

Fine-Tuning Model YOLOv8 untuk Meningkatkan Robustness pada Implementasi Deteksi Produk Di Kasir Koperasi

¹Rafi Achmad Fachrudi, ²Daniel Swanjaya, ³Danar Putra Pamungkas

¹⁻³Universitas Nusantara PGRI Kediri

¹achmadfahrudi153@gmail.com, ²daniel@unpkediri.ac.id,

³danar@unpkediri.ac.id

Penulis Korespondensi: Rafi Achmad Fachrudi

Abstrak— Penelitian ini bertujuan untuk mengembangkan sistem deteksi objek menggunakan model YOLOv8 guna mendukung sistem kasir cerdas tanpa barcode di koperasi. Model dilatih menggunakan dataset produk minuman kemasan yang dikumpulkan secara mandiri, kemudian dilakukan fine-tuning dengan data tambahan yang lebih bervariasi dari segi sudut, pencahayaan, dan kondisi objek. Hasil pengujian menunjukkan bahwa model fine-tuned lebih andal dalam mengenali objek di kondisi nyata meskipun terdapat penurunan pada beberapa metrik seperti precision dan mAP-50. Pendekatan augmentasi data dan pengaturan ulang pelatihan (freeze layer) terbukti meningkatkan kemampuan generalisasi model. Penelitian ini menunjukkan bahwa YOLOv8 dapat menjadi solusi efektif untuk otomatisasi kasir di lingkungan koperasi dan usaha kecil, serta mendukung upaya digitalisasi di sektor tersebut.

Kata kunci: deteksi objek; fine-tuning, koperasi; sistem kasir cerdas; YOLOv8

Abstract— This study aims to develop an object detection system using the YOLOv8 model to support a barcode-free smart cashier system in cooperatives. The model was trained on a self-collected dataset of packaged beverage products, followed by fine-tuning with additional data featuring varied angles, lighting, and object conditions. The evaluation results show that the fine-tuned model is more reliable in recognizing objects in real-world scenarios, despite a slight decrease in metrics such as precision and mAP-50. The data augmentation and training reconfiguration (freeze layer) approach proved to improve the model's generalization capabilities. This research demonstrates that YOLOv8 can be an effective solution for cashier automation in cooperatives and small businesses, supporting digital transformation in the sector.

Keywords: cooperative ; object detection; fine-tuning; smart cashier system; YOLOv8

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Kemajuan teknologi di bidang pengolahan citra dan kecerdasan buatan telah membuka banyak peluang untuk mempermudah pekerjaan manusia, salah satunya adalah teknologi deteksi objek. Salah satu pendekatan yang saat ini populer dan terus berkembang adalah YOLO (You Only Look Once), yang telah sampai pada versi ke-delapan yaitu YOLOv8. YOLOv8 dikenal dengan arsitekturnya yang lebih ringan, cepat, dan akurat, sehingga banyak digunakan dalam berbagai aplikasi, termasuk untuk mendeteksi kendaraan, keamanan, hingga produk di toko.

Dalam dunia ritel, deteksi produk secara otomatis bisa membantu mempercepat proses transaksi dan mengurangi kesalahan kasir. Pada salah satu studi lain, mengembangkan sistem kasir otomatis berbasis YOLOv8 yang dilengkapi dengan pelatihan ulang (*fine-tuning*), penambahan data (augmentasi), dan pelacakan objek[1]. Hasilnya menunjukkan bahwa pendekatan tersebut mampu mengatasi tantangan seperti pencahayaan yang tidak merata dan kemiripan antar produk, serta mendapatkan skor F1 sebesar 0,8177.

Namun, meskipun YOLOv8 menjanjikan performa yang baik, penerapannya di kondisi nyata seperti di toko atau koperasi kecil tidak selalu mudah. Model sering mengalami *overfitting* jika hanya dilatih dengan data terbatas, dan performanya bisa turun saat menghadapi latar belakang dan pencahayaan yang berbeda dari saat pelatihan. Penelitian sebelumnya menyebutkan bahwa dengan menambahkan teknik regularisasi seperti *dropout* serta menggunakan beberapa versi arsitektur YOLOv8 (seperti versi *small* hingga *extra-large*), performa model bisa ditingkatkan[2].

Beberapa penelitian lainnya juga mendukung pendekatan *fine-tuning* dan augmentasi data untuk meningkatkan akurasi deteksi objek di lingkungan nyata. Misalnya, peningkatan akurasi model untuk mendeteksi buah dengan cara menyesuaikan pelatihan hanya di bagian tertentu dari YOLOv8[3]. Sementara itu pada sebuah penelitian menunjukkan bahwa kombinasi pengaturan hyperparameter dan augmentasi data bisa menghasilkan akurasi tinggi dalam mendeteksi alat pelindung diri di area konstruksi[4].

Salah satu artikel dalam pembahasannya menggunakan teknik bernama SAHI (*Selective Area HI*) untuk mendeteksi objek kecil seperti hama tanaman, dan berhasil menjaga akurasi model tetap tinggi meskipun dalam kondisi nyata yang sulit[5]. Semua penelitian tersebut menunjukkan bahwa dengan penyesuaian pelatihan dan penambahan variasi data, YOLOv8 bisa lebih tangguh saat digunakan di dunia nyata.

Berdasarkan hal-hal di atas, penting untuk melakukan penelitian lebih lanjut agar YOLOv8 bisa diterapkan secara optimal di lingkungan nyata seperti koperasi atau toko ritel. Penelitian ini akan fokus pada bagaimana strategi *fine-tuning* dan augmentasi data bisa meningkatkan kemampuan YOLOv8 dalam mengenali produk, meskipun kondisi pencahayaan, latar belakang, dan kemasan produk berbeda-beda.

Permasalahan yang ingin dikaji dalam penelitian ini adalah bagaimana performa model YOLOv8 dalam mendeteksi produk di lingkungan ritel nyata yang memiliki kondisi pencahayaan dan latar belakang yang beragam. Selain itu, penelitian ini juga mempertanyakan apakah strategi *fine-tuning* dan augmentasi data mampu meningkatkan akurasi dan ketahanan (*robustness*)

model, serta sejauh mana pengaruh perbedaan varian arsitektur YOLOv8 terhadap risiko overfitting dan kemampuan generalisasi dalam kondisi nyata.

Penelitian ini bertujuan untuk menganalisis kinerja model YOLOv8 dalam mendeteksi produk ritel secara otomatis di lingkungan nyata, serta mengevaluasi efektivitas strategi *fine-tuning* dan augmentasi data dalam meningkatkan performa model. Selain itu, penelitian ini juga ingin membandingkan beberapa varian arsitektur YOLOv8 (*small, medium, large, extra-large*) guna mengetahui varian terbaik dalam hal generalisasi dan ketahanan terhadap tantangan dunia nyata.

hasil penelitian ini dapat dimanfaatkan oleh pelaku usaha kecil dan koperasi sebagai solusi alternatif dalam mempercepat proses transaksi tanpa bergantung pada sistem barcode, sekaligus mendukung digitalisasi inventaris berbasis kecerdasan buatan.

II. METODE

Penelitian ini dilakukan dalam bentuk studi eksperimental komparatif yang bertujuan untuk mengevaluasi performa model deteksi objek berbasis YOLOv8 sebelum dan sesudah proses *fine-tuning*[6]. Fokus utama penelitian ini adalah menganalisis pengaruh penambahan data dengan variasi kondisi terhadap performa model, serta mengkaji efektivitas strategi *fine-tuning* dalam mengurangi risiko *overfitting* pada model dasar.

A. Subjek dan Bahan

Penelitian ini menggunakan dataset citra produk sebanyak 10 kelas/label, masing-masing kelas memiliki 50 data gambar awal, sehingga total awal berjumlah 500 gambar. Data ini merupakan citra produk seperti minuman botol dan kopi kemasan, yang umum dijumpai di lingkungan koperasi atau warung kecil. Setiap citra diambil dengan kondisi latar belakang dan pencahayaan yang seragam, hanya memiliki variasi posisi objek. Data kemudian ditambah 25 gambar per kelas dengan variasi lebih kompleks, seperti perubahan sudut pengambilan gambar, pencahayaan berbeda, objek sebagian tertutup, hingga jarak pengambilan gambar yang bervariasi, sehingga total menjadi 750 data gambar.

B. Alat dan Perangkat

Proses pelatihan model dilakukan menggunakan bantuan Google Colab dengan pemrosesan berbasis GPU (NVIDIA Tesla T4). *Framework* yang digunakan untuk pelatihan model adalah YOLOv8 (Ultralytics), dijalankan dalam lingkungan Python dengan bantuan pustaka torch, opencv, dan ultralytics.

C. Perancangan Sistem

Rancangan sistem disusun berdasarkan tahapan sebagai berikut:

1. Pengumpulan Dataset

Pengumpulan dilakukan secara mandiri dengan mengambil gambar produk secara langsung menggunakan kamera ponsel, kemudian dilabeli secara manual dengan bantuan

aplikasi Roboflow. Dataset yang dikumpulkan meliputi 10 objek dengan jumlah data sebagai berikut:

Tabel 1. Tebel Pembagian Data

Pembagian Dataset			
Nama produk	Data awal	Data tambahan	Total data
Ades	50	25	75
Aqua	50	25	75
Floridina	50	25	75
Milku	50	25	75
Mizone	50	25	75
Orange Water	50	25	75
Pocari	50	25	75
Teh Pucuk	50	25	75
Ultrajaya Kacang Hijau	50	25	75
Ultramilk	50	25	75


Tabel 1 menyajikan rincian pembagian dataset yang digunakan dalam penelitian. Dataset ini mencakup 10 jenis produk yang berbeda, di mana setiap jenis produk awalnya memiliki 50 data. Untuk memperkaya variasi dan jumlah data pelatihan, ditambahkan 25 data tambahan untuk setiap produk. Dengan demikian, total data yang digunakan untuk setiap jenis produk menjadi 75, sehingga menghasilkan dataset yang lebih komprehensif untuk melatih model deteksi objek.

2. Preprocessing dan Split Data

Data yang telah dikumpulkan terlebih dahulu dilabeli menggunakan platform Roboflow dengan format anotasi YOLO. Setelah itu, data dibagi menjadi tiga bagian: 70% untuk pelatihan, 20% untuk validasi, dan 10% untuk pengujian[7]. Pembagian ini dilakukan secara acak namun tetap menjaga proporsi antar kelas agar seimbang. Seluruh gambar juga disesuaikan ke ukuran 640×640 piksel sesuai standar input YOLOv8.

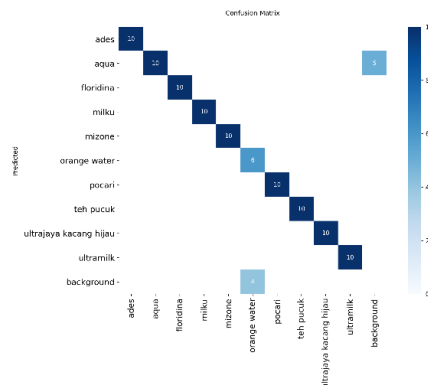
3. Pelatihan Model Dasar (Base Model)

Model dasar yang digunakan adalah YOLOv8n (nano). Pelatihan awal dilakukan dengan parameter *default* dan jumlah *epoch* sebanyak 100 [8]. Tidak ada pembekuan lapisan (freeze) pada model awal. Hasil dari pelatihan model dapat dilihat dari gambar berikut ini:



Gambar 1. Gambar hasil *training based model*

Grafik hasil pelatihan dari *based model* menunjukkan bahwa selama 100 *epoch*, nilai *loss* (baik *training* maupun *validation*) sudah secara konsisten menurun dan stabil, mengindikasikan model berhasil belajar dan konvergen. Bersamaan dengan itu, metrik kinerja seperti *precision*, *recall*, *mAP50*, dan *mAP50-95* menunjukkan peningkatan pesat di awal dan kemudian stabil pada nilai tinggi, menandakan model mencapai performa optimal dalam deteksi objek.




Gambar 2. Gambar *confussion matrix* dari based model

Hasil dari *confusion Matrix* menunjukkan bahwa model dasar berhasil mendeteksi sebagian besar produk dengan baik (seperti "ades", "milku", "mizone", dll.). Namun, terdapat beberapa kelemahan signifikan: 5 instans "orange water" salah terdeteksi sebagai "aqua", 4 instans "mizone" terdeteksi sebagai "orange water", dan 5 instans "aqua" gagal terdeteksi (masuk *background*). Ini menandakan model dasar memiliki akurasi yang baik pada umumnya tetapi masih lemah dalam membedakan beberapa produk serupa dan mengalami *false negatives* yang cukup banyak pada "aqua".

4. Fine-Tuning Model


Setelah model dasar selesai, dilakukan pelatihan tambahan (*fine-tuning*) dengan data yang telah ditambahkan variasi. Model dilatih ulang menggunakan parameter *freeze* 10 (lapisan awal dibekukan) dan *epoch* sebanyak 30, untuk meningkatkan kemampuan generalisasi terhadap kondisi dunia nyata[9].



Gambar 3. Gambar hasil *training* model *fine-tuned*

Grafik hasil pelatihan model setelah *fine-tuning* menunjukkan pola yang serupa dengan model dasar, namun dengan beberapa peningkatan. Nilai *loss* (termasuk *box loss*, *cls loss*, dan *dfl loss*) untuk *training* dan *validation* secara konsisten menurun seiring *epoch* dan mencapai stabilitas, mengindikasikan proses pembelajaran yang efektif dan konvergensi model.

Pada metrik kinerja seperti *precision*, *recall*, *mAP50*, dan *mAP50-95*, terlihat peningkatan cepat di awal *epoch* dan kemudian stabil pada nilai yang tinggi. Hal ini menunjukkan bahwa *fine-tuning* berhasil mengoptimalkan kemampuan model dalam deteksi dan klasifikasi objek, mencapai performa yang kuat dalam jumlah *epoch* yang relatif singkat.



Gambar 4. Gambar *confussion matrix* dari *based model*

Sementara itu hasil *confusion Matrix* menunjukkan peningkatan akurasi model setelah *fine-tuning*, dengan sebagian besar produk terdeteksi dengan benar (5 instans per kelas). Namun, masih ada tantangan: 6 instans "ades" salah terdeteksi sebagai "ultramilk", 1 "floridina" sebagai "ultrajaya kacang hijau". Selain itu, terjadi *false negatives* yang signifikan pada "teh pucuk" (9 instans) serta 1 instans "aqua" dan 1 "ultramilk" terklasifikasi sebagai *background*. Secara keseluruhan, *fine-tuning* meningkatkan akurasi namun perlu perbaikan pada pemisahan kelas serupa dan pengurangan *false negatives*.

5. Evaluasi Model

Model dievaluasi menggunakan metrik umum pada deteksi objek, yaitu *Precision*, *Recall*, *mAP* (*mean Average Precision*), dan *mAP-50*[10]. Kedua model dilakukan evaluasi menggunakan metrics tersebut dan menghasilkan data evaluasi model seperti berikut ini:

Tabel 2. Tabel Metrik Evaluasi

Metrik Evaluasi		
Metrik	Base Model	Fine-tuned Model
<i>Precision</i>	95	92
<i>Recall</i>	96	92
mAP	96	96
mAP-50	84	80

Adapun hasil pengukuran menunjukkan bahwa model awal (*base model*) memperoleh *precision* sebesar 95%, *recall* 96%, mAP 96%, dan mAP-50 sebesar 84%. Setelah dilakukan *fine-tuning*, model menghasilkan *precision* sebesar 92%, *recall* 92%, mAP tetap pada 96%, namun mAP-50 mengalami penurunan ke angka 80. Penurunan ini menunjukkan bahwa model menjadi lebih adaptif terhadap kondisi bervariasi, meskipun terjadi sedikit kompromi pada deteksi sederhana.

D. Analisis dan Interpretasi

Perbedaan hasil antara model awal dan model setelah *fine-tuning* menunjukkan bahwa meskipun terjadi sedikit penurunan pada metrik mAP-50, model yang telah dituning menjadi lebih robust terhadap kondisi lingkungan nyata yang tidak ideal. Hal ini sesuai dengan tujuan penelitian, yaitu menyiapkan sistem deteksi objek yang lebih siap digunakan dalam lingkungan masyarakat dengan variasi pencahayaan, posisi, dan kualitas gambar.

III. HASIL DAN PEMBAHASAN

A. Pengujian Sistem

Pengujian dilakukan terhadap dua versi model deteksi objek berbasis YOLOv8, yaitu model lama (*based model*) dan model hasil *tuning*. Pengujian bertujuan untuk membandingkan performa kedua model dalam mengenali objek produk minuman kemasan, yang terdiri dari lima kategori: Aqua, Mizone, Orange Water, Teh Pucuk, dan Ultramilk. Setiap objek diuji sebanyak enam kali menggunakan gambar yang bervariasi dari segi sudut pandang dan pencahayaan.

Parameter utama yang diamati meliputi:

1. Keberhasilan deteksi objek yang sesuai label (benar).
2. Kesalahan klasifikasi (label salah).
3. Kegagalan deteksi (tidak terdeteksi).
4. Confidence Score dari setiap deteksi.

B. Hasil Pengujian

Tabel 3 menyajikan perbandingan hasil deteksi antara model lama dan model hasil tuning untuk tiap objek yang diuji.

Tabel 3. Tabel Hasil Pengujian Model lama dan Model setelah Tuning

Rekap Hasil Pengujian Model					
Objek	Model	Deteksi Benar	Salah Deteksi	Gagal Deteksi	Rata-rata Confidence
Aqua	Lama	2	2	2	0.56
	Tuning	5	0	1	0.82
Mizone	Lama	4	2	0	0.92
	Tuning	6	0	0	0.84
Orange Water	Lama	3	3	0	0.71
	Tuning	6	0	0	0.61
Teh Pucuk	Lama	4	0	2	0.89
	Tuning	5	1	0	0.92
Ultramilk	Lama	6	0	0	0.81
	Tuning	6	0	0	0.90

Pengujian dilakukan untuk membandingkan kinerja deteksi objek antara model dasar dan model yang telah melalui proses *tuning*. Percobaan ini melibatkan lima jenis produk, yaitu Aqua, Mizone, Orange Water, Teh Pucuk, dan Ultramilk.

Pada pengujian produk Aqua, model dasar berhasil melakukan 2 deteksi benar dengan rata-rata *confidence score* 0.56, serta mencatat 2 kegagalan deteksi. Setelah *tuning*, model mampu melakukan 5 deteksi benar dan hanya 1 kegagalan deteksi, dengan rata-rata *confidence score* meningkat menjadi 0.82. Untuk produk Mizone, model dasar menghasilkan 4 deteksi benar dan 2 salah deteksi, dengan rata-rata *confidence score* 0.92. Setelah *tuning*, seluruh 6 percobaan menghasilkan deteksi benar tanpa adanya kesalahan atau kegagalan deteksi, dengan rata-rata *confidence score* 0.84.

Kemudian ada produk Orange Water, model dasar mencatat 3 deteksi benar dan 3 salah deteksi, dengan rata-rata *confidence score* 0.71. Setelah *tuning*, model mencapai 6 deteksi benar tanpa adanya kesalahan atau kegagalan deteksi, dengan rata-rata *confidence score* 0.61. Pengujian produk Teh Pucuk menunjukkan model dasar dengan 4 deteksi benar dan 2 kegagalan, serta rata-rata *confidence score* 0.89. Setelah *tuning*, deteksi benar meningkat menjadi 5, dengan 1 salah deteksi dan rata-rata *confidence score* 0.92.

Terakhir, untuk produk Ultramilk, baik model dasar maupun model setelah *tuning* berhasil mencatat 6 deteksi benar tanpa adanya kesalahan atau kegagalan deteksi. Rata-rata *confidence score* untuk model dasar adalah 0.81, sementara model setelah *tuning* menunjukkan peningkatan menjadi 0.90.

C. Pembahasan

Berdasarkan hasil pengujian, terlihat bahwa model hasil tuning mampu memberikan performa deteksi yang lebih akurat dan stabil dibandingkan model lama. Pada objek Aqua,

terjadi peningkatan signifikan dari hanya 2 deteksi benar menjadi 5 kali, dengan peningkatan rata-rata confidence dari 0.56 menjadi 0.82. Pada Mizone, kesalahan deteksi sebelumnya berhasil dieliminasi sepenuhnya, menunjukkan perbaikan konsistensi meskipun dengan sedikit penurunan confidence.

Objek Orange Water menjadi salah satu contoh keberhasilan tuning dalam memperbaiki klasifikasi; model lama mengalami 3 kesalahan klasifikasi, sementara model tuning berhasil mendeteksi seluruhnya dengan label yang tepat, meski nilai confidence masih bervariasi. Teh Pucuk juga mengalami peningkatan dari segi keandalan deteksi, dengan confidence yang lebih tinggi dan hanya satu percobaan yang kurang akurat. Untuk objek Ultramilk, kedua model menunjukkan kinerja yang baik, namun model tuning mampu meningkatkan rata-rata confidence menjadi 0.90.

Hasil ini menunjukkan bahwa proses fine-tuning model berperan penting dalam meningkatkan akurasi deteksi objek serta mengurangi kesalahan klasifikasi. Keberhasilan tuning dalam beberapa kategori objek memperlihatkan bahwa penyesuaian terhadap data latih yang lebih relevan mampu memperkuat kemampuan generalisasi model terhadap kondisi nyata di lapangan.

IV. KESIMPULAN

Penelitian ini membuktikan bahwa model deteksi objek YOLOv8 sangat cocok digunakan dalam sistem kasir otomatis, terutama di koperasi atau toko kecil. Peneliti menggunakan gambar-gambar produk minuman kemasan yang dikumpulkan sendiri, lalu melatih model YOLOv8n sebagai model awal. Setelah itu, model dilatih lagi (fine-tuning) dengan data tambahan yang lebih beragam dari segi posisi, pencahayaan, dan kondisi gambar. Hasil pengujian menunjukkan bahwa walaupun nilai akurasi model fine-tuned sedikit menurun pada beberapa metrik, model ini justru lebih handal saat digunakan di kondisi nyata yang tidak sempurna. Model hasil pelatihan ulang ini juga lebih konsisten mengenali produk meskipun latar belakang atau pencahayaannya berubah. Ini menunjukkan bahwa menambah variasi data dan mengatur ulang pelatihan bisa membuat model lebih pintar dan fleksibel. Secara keseluruhan, cara pelatihan ini terbukti dapat meningkatkan kemampuan YOLOv8 untuk mendeteksi produk, dan sangat bermanfaat untuk mengembangkan sistem kasir pintar tanpa barcode yang mendukung digitalisasi koperasi dan usaha kecil.

DAFTAR PUSTAKA

- [1] A. Vats and D. C. Anastasiu, "Enhancing Retail Checkout through Video Inpainting, YOLOv8 Detection, and DeepSort Tracking," *IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit. Work.*, vol. 2023-June, pp. 5530–5537, 2023, doi: 10.1109/CVPRW59228.2023.00585.
- [2] W. Yulita, U. A. Ramadhani, Z. Mufidah, G. K. M. Atmajaya, and R. Bagaskara, "Improved human image density detection with comparison of YOLOv8 depth level architecture and drop-out implementation," pp. 33–39, 2025, doi: <https://doi.org/10.52465/joscex.v6i1.556>.
- [3] V. Gandhi and S. Gandhi, "Fine-Tuning Without Forgetting: Adaptation of YOLOv8

- Preserves COCO Performance,” 2025, [Online]. Available: <http://arxiv.org/abs/2505.01016>, doi: <https://doi.org/10.48550/arXiv.2505.01016>.
- [4] Z. R. Utomo, P. W. Adi, P. S. Sasongko, and G. Rahman, “Development and Optimization of a Construction Personal Protective Equipment (PPE) Detection Model on YOLOv8 Architecture,” vol. 16, no. March, pp. 1–14, 2025, doi: 10.14710/jmasif.16.1.71622.
- [5] R. Ye, Q. Gao, Y. Qian, J. Sun, and T. Li, “Improved YOLOv8 and SAHI Model for the Collaborative Detection of Small Targets at the Micro Scale: A Case Study of Pest Detection in Tea,” *Agronomy*, vol. 14, no. 5, 2024, doi: 10.3390/agronomy14051034.
- [6] O. Selsa, I. Anggraeni, and P. T. Informatika, “Studi Komparatif Performa Framework Javascript Modern dalam Pengembangan Aplikasi Web,” vol. 2, no. 4, pp. 162–177, 2024, doi: <https://doi.org/10.62951/modem.v2i4.239>.
- [7] E. U. Armin, A. Purnama Edra, F. I. Alifin, I. Sadidan, I. P. Sary, and U. Latifa, “Performa Model YOLOv8 untuk Deteksi Kondisi Mengantuk pada pengendara mobil,” *BRAHMANA J. Penerapan Kecerdasan Buatan*, vol. 5, no. 1, pp. 67–76, 2023, [Online]. Available: <https://doi.org/10.30645/brahmana.v5i1.279>
- [8] D. Reis, J. Hong, J. Kupec, and A. Daoudi, “Real-Time Flying Object Detection with YOLOv8,” doi: <https://doi.org/10.48550/arXiv.2305.09972>.
- [9] J. Lee, R. Tang, and J. Lin, “What Would Elsa Do? Freezing Layers During Transformer Fine-Tuning,” 2018, doi: <https://doi.org/10.48550/arXiv.1911.03090>.
- [10] Z. F. Khan, M. Ramzan, M. Raza, S. Member, and M. A. Khan, “Real-Time Polyp Detection From Endoscopic Images Using YOLOv8 With YOLO-Score Metrics for Enhanced Suitability Assessment,” *IEEE Access*, vol. 12, no. December, pp. 176346–176362, 2024, doi: 10.1109/ACCESS.2024.3505619.