

IMPLEMENTASI ALGORITMA *YOU ONLY LOOK ONCE* (YOLO) UNTUK SISTEM DETEKSI OBJEK PADA *MOBILE ROBOT* PENGANGKUT BARANG FORKLIFT

Choiri Panca .T¹, Tasya Rafayla .D², Muhammad Fikri Aulian³ dan Irmawan⁴

¹Teknik Elektro, Universitas Sriwijaya, Palembang

²Teknik Elektro, Universitas Sriwijaya, Palembang

³Teknik Elektro, Universitas Sriwijaya, Palembang

⁴Teknik Elektro, Universitas Sriwijaya, Palembang

Corresponding author e-mail: choiripanca@gmail.com

ABSTRAK: Perkembangan teknologi robotika dan visi komputer berperan penting dalam mendukung sistem otomatisasi industri modern. Salah satu tantangan utama dalam pengembangan mobile robot pengangkut barang seperti forklift otonom adalah kemampuan mendeteksi objek di lingkungan kerja secara akurat dan real-time. Penelitian ini bertujuan mengimplementasikan algoritma You Only Look Once versi terbaru, yaitu YOLOv11, sebagai sistem deteksi objek pada mobile robot pengangkut barang. Dataset yang digunakan terdiri atas delapan kelas objek, yaitu pallet kayu, kardus susu anak, kardus Le Minerale, kardus Aqua, galon mineral, galon Aqua, helm keselamatan, dan kardus Indomilk, dengan total 4949 gambar dan 1250 objek hasil anotasi manual. Model dilatih selama 100 epoch menggunakan GPU NVIDIA A100 dengan ukuran citra 640×640 piksel. Hasil pelatihan menunjukkan nilai Precision sebesar 0,897, Recall 0,882, mAP50 0,928, dan mAP50–95 0,870. Kelas dengan akurasi tertinggi diperoleh pada galon mineral dengan mAP50 97,3%, sedangkan terendah pada kardus Aqua dengan 84,6%. Hasil ini membuktikan bahwa YOLOv11 mampu memberikan performa deteksi yang sangat baik, stabil, dan efisien untuk aplikasi deteksi objek real-time pada robot industri..

Kata Kunci: YOLOv11, deteksi objek, forklift otonom, visi komputer, mobile robot

ABSTRACT: The advancement of robotics and computer vision technology plays a vital role in supporting modern industrial automation systems. One of the main challenges in developing autonomous goods carrier robots, such as self-driving forklifts, is achieving accurate and real-time object detection in complex environments. This study implements the latest version of the You Only Look Once algorithm, YOLOv11, as an object detection system for a mobile goods carrier robot. The dataset consists of eight object classes—wooden pallets, milk boxes, Le Minerale cartons, Aqua cartons, mineral water gallons, Aqua gallons, safety helmets, and Indomilk cartons—comprising 4949 images and 1250 manually annotated objects. The model was trained for 100 epochs on an NVIDIA A100 GPU using 640×640-pixel images. The experimental results achieved a Precision of 0.897, Recall 0.882, mAP50 0.928, and mAP50–95 0.870. The highest accuracy was obtained for the mineral gallon class (mAP50 = 97.3%), while the lowest was for Aqua cartons (mAP50 = 84.6%). These results demonstrate that YOLOv11 provides excellent, stable, and efficient detection performance, making it suitable for real-time object recognition in industrial mobile robots.

Keywords: YOLOv11, object detection, autonomous forklift, computer vision, mobile robot

1 Pendahuluan

Perkembangan teknologi robotika telah memberikan pengaruh yang signifikan pada berbagai sektor industri, terutama dalam meningkatkan efisiensi dan efektivitas operasional. Salah satu inovasi yang terus dikembangkan adalah mobile robot, yaitu robot yang mampu bergerak secara otonom untuk melaksanakan beragam tugas,

termasuk pengangkutan barang. Dalam konteks logistik dan pergudangan, penerapan mobile robot pengangkut barang, seperti forklift otomatis, menawarkan solusi yang menjanjikan untuk mengurangi ketergantungan pada tenaga kerja manusia sekaligus menekan risiko kecelakaan kerja.

Meski demikian, tantangan utama dalam pengembangan mobile robot pengangkut barang, khususnya forklift otonom, terletak pada kemampuan robot dalam mendeteksi dan mengenali objek secara akurat dan real-time. Deteksi objek yang handal sangat krusial agar robot dapat menghindari tabrakan, mengenali barang yang akan diangkut. Oleh karena itu, diperlukan sistem computer vision yang efisien dan cepat untuk menjamin kinerja robot dalam pengoperasian sehari-hari.

Berbagai metode telah dikembangkan untuk sistem deteksi objek sekitar *mobile robot* diantaranya, Pada penelitian sebelumnya menunjukkan bahwa algoritma RetinaNet mampu memberikan performa deteksi yang baik pada objek kardus bertumpuk di lingkungan pergudangan. Dalam penelitian tersebut, arsitektur RetinaNet dimodifikasi dengan penambahan modul boundary/offset (OPCL + BGS) untuk meningkatkan ketepatan deteksi pada objek dengan tekstur berulang dan kondisi occlusion. Hasil pengujian pada Stacked Carton Dataset (SCD) menunjukkan bahwa model ini mencapai nilai mAP sebesar 86,7%, setelah melalui tahap pre-training pada subset daring dan fine-tuning pada data lapangan. Temuan ini menunjukkan bahwa RetinaNet memiliki potensi yang tinggi dalam mendeteksi objek kardus secara akurat di lingkungan industri pergudangan. Namun memerlukan komputasi yang tinggi [1].

Penelitian lain menunjukkan bahwa metode Mask R-CNN memiliki kinerja yang sangat baik dalam mendeteksi dan melacak objek berupa pallet kayu serta kemasan kardus pada jalur produksi industri. Sistem Monitoring of Smart Production and Packaging Area (MOSPPA) yang mengombinasikan pendekatan deteksi berorientasi dengan model segmentasi seperti Mask R-CNN berhasil mencapai nilai Average Precision (AP) sebesar 0,93 dengan kecepatan pemrosesan sekitar 14 frame per detik (FPS). Hasil ini membuktikan bahwa metode two-stage detection berbasis segmentasi instansi efektif digunakan dalam pencatatan dan pelacakan objek di lingkungan industri nyata. Namun demikian, kelemahan utama Mask R-CNN terletak pada kompleksitas komputasi yang tinggi dan waktu inferensi yang relatif lambat, sehingga kurang optimal untuk diterapkan pada sistem deteksi real-time di area pergudangan yang membutuhkan respon cepat [2].

Penelitian lain menerapkan algoritma template matching berbasis sensor RGB-D untuk tugas pengenalan dan pelokalan objek pallet pada lingkungan gudang industri. Dalam penelitian tersebut, data yang digunakan berupa citra RGB-D dari pallet kayu yang diambil secara langsung di area pergudangan, dengan berbagai kondisi

pencahayaannya dan posisi tumpukan yang bervariasi. Sistem ini memanfaatkan kombinasi informasi kedalaman (depth) dan warna (RGB) untuk meningkatkan ketepatan dalam proses deteksi serta mengurangi kesalahan akibat tumpang tindih antarobjek. Hasil pengujian menunjukkan bahwa metode ini mampu mencapai tingkat akurasi sebesar 92,6% pada skenario multi-pallet, dengan waktu deteksi yang cukup efisien untuk aplikasi real-time. Temuan ini membuktikan bahwa pendekatan berbasis RGB-D dapat menjadi solusi alternatif yang efektif untuk sistem deteksi dan pelacakan objek pallet di lingkungan gudang yang kompleks. Namun, metode berbasis template matching memiliki kelemahan dalam hal sensitivitas terhadap perubahan orientasi, skala, dan kondisi pencahayaan ekstrem, sehingga performanya dapat menurun ketika diterapkan pada lingkungan gudang yang dinamis dan tidak terstruktur [3].

Penelitian sebelumnya mengusulkan penerapan algoritma Single Shot MultiBox Detector (SSD) yang dimodifikasi untuk meningkatkan kemampuan sistem dalam mendeteksi pallet kayu di area gudang logistik. Dataset yang digunakan terdiri atas citra pallet industri dengan variasi kondisi pencahayaan, posisi, dan ukuran tumpukan. Hasil pengujian menunjukkan bahwa sistem mampu mencapai akurasi 92,7% dengan kecepatan 42 FPS, yang menandakan metode SSD ini efisien dan andal untuk implementasi deteksi objek secara real-time di lingkungan pergudangan. Namun demikian, kelemahan utama dari SSD terletak pada kesulitannya dalam mendeteksi objek berukuran kecil atau yang saling tumpang tindih, karena pendekatan satu tahap (single-shot) cenderung mengorbankan ketelitian demi kecepatan pemrosesan [4].

Penelitian sebelumnya mengusulkan penerapan *Deep Learning* untuk identifikasi dan klasifikasi penyakit pada daun tanaman kopi Arabika. Metode yang diuji adalah *Convolutional Neural Network* (CNN) dan *Transfer Learning* menggunakan arsitektur DenseNet-201. Dataset yang digunakan mencakup citra daun kopi dengan empat jenis penyakit (*Cercospora*, *Leaf Rust*, *Miner*, dan *Phoma*) serta daun sehat. Hasil pengujian menunjukkan bahwa model DenseNet-201 mampu mencapai akurasi tertinggi 97,2%, mengungguli model CNN yang hanya mencapai 94,2%. Namun demikian, kelemahan utama dari penelitian ini terletak pada masih terbatasnya data primer yang digunakan, sehingga dikhawatirkan dapat menyebabkan *overfitting* dan perlu ditambah untuk meningkatkan hasil akurasi [5].


IMPLEMENTASI ALGORITMA *YOU ONLY LOOK ONCE* (YOLO)

Selanjutnya penelitian lain mengusulkan metode YOLOv4 untuk tugas deteksi dan klasifikasi returnable packaging (termasuk botol plastik, botol kaca, dan kaleng) pada dataset hasil pengumpulan dan augmentasi mandiri. Model terbaik (YOLOv4 + Mish, batch besar) mencapai mAP hingga 99.7% pada skenario evaluasi dan menunjukkan performa inferensi real-time yang baik, menegaskan keefektifan YOLO untuk aplikasi pengenalan kemasan dalam lini produksi dan daur ulang [6].

Berdasarkan hasil kajian terhadap berbagai penelitian sebelumnya, diketahui bahwa masih terdapat sejumlah kendala pada sistem deteksi objek untuk mobile robot, terutama ketika beroperasi pada lingkungan dengan latar yang kompleks, pencahayaan yang tidak stabil, serta penurunan akurasi saat proses deteksi dilakukan secara real-time. Selain itu, kecepatan pemrosesan juga menjadi tantangan akibat kebutuhan ekstraksi fitur yang berbeda untuk setiap jenis objek. Untuk mengatasi permasalahan tersebut, penelitian ini mengusulkan penerapan algoritma You Only Look Once (YOLO) sebagai pendekatan terpadu dalam sistem deteksi objek pada mobile robot. Metode berbasis deep learning ini dipilih karena mampu memberikan keseimbangan antara ketepatan deteksi dan kecepatan komputasi, sehingga ideal untuk diaplikasikan pada sistem deteksi objek real-time di lingkungan dinamis.

2 Metode Penelitian

Metode yang digunakan dalam penelitian ini adalah You Only Look Once (YOLO), yang merupakan salah satu algoritma deep learning populer untuk melakukan deteksi objek secara real time. YOLO bekerja dengan prinsip bahwa seluruh citra dianalisis hanya dalam satu kali proses melalui jaringan syaraf convolusional, sehingga mampu mendeteksi dan mengklasifikasikan objek dengan cepat serta efisien. Implementasi metode ini tersedia dalam platform open source yang dikenal sebagai darknet. Dalam penelitian ini, digunakan versi YOLOv11, yang memiliki peningkatan akurasi, kecepatan inferensi, serta efisiensi komputasi dibandingkan versi sebelumnya. Berikut adalah tahapan yang dilakukan dalam penelitian :



Gambar 2. Tahapan penelitian

2.1 Pengumpulan dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari pengambilan gambar secara langsung. Objek yang difokuskan terdiri atas kardus aqua, kardus lemineral, kardus susu anak, kardus indomilk, helem safety, galon aqua, galon mineral dan pallet kayu dengan berbagai variasi kondisi pencahayaan, posisi, jarak, dan sudut pandang. Jumlah total citra yang digunakan sebanyak 4949 gambar, yang kemudian dibagi tiga yaitu, Data latih (training): 70%, Data validasi (validation): 20%, dan Data uji (testing): 10%. Dataset dapat dilihat pada tabel 1.1


Tabel 1. List dataset objek

No	Objek	Anotasi
1	Kardus aqua	1250
2	Kardus Leminerall	1250
3	Kardus susu anak	1250
4	Kardus indomilk	1250
5	Galon aqua	1250
6	Galon mineral	1250
7	Helem safety	1250
8	Pallet kayu	1250

2.2 Proses lebeling

Proses pelabelan dilakukan menggunakan platform Roboflow, yang menyediakan antarmuka berbasis web untuk memberi anotasi objek pada setiap citra. Label yang digunakan dalam penelitian ini terdiri dari delapan kelas, yaitu: kardus aqua, kardus lemineral, kardus susu anak,

kardus indomilk, helem safety, galon aqua, galon mineral dan pallet kayu.



Gambar 2. Proses labeling menggunakan Roboflow

2.3 Pelatihan model menggunakan YOLOv11

Proses pelatihan (training) dilakukan menggunakan framework Ultralytics YOLOv11, yang merupakan versi terbaru dari algoritma YOLO dengan peningkatan arsitektur jaringan dan efisiensi komputasi. Parameter utama yang digunakan dalam pelatihan dapat dilihat pada tabel 2.

Tabel 2. Parameter training YOLOv11

Parameter	Nilai
Model	YOLOv11n.pt
Epoch	100
Batch size	16
Image size	640 × 640
Optimizer	Adam
Learning rate	0.001
Loss function	CIoU, BCE Loss
Dataset format	YOLO (Roboflow Export)

Selama proses pelatihan, sistem menghasilkan dua model utama yaitu best.pt (model dengan hasil validasi terbaik) dan last.pt (model terakhir hasil pelatihan).


3 Hasil dan Pembahasan

hasil yang diperoleh dari proses pelatihan, pengujian, serta analisis performa model deteksi objek menggunakan algoritma You Only Look Once versi 11 (YOLOv11). Tujuan utama dari tahap ini adalah untuk mengevaluasi sejauh mana model yang telah dilatih mampu mengenali dan mengklasifikasikan berbagai objek di lingkungan nyata, seperti kardus aqua, kardus lemineral, kardus susu

anak, kardus indomilk, helem safety, galon aqua, galon mineral dan pallet kayu, secara akurat dan real-time. Proses pengujian dilakukan menggunakan dataset yang telah melalui tahap anotasi dengan Roboflow, kemudian dilakukan pelatihan menggunakan konfigurasi parameter tertentu untuk memperoleh model terbaik (best.pt). Hasil yang ditampilkan mencakup analisis grafik pelatihan, confusion matrix, hasil deteksi pada citra uji nyata, serta pembahasan mengenai performa sistem secara keseluruhan.

3.1 Hasil Pelatihan Model YOLOv11

Pelatihan model deteksi objek menggunakan YOLOv11 dilakukan selama 100 epoch dengan ukuran citra 640×640 piksel dan batch size 16. Proses pelatihan menghasilkan grafik metrik performa yang ditunjukkan pada Gambar 3.




Gambar 3. Grafik Hasil training

Dari hasil pelatihan pada Gambar 4.1, terlihat bahwa nilai box_loss, cls_loss, dan dfl_loss pada data pelatihan dan validasi mengalami penurunan signifikan seiring bertambahnya epoch. Hal ini menunjukkan bahwa model berhasil mempelajari fitur-fitur penting dari objek secara optimal. Nilai box_loss turun dari 0,6 menjadi 0,2, cls_loss dari 2,0 menjadi 0,3, dan dfl_loss dari 1,0 menjadi 0,85. Pada sisi lain, nilai precision meningkat hingga sekitar 0,90, recall mencapai 0,88, sedangkan nilai mAP@50 dan mAP@50–95 masing-masing mencapai 0,93 dan 0,87. Berdasarkan grafik tersebut, model YOLOv11 menunjukkan tingkat konvergensi yang stabil dan tidak

terjadi overfitting yang signifikan antara data pelatihan dan validasi.

3.2 Evaluasi Kinerja Model (Confusion Matrix)

Evaluasi model dilakukan menggunakan dataset uji yang terdiri dari 8 kelas objek, yaitu galon aqua, galon mineral, helm safety, kardus aqua, kardus Indomilk, kardus Le Minerale, kardus susu anak, dan pallet kayu. Dataset ini dipilih untuk merepresentasikan berbagai jenis objek yang umum ditemukan di lingkungan pergudangan dan industri logistik, di mana setiap objek memiliki bentuk, ukuran, serta tekstur yang berbeda-beda. Pengujian dilakukan dengan tujuan untuk mengetahui kemampuan model dalam mengenali dan mengklasifikasikan setiap objek secara akurat di bawah berbagai kondisi pencahayaan dan sudut pengambilan gambar yang bervariasi. Visualisasi hasil evaluasi berupa confusion matrix ditampilkan pada Gambar 4.



Gambar 4. Hasil confusion Matrix training

Berdasarkan confusion matrix pada Gambar 4, dapat diamati bahwa model YOLOv11 menunjukkan tingkat akurasi yang sangat baik dalam mengklasifikasikan sebagian besar kelas objek yang diuji. Secara keseluruhan, hasil evaluasi memperlihatkan bahwa model mampu mengenali delapan kelas objek galon aqua, galon mineral, helm safety, kardus aqua, kardus Indomilk, kardus Le Minerale, kardus susu anak, dan pallet kayu dengan tingkat ketepatan yang tinggi serta kesalahan deteksi yang relatif kecil.

Kelas kardus Indomilk dan kardus Le Minerale menunjukkan hasil paling optimal, masing-masing dengan

300 dan 299 prediksi benar, tanpa adanya kesalahan klasifikasi signifikan. Kedua kelas ini memiliki ciri visual yang cukup khas dari segi warna dan tekstur, sehingga mudah dikenali oleh model. Sementara itu, kelas galon Aqua dan galon Mineral juga menunjukkan performa yang sangat baik, dengan tingkat ketepatan di atas 95%, dan hanya terdapat kurang dari 5 sampel yang salah terdeteksi akibat kesamaan bentuk dan pantulan cahaya pada permukaan galon.


Untuk kelas helm safety, model mampu mendeteksi 287 dari 300 sampel dengan benar, sementara sisanya keliru terklasifikasi sebagai latar belakang (background) karena variasi posisi dan pencahayaan yang ekstrem. Kelas kardus Aqua juga menunjukkan performa tinggi dengan 294 prediksi benar, dengan sebagian kecil kesalahan akibat kemiripan visual dengan kardus Le Minerale.

Pada kelas kardus susu anak, hasil deteksi mencapai 283 sampel benar dari total 300, dengan sebagian kesalahan kecil yang disebabkan oleh kemiripan pola warna dengan kardus Indomilk. Sementara itu, pada kelas pallet kayu, model berhasil mengenali 191 sampel dengan benar, meskipun masih terdapat beberapa kesalahan klasifikasi terhadap kelas “background” akibat tekstur kayu yang menyerupai permukaan lantai.

Secara umum, distribusi hasil pada confusion matrix menunjukkan bahwa YOLOv11 mampu mendeteksi objek-objek pada lingkungan pergudangan dengan tingkat akurasi rata-rata mencapai 93%, dengan nilai Precision sebesar 0,90 dan Recall sebesar 0,88. Hasil ini membuktikan bahwa model tidak hanya unggul dalam mengenali objek yang memiliki perbedaan visual yang jelas, tetapi juga cukup andal dalam menghadapi objek dengan kesamaan bentuk atau warna di bawah kondisi pencahayaan yang beragam.

3.3 Hasil Deteksi Objek pada Lingkungan Nyata

Untuk menguji kemampuan model secara langsung, dilakukan implementasi sistem deteksi real-time menggunakan kamera dengan objek di lingkungan nyata. Hasil uji coba ditunjukkan pada Gambar 5.



Gambar 5. Hasil Deteksi Objek

Pada Gambar 5 terlihat bahwa sistem berhasil mendeteksi seluruh objek yang terdapat pada area uji, seperti kardus Aqua, kardus susu anak, kardus Indomilk, kardus Le Mineral, galon air, helm safety, serta pallet kayu. Setiap objek diberi bounding box berwarna berbeda dengan label kelas dan nilai confidence score di atas 0.95, menunjukkan tingkat keyakinan tinggi dari model terhadap hasil deteksi. Khusus untuk objek pallet kayu, model memberikan nilai confidence 0.97, menunjukkan kemampuan yang sangat baik dalam mengenali bentuk persegi panjang dengan tekstur kayu yang kompleks. Hal ini memperlihatkan keunggulan YOLOv11 dalam mendeteksi objek yang memiliki pola geometri dan tekstur berbeda di lingkungan nyata.

3.4 Perhitungan Akurasi Model

Untuk mengukur kinerja model secara kuantitatif, digunakan rumus akurasi sebagai berikut :

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Dengan keterangan dimana TP (True Positive) jumlah objek yang terdeteksi dengan benar sesuai kelasnya, TN (True Negative) jumlah citra non-objek yang diklasifikasikan dengan benar, FP (False Positive) jumlah objek yang salah diklasifikasikan, dan FN (False Negative) jumlah objek yang tidak terdeteksi. Berdasarkan hasil confusion matrix pada Gambar 4, total deteksi benar (TP + TN) mendominasi dibandingkan jumlah kesalahan (FP + FN). Dengan menghitung seluruh elemen pada matriks, diperoleh nilai akurasi model sebagai berikut :

$$\text{Akurasi} = \frac{865 + 720}{865 + 720 + 92 + 61} = \frac{1585}{1738} = 0.911$$

Dari hasil tersebut, diperoleh tingkat akurasi sebesar 91,1%. Nilai ini menunjukkan bahwa model YOLOv11 memiliki performa yang baik dalam mendeteksi objek-objek di lingkungan nyata. Nilai-nilai tersebut menegaskan bahwa YOLOv11 tidak hanya akurat tetapi juga stabil dan efisien untuk aplikasi deteksi objek secara real-time

4 Kesimpulan

Berdasarkan analisis hasil penelitian dan pengujian, dapat disimpulkan bahwa model *object detection* telah berhasil dibangun dan berfungsi dengan baik. Secara kualitatif, model menunjukkan kinerja yang sangat tinggi, mampu mendeteksi berbagai objek secara bersamaan—termasuk yang tumpang tindih—dengan tingkat kepercayaan (confidence) rata-rata di atas 0.95 (95%). Berdasarkan *confusion matrix*, model ini terbukti memiliki akurasi klasifikasi yang sangat baik, mampu membedakan dengan jelas antar kelas objek yang serupa, seperti antara galon aqua dan galon mineral, serta di antara berbagai jenis kardus dengan tingkat kebingungan (confusion) yang sangat minim. Meskipun demikian, kelemahan utama model adalah tingginya jumlah *False Negatives*, di mana model sering gagal mendeteksi objek yang ada dan salah mengklasifikasikannya sebagai background, terutama untuk kelas kardus aqua, kardus indomilk, dan helm safety. Selain itu, model juga menunjukkan kelemahan sekunder berupa *False Positives*, yaitu kecenderungan salah mengidentifikasi area *background* sebagai objek, paling sering sebagai pallet kayu dan kardus susu anak. Secara keseluruhan, model ini sangat andal dalam membedakan *jenis* objek, namun masih memiliki tantangan signifikan dalam membedakan antara 'objek' dan 'bukan objek' (background)

Daftar Pustaka

- [1] J. Yang *et al.*, “SCD: A Stacked Carton Dataset for Detection and Segmentation,” *Sensors*, vol. 22, no. 10, pp. 1–23, 2022, doi: 10.3390/s22103617.
- [2] J. Castaño-Amoros, F. Fuentes, and P. Gil, “MOSPAA: monitoring system for palletised packaging recognition and tracking,” *Int. J. Adv. Manuf. Technol.*, vol. 126, no. 1–2, pp. 179–195, 2023, doi: 10.1007/s00170-023-11098-6.
- [3] J. Zhao, B. Li, X. Wei, H. Lu, E. Lü, and X. Zhou, “Recognition and Location Algorithm for Pallets in Warehouses Using RGB-D Sensor,” *Appl. Sci.*, vol. 12, no. 20, 2022, doi: 10.3390/app122010331.
- [4] T. Li, B. Huang, C. Li, and M. Huang, “Application of convolution neural network object detection algorithm in logistics warehouse,” *J.*

- Eng.*, vol. 2019, no. 23, pp. 9053–9058, 2019, doi: 10.1049/joe.2018.9180.
- [5] I. Irmawan, R. Rendiansyah, G. Gustini, and S. A. Harahap, “Identifikasi Dan Klasifikasi Penyakit Pada Tanaman Kopi Arabica Dengan Metode Cnn Dan Transfer Learning Densenet-201,” *Transm. J. Ilm. Tek. Elektro*, vol. 27, no. 2, pp. 83–91, 2025, doi: 10.14710/transmisi.27.2.83-91.
- [6] M. Glučina, S. Baressi Šegota, N. Anđelić, and Z. Car, “Automated Detection and Classification of Returnable Packaging Based on YOLOV4 Algorithm,” *Appl. Sci.*, vol. 12, no. 21, 2022, doi: 10.3390/app122111131.