains Data, Matematika dan Informatika, IPB University

mkhoirun@apps.ipb.ac.id (Corresponding)

ABSTRAK

Kopi merupakan komoditas perkebunan strategis di Indonesia yang kualitasnya sangat dipengaruhi oleh tingkat kematangan buah saat panen. Namun, penilaian kematangan buah kopi di lapangan masih banyak dilakukan secara manual, sehingga rentan terhadap subjektivitas dan rendahnya efisiensi. Penelitian ini bertujuan untuk menganalisis performa YOLOv8 dalam mendeteksi tiga tingkat kematangan buah kopi, yaitu mentah, setengah matang, dan matang, serta mengevaluasi pengaruh berbagai konfigurasi pelatihan terhadap kinerja model. Dataset yang digunakan adalah dataset publik “Coffee Cherry” dari Kaggle yang terdiri dari 432 citra dengan 1000 anotasi bounding box. Eksperimen dilakukan dengan memvariasikan subversi YOLOv8 (n, s, m), ukuran citra, batch size, jumlah epoch, serta penggunaan augmentasi berbasis warna (HSV), skala objek, dan mixup. Hasil pengujian menunjukkan bahwa YOLOv8s memberikan keseimbangan terbaik antara akurasi dan efisiensi komputasi. Konfigurasi optimal diperoleh pada ukuran citra 416, batch size 8, dan 30 epoch, dengan augmentasi yang mampu meningkatkan nilai recall dan mAP@50, khususnya pada kelas yang sulit dideteksi. Meskipun demikian, keterbatasan jumlah dan variasi dataset masih menjadi faktor pembatas utama. Secara keseluruhan, YOLOv8 menunjukkan potensi yang baik untuk deteksi kematangan buah kopi di kondisi lapangan.

Kata kunci: YOLOv8; deteksi objek; kematangan buah kopi; visi komputer; deep learning

ABSTRACT

Coffee is a strategic plantation commodity in Indonesia, whose quality is strongly influenced by fruit maturity at harvest. However, maturity assessment in the field is still largely conducted manually, leading to subjectivity and low efficiency. This study aims to analyze the performance of YOLOv8 in detecting three coffee fruit maturity levels—unripe, semi-ripe, and ripe—and to evaluate the impact of different training configurations on model performance. The experiments were conducted using the public “Coffee Cherry” dataset from Kaggle, consisting of 432 images with 1000 bounding box annotations. Several configurations were evaluated, including YOLOv8 variants (n, s, m), image sizes, batch sizes, number of epochs, and data augmentation techniques based on HSV color space, object scaling, and mixup. The results show that YOLOv8s provides the best balance between detection accuracy and computational efficiency. The optimal configuration was achieved using an image size of 416, batch size of 8, and 30 epochs, with augmentation improving recall and mAP@50, particularly for challenging classes. Nevertheless, limited dataset size and diversity remain the main constraints affecting performance. Overall, YOLOv8 demonstrates strong potential for coffee fruit maturity detection under real-world conditions.

Keywords: YOLOv8; object detection; coffee fruit maturity; computer vision; deep learning

PENDAHULUAN

Kopi tidak hanya menjadi komoditas perkebunan, namun juga memiliki peran sentral dalam kehidupan masyarakat Indonesia. Data terbaru dari *US Department of Agriculture (USDA)* menunjukkan bahwa Indonesia merupakan salah satu penghasil kopi terbesar di dunia, dengan menempati peringkat ke-4 setelah Brazil, Vietnam, dan Kolombia. Selain itu, data Badan Pusat Statistik (BPS) hingga September 2025 menunjukkan bahwa kopi menempati posisi kedua dalam total ekspor hasil pertanian, di bawah buah-buahan, dengan volume mencapai 372,8 ribu ton. Nilai ekspor kopi bahkan menjadi yang terbesar di antara seluruh komoditas pertanian lainnya, yaitu senilai 1.867,9 juta USD. Hal inilah yang menjadikan kopi banyak digemari oleh orang-orang.

Sebelum menikmati biji kopi berkualitas baik, Biji kopi harus diseleksi dulu supaya mendapatkan kualitas biji kopi yang terbaik. Saat ini, deteksi biji kopi masih dilakukan secara manual. Ada tantangan tersendiri ketika melakukan deteksi biji kopi secara manual, di antaranya adalah deteksi manual sangat menguras tenaga sehingga membuat pemantauan di kebun menjadi tidak optimal karena pemantauan tidak dilakukan di sepanjang kebun (Kazuma *et al.* 2024). Kazuma *et al.* (2024) juga menyatakan bahwa lingkungan di lapang yang kompleks menjadi tantangan dalam deteksi biji kopi secara manual, di antaranya adalah biji kopi yang seringkali tersembunyi di balik dedaunan, kemiripan buah dengan latar belakang, dan penumpukan biji kopi yang membuat mata sering melewatkan biji kopi. Fadri *et al.* (2021) menambahkan bahwa standar penilaian biji kopi seringkali bervariasi, terutama saat harus mengidentifikasi cacat fisik pada biji kopi.

Deteksi otomatis menggunakan komputer menjadi solusi atas kedua masalah yang ditemukan salah satunya adalah pemanfaatan teknologi visi komputer berbasis deep learning. Pemanfaatan teknologi visi komputer berbasis deep learning mengalami perkembangan pesat dan semakin banyak diterapkan pada sektor pertanian, khususnya untuk automasi dan deteksi penyakit tanaman. Deteksi visual tanaman secara manual umumnya dilakukan oleh petani melalui pengamatan langsung, namun metode tersebut dinilai kurang efisien, membutuhkan waktu lama, serta rentan terhadap subjektivitas manusia. Oleh karena itu, pendekatan menggunakan algoritma convolutional neural network (CNN) menjadi solusi yang semakin banyak diteliti karena mampu memberikan akurasi tinggi dan kecepatan deteksi yang baik.

Salah satu arsitektur CNN yang paling populer dalam deteksi objek adalah keluarga YOLO (You Only Look Once), yang dikenal karena kemampuannya mendeteksi objek secara real-time dengan akurasi yang kompetitif. Chitriningrum *et al.* (2023) dalam jurnalnya yang berjudul melakukan perbandingan kinerja YOLOv5 dan YOLOv8 pada deteksi penyakit daun jagung menggunakan dataset publik dari Kaggle. Hasil penelitian tersebut menunjukkan bahwa YOLOv8 menghasilkan akurasi yang lebih tinggi secara konsisten dibandingkan YOLOv5.

Temuan tersebut memotivasi penelitian ini untuk mengevaluasi performa YOLOv8 lebih lanjut, namun pada domain yang berbeda, yaitu deteksi tingkat kematangan buah kopi. Penentuan tingkat kematangan merupakan tahapan penting dalam proses pascapanen kopi karena berpengaruh langsung terhadap kualitas akhir biji kopi. Seperti halnya deteksi penyakit daun jagung, penilaian kematangan buah kopi di lapangan umumnya masih dilakukan secara manual berdasarkan pengamatan warna buah. Hal ini menyebabkan ketidakseragaman dalam penilaian, potensi kesalahan, serta rendahnya efisiensi proses.

Oleh sebab itu, penelitian ini berfokus pada pengujian dan optimasi model YOLOv8 untuk mendeteksi tiga tingkat kematangan buah kopi, yaitu mentah, setengah matang, dan matang. Pendekatan ini dilakukan melalui serangkaian eksperimen meliputi pemilihan varian YOLOv8 (n, s, m), variasi ukuran gambar, batch size, jumlah epoch, serta augmentasi berbasis warna (HSV) untuk menyesuaikan dengan karakteristik visual buah kopi.

METODE PENELITIAN

Penelitian ini menggunakan dataset publik dari Kaggle berjudul “Dataset Coffee Cherry” yang dikembangkan oleh Haris Yunanda. Dataset ini berisi 432 citra buah kopi dengan total 1000 anotasi bounding box. Dataset dibagi menjadi 346 citra (80%) untuk pelatihan dengan 564 anotasi, dan 86 citra (20%) untuk validasi dengan 436 anotasi.

Dataset ini dikumpulkan langsung dari perkebunan kopi nyata, sehingga memuat beragam kondisi pencahayaan alami, latar belakang alami (daun, ranting, tanah), variasi posisi kamera, serta perbedaan warna buah kopi yang berubah secara bertahap dari hijau, kuning, dan merah. Variabilitas dan noise visual ini menjadikan dataset sangat relevan sebagai representasi kondisi dunia nyata, sekaligus menjadi tantangan dalam membedakan tingkat kematangan berdasarkan fitur warna.

Spesifikasi Hardware dan Software yang digunakan adalah sebagai berikut:

Spesifikasi *hardware*:

Tabel 1. Spesifikasi Hardware yang Digunakan

<i>Laptop</i>	ROG Zephyrus G14 (GA401II)
Prosesor	AMD Ryzen 7 4800HS - Radeon Graphics (8 Core/16 Thread, 2.9-4.2 GHz)
GPU	NVIDIA GeForce GTX 1650 Ti (4 GB VRAM, CUDA 12.9)
RAM	8GB DDR4
VRAM	3.9 GB <i>dedicated</i> + 3.8 GB <i>shared</i>
<i>Storage</i>	SSD NVMe 512 GB

Spesifikasi *software*:

Tabel 2. Spesifikasi Software yang Digunakan

OS	Windows 11 Home Single Language 64-bit (Build 26200)
Bahasa pemrograman	Python
IDE	Visual Studio Code
<i>Deep learning frameworks</i>	PyTorch
<i>GPU acceleration libraries</i>	CUDA

HASIL DAN PEMBAHASAN

Pengujian pertama dilakukan untuk menentukan subversi YOLOv8 (n, s, m) yang paling sesuai untuk mendeteksi tiga tingkat kematangan buah kopi. Model diuji menggunakan konfigurasi awal (image size 416, batch size 2, epoch 100). Alasan pemilihan konfigurasi ini adalah batasan tertinggi perangkat untuk YOLOv8m.

Tabel 3. Perbandingan Performa Berbagai Subversi YOLO V8

Versi	Kelas	Precision	Recall	mAP@50	mAP@50-95	Detection Time	Training Time
Yolov8n	Mentah	0.537	0.789	0.714	0.379	28.2 ms per image	0.993 Hours
	Setengah	0.710	0.679	0.789	0.372		
	Matang	0.605	0.481	0.547	0.246		
	Rata-rata	0.617	0.650	0.683	0.332		
Yolov8s	Mentah	0.666	0.663	0.730	0.382	37.8 ms per image	1.414 Hours
	Setengah	0.704	0.741	0.802	0.401		
	Matang	0.510	0.550	0.495	0.222		
	Rata-rata	0.627	0.651	0.676	0.335		
Yolov8m	Mentah	0.681	0.705	0.742	0.384	70.3 ms per image	3.168 Hours
	Setengah	0.697	0.716	0.782	0.372		
	Matang	0.551	0.473	0.521	0.238		
	Rata-rata	0.643	0.631	0.682	0.331		

Hasil training menunjukkan bahwa ketiga model—YOLOv8n, YOLOv8s, dan YOLOv8m—memiliki performa yang hampir serupa, dengan rata-rata mAP@50 masing-masing 0.683, 0.676, dan 0.682, namun YOLOv8s umumnya memberikan hasil yang sedikit lebih stabil dan

lebih baik dibanding YOLOv8n, terutama pada kelas setengah matang (0.802 vs 0.789) dan konsistensi precision–recall. Pada tingkat kelas lainnya, perbedaannya tetap tipis: untuk Mentah, ketiganya berada pada mAP@50 0.714–0.742, sementara untuk matang, ketiganya sama-sama rendah di kisaran 0.495–0.547. Meskipun demikian, perbedaan terbesar justru terlihat pada efisiensi model: YOLOv8n adalah yang tercepat dengan 28.2 ms per gambar dan 0.99 jam training, YOLOv8s sedikit lebih lambat dengan 37.8 ms dan 1.41 jam namun menawarkan performa yang lebih baik, sedangkan YOLOv8m jauh lebih lambat dengan 70.3 ms dan 3.17 jam tanpa peningkatan akurasi yang berarti, sehingga YOLOv8s menjadi pilihan paling ideal karena memberikan keseimbangan terbaik antara akurasi dan kecepatan.

Pengujian kedua dilakukan untuk menilai dampak ukuran citra terhadap performa deteksi. Karena dataset kopi berbasis warna, percobaan dilakukan untuk memastikan apakah peningkatan resolusi membantu model mengenali detail warna. Ukuran gambar ditingkatkan dari 416 ke 512.

Tabel 4. Perbandingan Ukuran Gambar pada YOLOv8

<i>Image Size</i>	<i>Kelas</i>	<i>Precision</i>	<i>Recall</i>	<i>mAP@50</i>	<i>mAP@50-95</i>	<i>Detection Time</i>	<i>Training Time</i>
416	Mentah	0.666	0.663	0.730	0.382	37.8 ms per image	1.414 Hours
	Setengah Matang	0.704	0.741	0.802	0.401		
	Matang	0.510	0.550	0.495	0.222		
	Rata-rata	0.627	0.651	0.676	0.335		
512	Mentah	0.640	0.695	0.686	0.356	51 ms per image	2.142 Hours
	Setengah Matang	0.679	0.778	0.789	0.401		
	Matang	0.470	0.588	0.498	0.236		
	Rata-rata	0.596	0.687	0.658	0.331		

Perbandingan YOLOv8s resolusi 416 dan 512 menunjukkan bahwa peningkatan ukuran gambar tidak meningkatkan performa; justru model 416 memberikan hasil lebih baik dengan mAP@50 0.676 dibanding 0.658 pada 512, serta precision dan mAP@50-95 yang juga lebih tinggi. Pada masing-masing kelas, perbedaannya sangat kecil—kelas setengah matang sedikit turun dari 0.802 ke 0.789, dan kelas matang tetap rendah di kisaran 0.495–0.498—sementara resolusi 512 membutuhkan waktu deteksi dan training jauh lebih lama (51 ms dan 2.14 jam). Performa 512 tidak naik kemungkinan karena ukuran objek dalam dataset tidak cukup kecil untuk memanfaatkan resolusi lebih besar, kualitas data menjadi faktor pembatas, atau model sudah mencapai titik saturasi sehingga peningkatan resolusi hanya menambah beban komputasi tanpa memberi manfaat. Oleh sebab itu, resolusi 416 tetap menjadi pilihan terbaik. Pengujian ketiga bertujuan menentukan ukuran batch terbaik untuk stabilitas training. Batch size diuji pada nilai 2, 4, dan 8.

Tabel 5. Perbandingan Setiap Ukuran Batch

<i>Batch</i>	<i>Kelas</i>	<i>Precision</i>	<i>Recall</i>	<i>mAP@50</i>	<i>mAP@50-95</i>	<i>Detection Time</i>	<i>Training Time</i>
Batch 2	Mentah	0.666	0.663	0.730	0.382	37.8 ms per image	1.414 Hours
	Setengah Matang	0.704	0.741	0.802	0.401		
	Matang	0.510	0.550	0.495	0.222		
	Rata-rata	0.627	0.651	0.676	0.335		
Batch 4	Mentah	0.581	0.768	0.721	0.380	47.8 ms per image	1.199 Hours
	Setengah Matang	0.645	0.763	0.792	0.402		
	Matang	0.521	0.508	0.490	0.217		
	Rata-rata	0.582	0.680	0.668	0.333		
Batch 8	Mentah	0.686	0.690	0.699	0.374	38.6 ms per image	1.321 Hours
	Setengah Matang	0.589	0.765	0.827	0.398		
	Matang	0.561	0.538	0.520	0.229		
	Rata-rata	0.612	0.665	0.682	0.334		

Pengujian batch size menunjukkan bahwa meskipun performa ketiga opsi (batch 2, 4, dan 8) berada dalam rentang yang mirip, batch 8 memberikan hasil paling baik dan paling seimbang. Batch 8 mencapai rata-rata mAP@50 0.682, tertinggi di antara ketiganya, dengan peningkatan jelas pada kelas setengah matang (0.827, tertinggi dari semua percobaan) serta perbaikan pada kelas matang (0.520, lebih baik dari batch 2 maupun batch 4). Batch 2 memang stabil tetapi tidak mencapai nilai puncak tersebut, sedangkan batch 4 justru menurun pada precision dan mAP beberapa kelas. Selain itu, detection time batch 8 tetap cepat (38.6 ms) dan waktu training hanya sedikit berbeda dari batch lain, sehingga batch terbaik adalah 8.

Pengujian berikutnya dilakukan untuk menentukan jumlah epoch paling efektif. Awalnya epoch dinaikkan ke 150, namun YOLOv8 menghentikan training pada epoch 116, dan best model ditemukan pada epoch 16, menandakan model cepat konvergen. Epoch 16 memang menjadi titik terbaik menurut early stopping, namun hasilnya biasanya kurang stabil karena model belum benar-benar mencapai konsistensi antar batch, sehingga 30 epoch dipilih sebagai titik tengah yang optimal, cukup lama untuk mematangkan pembelajaran.

Tabel 6. Perbandingan Epoch 30 dan 100

<i>Epoch</i>	<i>Kelas</i>	Precision	Recall	mAP@50	mAP@50-95	Detection Time	Training Time
100	Mentah	0.686	0.690	0.699	0.374	38.6 ms per image	1.321 Hours
	Setengah Matang	0.589	0.765	0.827	0.398		
	Matang	0.561	0.538	0.520	0.229		
	Rata-rata	0.612	0.665	0.682	0.334		
30	Mentah	0.646	0.684	0.712	0.375	37.3 ms per image	0.330 Hours
	Setengah Matang	0.721	0.764	0.810	0.388		
	Matang	0.444	0.638	0.511	0.231		
	Rata-rata	0.603	0.696	0.678	0.331		

Pengujian jumlah epoch menunjukkan bahwa 30 epoch memberikan hasil yang lebih stabil dan lebih seimbang. Performa rata-rata mencapai mAP@50 0.678, sangat dekat dengan hasil epoch 100 (0.682) namun dengan waktu training jauh lebih efisien (0.33 jam vs 1.32 jam). Selain itu, epoch 30 memberikan peningkatan signifikan pada recall rata-rata (0.696), tertinggi dari seluruh pengujian, yang berarti model lebih baik dalam menemukan objek di semua kelas, termasuk kenaikan besar pada kelas matang (recall 0.638, tertinggi).


Tahap pengujian terakhir, augmentasi ditingkatkan karena model deteksi kematangan kopi sangat bergantung pada perbedaan warna dan pencahayaan, sehingga diperlukan variasi tambahan agar model lebih tahan terhadap kondisi lapangan yang berubah-ubah. Parameter augmentasi dinaikkan pada aspek warna, skala objek (scale), dan pencampuran gambar (mixup) dengan tujuan memperluas distribusi visual data dan mengurangi risiko model terlalu bergantung pada pola warna tertentu.

Tabel 7. Perbandingan Parameter Augmentasi

Augmentasi	<i>Kelas</i>	Precision	Recall	mAP@50	mAP@50-95	Detection Time	Training Time
Tidak	Mentah	0.646	0.684	0.712	0.375	37.3 ms per image	0.330 Hours
	Setengah Matang	0.721	0.764	0.810	0.388		
	Matang	0.444	0.638	0.511	0.231		
	Rata-rata	0.603	0.696	0.678	0.331		
Ya	Mentah	0.680	0.737	0.715	0.360	39 ms per image	0.402 Hours
	Setengah Matang	0.563	0.840	0.790	0.403		
	Matang	0.534	0.546	0.542	0.239		
	Rata-rata	0.592	0.708	0.682	0.334		

Hasil pengujian menunjukkan bahwa konfigurasi augmentasi meningkatkan sensitivitas model, terlihat dari kenaikan recall rata-rata (0.696 menjadi 0.708) serta peningkatan mAP kelas matang yang sebelumnya sulit dideteksi, menandakan bahwa model menjadi lebih sensitif dan lebih jarang melewatkan objek. Meskipun precision sedikit menurun akibat bertambahnya variasi warna yang agresif, hal ini merupakan trade-off yang dapat diterima karena untuk aplikasi seperti deteksi kematangan buah, kesalahan melewatkan buah (FN) lebih merugikan dibanding kesalahan mendeteksi berlebih (FP). Dengan kata lain, augmentasi membuat model lebih siap menghadapi variasi nyata di lapangan, lebih stabil mendeteksi objek dalam kondisi pencahayaan berbeda, dan memberikan generalisasi yang lebih baik sehingga konfigurasi dengan augmentasi dipilih sebagai yang paling menguntungkan secara praktis.

Perbandingan confusion matrix antara model YOLOv8s awal dan konfigurasi akhir dilakukan untuk melihat bagaimana perubahan konfigurasi training memengaruhi pola kesalahan klasifikasi pada ketiga kelas buah kopi.



Gambar 1. (a.) Confusion Matrix YOLOv8s awal, (b.) Confusion Matrix YOLOv8s final

Confusion matrix menunjukkan bahwa model final memiliki peningkatan performa terutama pada kelas setengah matang, dengan persentase prediksi benar meningkat dari 0.74 menjadi 0.83. Kelas mentah tetap stabil dengan perubahan kecil dari 0.71 menjadi 0.69, sedangkan kelas matang mengalami penurunan ringan dari 0.63 menjadi 0.58, namun disertai penurunan kesalahan prediksi sebagai *background*, yang menandakan kemampuan segmentasi objek yang lebih baik. Berdasarkan perubahan tersebut, seluruh tahapan perubahan konfigurasi, mulai dari pemilihan varian YOLOv8s, penetapan ukuran citra 416, *batch size* 8, penyesuaian *epoch* menjadi 30, hingga penggunaan augmentasi berbasis HSV, secara konsisten memberikan kontribusi positif terhadap performa model.

PENUTUP

Simpulan

YOLOv8 terbukti dapat diterapkan untuk mendeteksi tingkat kematangan buah kopi, dan pengujian menunjukkan bahwa berbagai konfigurasi, seperti model, resolusi, batch size, epoch, dan augmentasi, memberikan pengaruh nyata terhadap performa model. Meskipun begitu, keterbatasan jumlah dan variasi dataset tetap menjadi faktor pembatas utama, karena kesalahan klasifikasi terutama pada kelas matang masih cukup tinggi dan model sangat sensitif terhadap variasi warna dan pencahayaan. Hal ini menunjukkan bahwa meskipun konfigurasi optimal mampu meningkatkan robustnes dan recall, peningkatan kualitas dan jumlah data tetap menjadi kunci untuk performa yang lebih stabil dan akurat di lapangan.

Saran

Adapun beberapa saran yang dapat dipertimbangkan untuk pengembangan selanjutnya.

1. Perluasan dan diversifikasi dataset. Tambahkan lebih banyak sampel dengan tetap menjadi keseimbangan kelas. Pastikan jumlah sampel tiap kelas seimbang agar model tidak bias terhadap kelas dominan, Sertakan variasi pencahayaan, posisi, dan jarak kamera untuk meningkatkan kemampuan generalisasi.

2. Penelitian ke depan dapat dilakukan dengan spesifikasi perangkat yang lebih baik, sehingga memungkinkan penggunaan variasi model yang lebih besar dan konfigurasi training yang lebih luas. Dengan perangkat yang lebih kuat, batasan komputasi saat ini dapat diatasi, sehingga model dapat dilatih secara lebih optimal dan performanya meningkat.

DAFTAR PUSTAKA

- [USDA] United States Department of Agriculture.(2024). Coffee: World Markets and Trade. Tersedia pada : <https://www.fas.usda.gov/sites/default/files/2024-12/coffee.pdf>
- [BPS] Badan Pusat Statistik.(2025). Nilai Ekspor Bulanan Hasil Pertanian Menurut Komoditas (Juta US\$). Tersedia pada : <https://www.bps.go.id/id/statistics-table/2/MjMxMCMMy/nilai-ekspor-bulanan-hasil-pertanian-menurut-komoditas---juta-us--.html>
- [BPS] Badan Pusat Statistik.(2025). Berat Bersih Ekspor Bulanan Hasil Pertanian Menurut Komoditas (Ribu Ton), 2025. Tersedia pada : <https://www.bps.go.id/id/statistics-table/2/MjMxMSMy/berat-bersih-ekspor-bulanan-hasil-pertanian-menurut-komoditas---ribu-ton-.html>
- Chitraningrum, N., Banowati, L., Herdiana, D., Mulyati, B., Sakti, I., Fudholi, A., ... Andria, A. (2023). Comparison study of corn leaf disease detection based on deep learning YOLO-v5 and YOLO-v8. *Journal of Engineering and Technological Sciences*, 56(1), 61–70.
- Kazama, E. H., Tedesco, D., Carreira, V. S., Barbosa Júnior, M. R., de Oliveira, M. F., Ferreira, F. M., . . . da Silva, R. P. (2024). Monitoring coffee fruit maturity using an enhanced convolutional neural network under different image acquisition settings. *Scientia Horticulturae*, 328, 112957.
- Fadri, R. A., Sayuti, K., Nazir, N., & Suliansyah, I. (2021). Evaluation of the value of the defective and taste of Arabica coffee (*Coffea Arabica* L) West Sumatera. *IOP Conference Series: Earth and Environmental Science*, 819(1), 012004