



Pendekatan YOLOv5 dalam Mendeteksi dan Mengklasifikasikan Obyek Lalu Lintas serta Pelanggaran Melawan Arah

Bambang Minto Basuki^{1*}, Ondang Fajrul Falach²

^{1,2}Fakultas Teknik, Teknik Elektro, Universitas Islam Malang, Indonesia

*Penulis Korespondensi: bambang.minto@unisma.ac.id

Abstract. *The increasing intensity of traffic object movement in urban areas has not been accompanied by adequate road infrastructure, resulting in traffic congestion, air pollution, and a higher risk of traffic accidents. One of the primary causes of accidents is traffic violations, particularly wrong-way driving behavior. This study develops a video-based automated traffic violation detection system using the YOLOv5 algorithm. A computer vision approach is employed to detect, classify traffic objects, and count wrong-way violations in real time. Due to limited access to real-world traffic violation footage, simulated traffic scenarios are used as testing data. The system is evaluated on four traffic object classes: motorcycles, cars, buses, and trucks. Experimental results demonstrate strong performance, achieving a precision of 90%, a recall of 92%, and an F1-score of 91%, while the traffic object counting accuracy reaches 89%. These findings indicate that the proposed system has significant potential to support traffic analysis and assist authorities in making more effective decisions to reduce congestion and traffic accidents.*

Keywords: SORT; Traffic Object Classification; Traffic Object Counting; Traffic Object Detection; YOLOv5.

Abstrak. Peningkatan intensitas pergerakan obyek lalu lintas di wilayah perkotaan belum diikuti oleh ketersediaan infrastruktur jalan yang memadai, sehingga berdampak pada kemacetan, pencemaran udara, serta tingginya risiko kecelakaan lalu lintas. Salah satu faktor utama penyebab kecelakaan adalah pelanggaran aturan berkendara, khususnya perilaku melawan arah arus lalu lintas. Penelitian ini mengembangkan sistem otomatis berbasis video untuk mendeteksi pelanggaran lalu lintas dengan memanfaatkan algoritma YOLOv5. Pendekatan computer vision digunakan untuk melakukan pendeteksian, pengklasifikasian obyek lalu lintas, serta perhitungan jumlah pelanggaran melawan arah secara real-time. Keterbatasan akses terhadap rekaman pelanggaran nyata menyebabkan penggunaan skenario simulasi lalu lintas sebagai data pengujian. Sistem diuji menggunakan empat kelas obyek lalu lintas, yaitu sepeda motor, mobil, bus, dan truk. Hasil evaluasi menunjukkan kinerja yang baik dengan nilai precision sebesar 90%, recall 92%, dan F1-score 91%, sementara tingkat akurasi perhitungan obyek lalu lintas mencapai 89%. Temuan ini mengindikasikan bahwa sistem memiliki potensi signifikan dalam mendukung analisis kondisi lalu lintas serta membantu pihak berwenang dalam pengambilan keputusan guna menekan tingkat kemacetan dan kecelakaan.

Kata kunci: Deteksi Obyek Lalu Lintas; Klasifikasi Obyek Lalu Lintas; Perhitungan Obyek Lalu Lintas; YOLOv5 SORT; YOLOv5.

1. LATAR BELAKANG

Di kota-kota besar di Indonesia, pertumbuhan jumlah objek lalu lintas pribadi mengalami peningkatan signifikan. Fenomena ini tidak diimbangi dengan pengembangan fasilitas jalan yang memadai sehingga menimbulkan berbagai permasalahan seperti kemacetan, peningkatan polusi udara, dan tingginya angka kecelakaan lalu lintas (Iskandar Mulyana & Rofik, 2022; Harahap et al., 2019). Data Badan Pusat Statistik menunjukkan bahwa jumlah kecelakaan lalu lintas terus meningkat setiap tahun, dengan sebagian besar insiden disebabkan oleh ketidakpatuhan pengguna jalan terhadap peraturan lalu lintas, seperti menerobos lampu lalu lintas dan melawan arus (Ardiansyah et al., 2022; Hutauruk et al., 2020).

Pelanggaran tersebut umumnya didominasi oleh pengendara roda dua yang merupakan populasi terbesar pengguna jalan di Indonesia (Amiril & Kurnia, 2022).

Sebagai upaya pengawasan, pemerintah telah menerapkan sistem pemantauan lalu lintas menggunakan kamera CCTV. Meskipun efektif dalam merekam kondisi lalu lintas, proses analisis data CCTV masih banyak dilakukan secara manual sehingga kurang optimal dalam mendukung pengambilan keputusan secara cepat dan akurat (Ramadan et al., 2022). Seiring perkembangan teknologi, pendekatan berbasis kecerdasan buatan, khususnya computer vision dan deteksi objek, mulai banyak diterapkan untuk meningkatkan efisiensi pemantauan lalu lintas (Indaryanto et al., 2021).

YOLOv5 merupakan salah satu algoritma deep learning berbasis Convolutional Neural Network (CNN) yang dirancang untuk mendeteksi dan mengklasifikasikan objek secara real-time. Algoritma ini telah banyak digunakan dalam berbagai penelitian di Indonesia dan terbukti memiliki kinerja yang baik dalam mendeteksi objek lalu lintas secara otomatis (Iskandar Mulyana & Rofik, 2022). Oleh karena itu, penelitian ini mengimplementasikan YOLOv5 untuk membangun sistem yang mampu mendeteksi, mengklasifikasikan, dan menghitung objek lalu lintas serta mendeteksi pelanggaran melawan arah arus lalu lintas.

2. KAJIAN TEORITIS

YOLOv5 (*You Only Look Once version 5*) merupakan metode *deep learning* berbasis *Convolutional Neural Network* (CNN) untuk *object detection* secara *real-time* dengan pendekatan *single-stage detector*, sehingga proses deteksi dan klasifikasi objek dilakukan secara simultan dalam satu jaringan (Iskandar Mulyana & Rofik, 2022; Amiennullah, 2024). Arsitektur YOLOv5 terdiri dari tiga komponen utama, yaitu *Backbone*, *Neck*, dan *Head*, yang memungkinkan ekstraksi fitur multi-skala dan prediksi *bounding box* secara efisien (Ashari et al., 2025).

YOLOv5 membagi citra masukan ke dalam grid dan memprediksi beberapa *anchor box* pada setiap grid, dengan *confidence score* yang merepresentasikan probabilitas keberadaan objek. Proses pasca-pemrosesan menggunakan *Non-Maximum Suppression* (NMS) untuk menghilangkan *bounding box* yang saling tumpang tindih sehingga meningkatkan akurasi deteksi, terutama pada kondisi lalu lintas padat (Silalahi et al., 2025; Virgiawan et al., 2024).

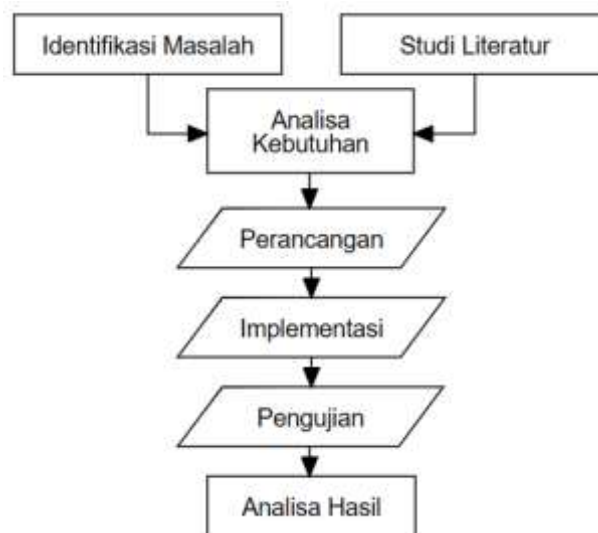
Kelebihan YOLOv5 meliputi kecepatan deteksi tinggi, akurasi yang baik pada berbagai ukuran objek, serta kemudahan implementasi dan *fine-tuning*. Namun, kinerjanya sangat bergantung pada kualitas data latih dan dapat menurun pada objek yang berukuran sangat kecil atau saling tumpang tindih (Asni et al., 2024; Hidayat et al., 2024).

Berbagai penelitian di Indonesia menunjukkan efektivitas YOLOv5 dalam deteksi dan klasifikasi kendaraan. Silalahi et al. (2025) serta Iskandar Mulyana dan Rofik (2022) membuktikan bahwa YOLOv5 mampu mendeteksi dan mengklasifikasikan kendaraan secara *real-time* dengan performa yang stabil. Pengembangan lebih lanjut juga diterapkan pada deteksi plat kendaraan di wilayah perkotaan (Illmawati & Hustinawati, 2023), model YOLO ringan untuk efisiensi komputasi (Ashari et al., 2025), serta kasus pelanggaran dan kepadatan lalu lintas dengan evaluasi *mean average precision* (Amiennullah, 2024; Hidayat & Whardana, 2024).

Selain itu, YOLO digunakan untuk menghitung kepadatan kendaraan di area parkir (Hidayat et al., 2024) dan dikombinasikan dengan metode *tracking* untuk pemantauan objek secara *real-time* (Virgiawan et al., 2024). Pengembangan YOLO terbaru juga terbukti andal pada berbagai kondisi pencahayaan dalam deteksi rambu lalu lintas (Pangestu & Putra, 2025). Berdasarkan hasil tersebut, YOLOv5 memiliki potensi besar untuk diterapkan dalam sistem pemantauan dan deteksi pelanggaran lalu lintas secara otomatis dan efisien.

3. METODE PENELITIAN

Sistematika atau alur dari penulisan yang menjadi metode berfikir dalam penelitian otomatisasi perhitungan ini dapat kita lihat gambar 1.

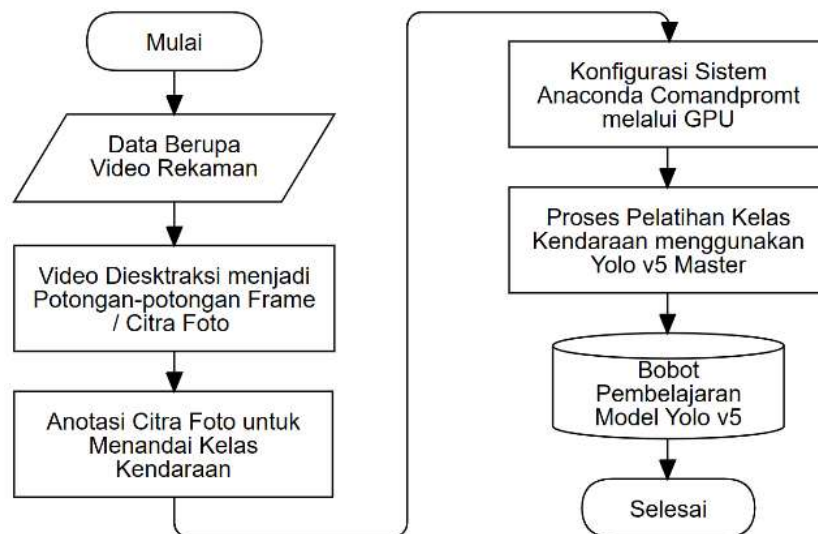


Gambar 1. Diagram alir metode penelitian.

Hal-hal yang dibutuhkan sebagai bentuk penunjang kelancaran dalam merancang dan mengimplementasikan serta menguji sistem ialah menentukan dan memilih standar minimum hardware dan software yang mana saja nanti dipergunakan. Hardware (RAM 16 GB, AMD Ryzen 5 75735SHS Processor, Nvidia GeForce RTX 2050). Software (Windows 11 - 64 bit,

Python, Anaconda Navigator, Anaconda Commandprompt, Numpy, Matplotlib, Sort, Times, Adobe Priemere Pro)

Proses pengumpulan data meliputi pengambilan sample gambar sebagai bahan pembuatan dataset, melalui roboflow, dilanjutkan dengan pelabelan atau anotasi citra menggunakan platform online roboflow.com. Berlanjut pada proses augmentasi, dimana proses ini bertujuan memperbanyak jumlah referensi oleh sistem untuk pendeteksian objek yang diekpor dalam format yaml. Hal ini terlihat pada diagram di bawah in. Setelah didapati sebuah data yaml, pelatihan dapat dilakukan secara mandiri dengan memberikan perintah pada terminal python. Pelatihan dataset terlihat pada diagram alir di bawah ini



Gambar 2. Flowchart pelatihan dataset.

4. HASIL DAN PEMBAHASAN

Proses pengumpulan data dilakukan dengan cara mengumpulkan data dari video lalu lintas yang dikonversi menjadi bentuk frame atau citra dan data dari roboflow.com. Citra ini kemudian diberi label yang selanjutnya dilakukan proses anotasi dan augmentasi.

Salah satu Perintah phyton digunakan untuk melatih model YOLOv5 dari awal tanpa memanfaatkan bobot pralatih (pretrained weights). Pelatihan dilakukan dengan ukuran input gambar yang disesuaikan menjadi 320×320 piksel, menggunakan file konfigurasi data.yaml sebagai referensi dataset hasil augmentasi. Proses pelatihan dilakukan selama 100 epoch dengan arsitektur model yolov5s.yaml, serta menggunakan batch size sebesar 16, yang berarti model memproses 16 gambar dalam setiap iterasi pelatihan. Sehingga dihasilkan sebuah bobot dalam model deteksi objek.

Untuk mengurangi resiko kesalahan perhitungan oleh sistem, peneliti menambahkan sebuah lohika SORT (Simple Online and Realtime tracking) bertujuan untuk meningkatkan performa dari sistem dalam menghitung pelanggaran melawan arus dengan memberikan id unik pada objek, agar tidak terhitung lebih dari satu [7]saat melintas pada lalu lintas yang ada.



Gambar 3. Citra hasil deteksi.

Citra hasil deteksi, klasifikasi dan jumlah kendaraan terhitung terdapat pada gambar 3 di atas. Untuk penerapan sort pada algoritma tersebut juga juga berhasil ditambahkan. Pada gambar terlihat pada setiap objek yang dideteksi memiliki boundingbox, centeroid, label dan id unik yang di berikan oleh logika sort. Sistem juga berhasil menyimpan video citra hasil tersebut pada sebuah folder yang ditentukan dalam skrip program keseluruhan .

Pengujian dilakukan dengan menggunakan video arus lalu lintas dua arah yang di skenariokan bahwa yang salah satu arahnya adalah pelanggar. Hal ini disebabkan keterbatasan peneliti mendapatkan video pengawasan lalu lintas yang terdapat kasus nyata pelanggarannya.


Pengujian dilakukan dengan 3 sampel video berbeda dan diuji antar frame. Setiap video diambil sampel acak 5 variabel pada frame yang akan di bandingkan dengan nilai groundtruth yang ada pada video dan bukan menurut sistem. Sehingga dengan begitu, didapati hasil pengujian yang diinginkan.

Mobil : 4	Sepeda Motor : 2	Bus : 0	Truk : 1									
Pelanggar												
Mobil : 1	Sepeda Motor : 3	Bus : 0	Truk : 0	<table border="1"> <tr> <td>Mobil: 4</td> <td>Mobil: 1</td> </tr> <tr> <td>Sepeda Motor: 2</td> <td>Sepeda Motor: 2</td> </tr> <tr> <td>Bus: 0</td> <td>Bus: 0</td> </tr> <tr> <td>Truk: 1</td> <td>Truk: 0</td> </tr> </table> <p>Pada frame ini sepeda motor tidak terdeteksi karena tidak terlihat jelas.</p>	Mobil: 4	Mobil: 1	Sepeda Motor: 2	Sepeda Motor: 2	Bus: 0	Bus: 0	Truk: 1	Truk: 0
Mobil: 4	Mobil: 1											
Sepeda Motor: 2	Sepeda Motor: 2											
Bus: 0	Bus: 0											
Truk: 1	Truk: 0											
Total												
Mobil : 27	Sepeda Motor : 41	Bus : 0	Truk : 3	<table border="1"> <tr> <td>Mobil : 31</td> <td>Sepeda Motor : 36</td> <td>Bus : 0</td> <td>Truk : 3</td> </tr> </table>	Mobil : 31	Sepeda Motor : 36	Bus : 0	Truk : 3				
Mobil : 31	Sepeda Motor : 36	Bus : 0	Truk : 3									

Gambar 4. Rasio total pada Sample 1.

Frame ke-1361			
Non-Pelanggar			
Mobil	: 5		
Sepeda Motor	: 2		
Bus	: 0		
Truk	: 0		
Pelanggar		Mobil: 7 (2s)	Mobil: 1
Mobil	: 1	Sepeda Motor: 2	Sepeda Motor: 2
Sepeda Motor	: 2	Bus: 0	Bus: 0
Bus	: 0	Truk: 0	Truk: 0
Truk	: 0	Pada frame sepeda motor tidak terdeteksi, 2 tpi sehingga dikenali menjadi mobil dan dikenali menjadi objek lain.	
Total			
Mobil	: 18	Mobil	: 23
Sepeda Motor	: 28	Sepeda Motor	: 22
Bus	: 0	Bus	: 0
Truk	: 1	Truk	: 1

Gambar 5. Rasio total pada Sample 2.

Frame ke-1505			
Non-Pelanggar			
Mobil	: 4		
Sepeda Motor	: 6		
Bus	: 0		
Truk	: 0		
Pelanggar		Mobil: 3	Mobil: 0
Mobil	: 0	Sepeda Motor: 3	Sepeda Motor: 0
Sepeda Motor	: 0	Bus: 0	Bus: 0
Bus	: 0	Truk: 1 (1m)	Truk: 0
Truk	: 0	Pada frame ini 1 mobil tidak terdeteksi karena threshold meyyrup, sehingga dikenali menjadi truk dan 3 motor tidak terdeteksi karena terlalu rapat.	
Total			
Mobil	: 20	Mobil	: 19
Sepeda Motor	: 16	Sepeda Motor	: 13
Bus	: 0	Bus	: 0
Truk	: 0	Truk	: 2

Gambar 6. Rasio total pada Sample 3.

Gambar 4 sampai 6 merupakan hasil akhir dari total pengujian pada 5 frame berbeda. Berdasarkan paparan pengujian yang dilakukan pada tabel 1. sampai 3. Berdasarkan hasil prediksi jaringan YOLOv5 pada dataset,-disusun confusion matrix yang menunjukkan performa deteksi untuk empat kelas obyek lalu lintas (mobil, motor, bus, truk), sebagaimana tercantum di Tabel1.

Confusion Matrix		Aktual			
		Mobil	Motor	Bus	Truk
Prediksi	Mobil	73	0	0	0
	Sepeda Motor	0	71	0	0
	Bus	0	0	0	0
	Truk	0	0	0	6
	Tidak Terdeteksi	-8	14	0	-2

Gambar 7. Confusion matrix hasil deteksi.

Merujuk pada tabel 4 barulah dapat ditemukan bobot jumlah kebenaran positif, kesalahan positif, kesalahan negatif, kepresisian, bobot balik pemanggilan, dan skor keakurasian F1 hasil pengolahan jaringan dalam satu kesatuan skenario. Peemaparan bentuk jumlah keseluruhan poin untuk mencari nilai-nilai tersebut.

$$\begin{aligned} \text{True Positive} &= 73 + 71 + 6 = 150 \\ \text{False Positive} &= 1 + 1 + 1 + 1 + 2 + 1 + 2 + 1 = 10 \\ \text{False Negative} &= (-8) + 14 + (-2) = 4 \\ \text{Precision} &= \frac{TP}{TP+FP} = \frac{150}{150+9} = 0,94 \\ \text{Recall} &= \frac{TP}{TP+FN} = \frac{150}{150+4} = 0,97 \\ \text{F1-Score} &= 2 \times \left(\frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \right) = 2 \times \left(\frac{0,94 \times 0,97}{0,94 + 0,97} \right) = 0,96 \end{aligned}$$

Berdasarkan perhitungan yang diperoleh, sistem berhasil mengenali sebanyak 150 objek dari kelas yang terdeteksi sebagai true positive. Selain itu, terdapat 9 objek otomotif yang teridentifikasi tidak sesuai dengan kondisi sebenarnya sehingga dikategorikan sebagai false positive, serta 4 objek yang tidak terdeteksi oleh sistem dan termasuk dalam false negative.

Nilai kinerja sistem menunjukkan hasil yang baik, dengan *precision* sebesar 0,94, *recall* sebesar 0,97, dan *F1-score* sebesar 0,97. Hasil tersebut menunjukkan bahwa sistem memiliki tingkat ketepatan dan keandalan yang tinggi. Dengan demikian, capaian kinerja yang diperoleh telah sesuai dengan tujuan penelitian dan dapat dikatakan memenuhi kriteria performa yang diharapkan.

Pengujian terhadap program YOLO menunjukkan bahwa sistem mampu melakukan perhitungan jumlah obyek lalu lintas secara otomatis. Hal ini ditandai dengan pemanfaatan dua garis bantu berwarna hijau dan merah.

Pengambilan data dilangsungkan setelah terjalankannya rentetan program dengan cara menghitung jumlah obyek lalu lintas yang melintas setiap interval 10 detik hingga 1 menit. Hasil dari sistem kemudian dibandingkan dengan hasil perhitungan manual untuk mengukur tingkat akurasi sistem. Uji coba dilakukan menggunakan 3 sampel video rekaman dari CCTV Dinas Perhubungan pada sever opensource

5. KESIMPULAN DAN SARAN

Kesimpulan yang dapat diambil dari pembahasan penelitian adalah: 1) Pada akhir penelitian ini, dihasilkan pengembangan fitur yang memperbarui proses fiturisasi menjadi lebih kompleks dalam pendeteksian objek lalu lintas secara otomatis menggunakan algoritma YOLOv5 berbasis bahasa pemrograman Python. Sistem dirancang melalui beberapa tahapan,

meliputi analisis kebutuhan, pemilihan algoritma, serta pengujian performa, dengan fokus pada empat kategori objek, yaitu sepeda motor, mobil, bus, dan truk. Proses klasifikasi dilakukan berdasarkan pelabelan objek dan mampu menangani variasi sudut pandang citra. 2) Simulasi pelanggaran lalu lintas dilakukan dengan mengasumsikan pergerakan objek pada jalur tertentu sebagai pelanggaran arus, sehingga sistem tetap dapat diuji meskipun tanpa data pelanggaran nyata. Hasil pengujian menunjukkan bahwa sistem memiliki kinerja deteksi yang tinggi dengan nilai *precision* sebesar 90%, *recall* 92%, dan *F1-score* 91%. Selain itu, akurasi sistem dalam menghitung objek lalu lintas mencapai 89%, yang menunjukkan peningkatan signifikan dibandingkan pendekatan manual pada penelitian sebelumnya dengan akurasi di bawah 60%. Dengan demikian, sistem ini memiliki potensi yang kuat untuk mendukung pemantauan lalu lintas secara *real-time* dan efisien.

Saran yang bisa diberikan pada Penelitian selanjutnya adalah menggunakan dataset yang lebih besar dan beragam agar model deteksi lebih robust terhadap variasi kondisi lalu lintas. Selain itu, penggunaan versi YOLO yang lebih terbaru serta optimasi *hyperparameter* diharapkan dapat meningkatkan akurasi dan F1-score. Integrasi algoritma *object tracking* seperti SORT atau DeepSORT juga direkomendasikan untuk meningkatkan ketepatan perhitungan kendaraan. Terakhir, pengujian pada lingkungan *real-time* dan perangkat terbatas perlu dilakukan guna memastikan keandalan sistem dalam implementasi nyata.

DAFTAR REFERENSI

- Amiennullah, J. (2024). Mendeteksi kendaraan menggunakan algoritma YOLOv5. *COREAI: Jurnal Kecerdasan Buatan, Komputasi dan Teknologi Informasi*, 5(2). <https://doi.org/10.33650/coreai.v5i2.9372>
- Ashari, I. A., Mangku Negara, I. S., & Setia Sandi, A. (2025). Lightweight YOLO models for real-time multi-vehicle detection. *Sinkron: Jurnal dan Penelitian Teknik Informatika*, 9(3). <https://doi.org/10.33395/sinkron.v9i3.15071>
- Asni, B., Amin, A., & Kasrani, M. W. (2024). Penerapan metode YOLO object detection terhadap proses pendeteksian jenis kendaraan di parkiran. *Jurnal Teknik Elektro UNIBA*, 6(1). <https://doi.org/10.36277/jteuniba.v6i1.130>
- Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. *arXiv*. <https://arxiv.org/abs/2004.10934>
- Glenn, J., Jocher, G., Chaurasia, A., & Qiu, J. (2023). *YOLOv5 by Ultralytics* [Computer software]. GitHub. <https://github.com/ultralytics/yolov5>
- Hidayat, F. A., Umbara, F. R., & Ilyas, R. (2024). Implementasi YOLO untuk menghitung kepadatan kendaraan tempat parkir. *Jurnal Algoritma*, 22(2). <https://doi.org/10.33364/algoritma/v.22-2.2919>

- Hidayat, F. T., & Whardana, A. K. (2024). Deteksi pelanggaran sepeda motor menggunakan algoritma YOLO dan mean average precision. *Jurnal SISKOM-KB: Sistem Komputer dan Kecerdasan Buatan*, 8(1). <https://doi.org/10.47970/siskom-kb.v8i1.401>
- Ilmawati, R., & Hustinawati. (2023). YOLOv5 untuk deteksi plat kendaraan di DKI Jakarta. *Jurnal Ilmu Komputer dan Agri-Informatika*, 10(1), 32–43. <https://doi.org/10.29244/jika.10.1.32-43>
- Iskandar Mulyana, D., & Rofik, M. A. (2022). Implementasi deteksi real time klasifikasi jenis kendaraan di Indonesia menggunakan metode YOLOv5. *Jurnal Pendidikan Tambusai*, 6(3), 13971–13982. <https://doi.org/10.31004/jptam.v6i3.4825>
- Pangestu, A., & Putra, M. P. K. (2025). YOLOv9-based traffic sign detection under varying lighting conditions. *Jurnal Teknik Informatika (JUTIF)*, 6(1). <https://doi.org/10.52436/1.jutif.2025.6.1.3917>
- Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. *arXiv*. <https://arxiv.org/abs/1804.02767>
- Saha, S., Mukherjee, A., & Dutta, P. (2023). Traffic object detection and violation monitoring using deep learning-based YOLO models. *International Journal of Intelligent Transportation Systems*, 18(2), 145–156. <https://doi.org/10.1016/j.ijits.2023.01.004>
- Silalahi, N. A., Saputra, H. K., Zaus, M. A., & Samala, A. D. (2025). Rancang bangun aplikasi penghitung kendaraan secara real-time menggunakan deteksi objek dengan metode YOLO. *Jurnal Pendidikan Tambusai*, 9(2), 14762–14770. <https://doi.org/10.31004/jptam.v9i2.27757>
- Virgiawan, I., Maulana, F., Putra, M. A., Kurnia, D. D., & Sinduningrum, E. (2024). Deteksi dan tracking objek secara real time berbasis computer vision menggunakan metode YOLOv3. *Humantech: Jurnal Ilmiah Multidisiplin Indonesia*, 3(3). <https://doi.org/10.32670/ht.v3i3.4348>
- Zhang, Y., Wang, X., & Li, H. (2024). Real-time traffic violation detection using YOLO-based deep convolutional neural networks. *Journal of Advanced Transportation*, 2024, 1–12. <https://doi.org/10.1155/2024/8892456>