JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.148-155

IMPLEMENTASI METODE YOLOV9 UNTUK MENDETEKSI PELANGGARAN PARKIR DI BAHU JALAN PERKOTAAN

Adeste C. L. Adhi*[1)], Christine Dewi[2)]
1. Teknik Informatika, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana, Indonesia
2. Teknik Informatika, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana, Indonesia

Article Info
Kata Kunci: Deteksi Objek; Pelanggaran Parkir; Pemrosesan Citra; Sistem Otomatis; YOLOv9

Keywords: Automated System; Image Processing; Object Detection; Parking Violation; YOLOv9

Article history:
Received 28 April 2025
Revised 30 May 2025
Accepted 7 June 2025
Available online 1 March 2026

DOI :
https://doi.org/10.29100/jipi.v11i1.7731

* Corresponding author.
Adeste C. L. Adhi
E-mail address:
672021068@student.uksw.edu

ABSTRAK
Pelanggaran parkir merupakan salah satu faktor utama penyebab kemacetan lalu lintas di kawasan perkotaan. Penelitian ini bertujuan untuk mengembangkan sistem deteksi otomatis pelanggaran parkir berbasis algoritma YOLOv9, khususnya varian YOLOv9C yang mengutamakan efisiensi dan akurasi tinggi dalam pemrosesan *real-time*. Data pelatihan diperoleh dari frame video pengawasan yang telah dianotasi secara manual menjadi dua kategori: “Melanggar” dan “Tidak Melanggar”. Untuk meningkatkan generalisasi model terhadap kondisi lapangan, dilakukan teknik augmentasi data seperti rotasi, flipping, penyesuaian pencahayaan, dan mosaic augmentation. Model dilatih selama 50 epoch dan dievaluasi menggunakan metrik *Confusion Matrix, Precision, Recall, F1-Score, dan Mean Average Precision* (mAP). Hasil evaluasi menunjukkan bahwa YOLOv9C mampu mendeteksi pelanggaran dengan precision 0.995 dan mAP 0.822. Namun, ditemukan tantangan pada akurasi kelas minor akibat ketidakseimbangan data. Sistem ini berpotensi untuk diimplementasikan dalam skenario monitoring lalu lintas otomatis dengan dukungan *edge computing*. Rekomendasi pengembangan lanjutan meliputi integrasi metode segmentasi semantik dan balancing data untuk meningkatkan performa pada lingkungan kompleks.

ABSTRACT
Illegal parking is one of the main contributors to traffic congestion in urban areas. This study aims to develop an automatic parking violation detection system based on the YOLOv9 algorithm, specifically the YOLOv9C variant, which prioritizes high efficiency and real-time accuracy. Training data were obtained from surveillance video frames, which were manually annotated into two categories: "Violating" and "Non-Violating." To improve the model's generalization to real-world conditions, various image augmentation techniques were applied, including rotation, flipping, brightness adjustment, and mosaic augmentation. The model was trained over 50 epochs and evaluated using performance metrics such as Confusion Matrix, Precision, Recall, F1-Score, and Mean Average Precision (mAP). The results show that YOLOv9C achieved a precision of 0.995 and an overall mAP of 0.822, indicating strong performance in detecting parking violations. However, challenges remain in detecting ambiguous cases, particularly those near violation boundaries, due to class imbalance. This system has potential for implementation in real-time traffic monitoring applications, particularly in smart cities. Future enhancements may include the integration of semantic segmentation, data balancing strategies, and deployment via edge computing platforms to ensure scalability and robustness.

I. PENDAHULUAN

Kemacetan lalu lintas merupakan salah satu permasalahan utama di kawasan perkotaan yang berdampak pada penurunan kualitas hidup masyarakat. Salah satu penyumbang signifikan kemacetan adalah pelanggaran parkir, khususnya parkir sembarangan di bahu jalan. Peningkatan jumlah kendaraan akibat pertumbuhan ekonomi dan populasi menyebabkan keterbatasan ruang parkir serta padatnya arus lalu lintas [1]. Kondisi ini menurunkan efisiensi transportasi, memperpanjang waktu tempuh, serta meningkatkan potensi kecelakaan dan konflik antar pengguna jalan [2][3].

Fenomena serupa terjadi di berbagai kota besar di dunia. Di New York City, kemacetan lalu lintas dipengaruhi

oleh perilaku pelanggaran lalu lintas, termasuk pelanggaran parkir serta dominasi kendaraan pribadi. Studi Liang et al. menunjukkan bahwa penerapan sistem tol di pusat kota dapat secara signifikan mengurangi volume kendaraan pribadi dan meningkatkan penggunaan angkutan umum [4]. Selain itu, kota ini juga menerapkan sistem kamera pengawas berbasis AI untuk mendeteksi dan menindak pelanggaran parkir secara real-time, yang terbukti membantu mengurangi hambatan pada jalur lalu lintas utama. Sementara itu, di Seoul, pendekatan berbasis teknologi digunakan untuk menganalisis pola penyebaran kemacetan melalui data kecepatan lalu lintas beresolusi tinggi, yang menunjukkan bahwa karakteristik penyebaran kemacetan berbeda antara pagi dan sore hari [5]. Kwon et al. juga menunjukkan bahwa dengan menggunakan pendekatan perkolasi, titik-titik kritis kemacetan dapat diidentifikasi untuk meningkatkan efisiensi sistem lalu lintas perkotaan [6]. Di London, sistem lampu lalu lintas berbasis AI yang mampu mendeteksi pesepeda dan pejalan kaki diuji coba untuk menyesuaikan durasi sinyal secara real-time, menghasilkan peningkatan keselamatan serta efisiensi jalan raya [7]. Selain itu, pemerintah kota juga menggunakan teknologi deteksi otomatis untuk mengidentifikasi dan memberikan sanksi terhadap kendaraan yang parkir sembarangan, sehingga dapat mengurangi gangguan terhadap kelancaran arus lalu lintas. Penerapan teknologi serupa di berbagai kota tersebut menegaskan pentingnya pengembangan sistem manajemen lalu lintas berbasis kecerdasan buatan (AI) di kota-kota Indonesia, terutama dalam menangani pelanggaran parkir sebagai salah satu faktor signifikan penyebab kemacetan.

Berbagai upaya telah dilakukan oleh otoritas untuk mengatasi permasalahan ini, di antaranya dengan menerapkan sistem pemantauan dan penindakan secara manual. Namun, pendekatan ini memiliki keterbatasan dalam aspek skalabilitas, kecepatan respons, dan akurasi, khususnya pada kondisi lalu lintas yang kompleks dan terus berubah [8]. Kota-kota di Indonesia mengalami beban lalu lintas yang semakin kompleks, yang menuntut implementasi sistem pengawasan berbasis teknologi untuk menjangkau area secara luas dengan efisiensi tinggi [9].

Dengan kemajuan teknologi dalam bidang pengolahan citra digital dan kecerdasan buatan, deteksi objek secara real-time telah menjadi salah satu solusi yang menjanjikan. YOLO (You Only Look Once) merupakan algoritma deteksi objek berbasis deep learning yang dikenal mampu mendeteksi objek secara cepat dan efisien. Penerapan YOLOv3 dalam sistem pengawasan parkir telah menunjukkan akurasi rata-rata sebesar 94,49% dalam identifikasi kendaraan yang melanggar [10]. Studi lain oleh Suarjaya et al., menunjukkan bahwa integrasi YOLOv4 dengan sistem berbasis web mampu mendeteksi ketersediaan lahan parkir dengan mAP mencapai 100% [11].

Dalam konteks sistem pengawasan parkir berbasis kamera di lingkungan perkotaan Indonesia yang dinamis dan memerlukan respons waktu nyata, pemilihan algoritma deteksi objek yang efisien dan akurat menjadi sangat penting. YOLOv9, dengan arsitektur Generalized Efficient Layer Aggregation Network (GELAN) dan Programmable Gradient Information (PGI), menawarkan keunggulan signifikan dalam hal kecepatan inferensi dan efisiensi memori, menjadikannya unggul untuk aplikasi real-time di lingkungan dengan sumber daya terbatas [12]. Sebagai perbandingan, SSD (Single Shot MultiBox Detector) memang menawarkan keseimbangan antara kecepatan dan akurasi. Namun, SSD cenderung kurang andal dalam mendeteksi objek kecil dan bertumpuk, serta memerlukan dataset besar untuk mencapai performa optimal [7]. Di sisi lain, Faster R-CNN dikenal memiliki tingkat akurasi tinggi, namun performanya terkendala oleh waktu inferensi yang lambat karena arsitektur dua tahap [4]. Oleh karena itu, pemilihan YOLOv9 didasarkan pada kemampuannya menggabungkan kecepatan deteksi tinggi dengan akurasi yang kompetitif, sekaligus mempertahankan efisiensi komputasi sebagai faktor yang krusial dalam implementasi sistem pengawasan parkir otomatis di wilayah dengan keterbatasan sumber daya, seperti di Indonesia.

YOLOv9 juga hadir dengan peningkatan signifikan dalam arsitektur jaringan dan efisiensi komputasi. YOLOv9 telah terbukti lebih adaptif terhadap variasi latar belakang, sudut pandang, serta kondisi pencahayaan yang beragam, berdasarkan hasil pengujian dalam lingkungan nyata [13]. Studi oleh Alwafi menunjukkan bahwa penggunaan kombinasi YOLOv8 dengan optical flow dapat meningkatkan presisi deteksi pelanggaran parkir hingga 96,3% dan mAP sebesar 98,9%, menandakan bahwa teknologi ini sangat potensial diterapkan dalam sistem pengawasan lalu lintas otomatis [9].

Meskipun YOLOv9 menawarkan keunggulan dalam kecepatan inferensi dan efisiensi memori, penerapannya di Indonesia menghadapi beberapa hambatan. Keterbatasan cakupan dan kualitas kamera pengawas, variabilitas kondisi pencahayaan, serta kesulitan integrasi dengan infrastruktur sistem transportasi cerdas yang belum merata menjadi tantangan utama [14]. Studi oleh Suparwito et al. menunjukkan bahwa YOLOv9 memiliki akurasi tinggi dalam mendeteksi kendaraan besar, namun performanya menurun saat mendeteksi objek kecil seperti sepeda motor, terutama dalam kondisi pencahayaan rendah dan sudut kamera yang tidak ideal [14]. Hal ini menunjukkan perlunya adaptasi algoritma terhadap kondisi lokal.

Untuk mengatasi tantangan ini, pendekatan seperti GC-YOLOv9 yang mengintegrasikan Ghost Convolution

telah dikembangkan untuk meningkatkan akurasi deteksi dalam kondisi pencahayaan yang buruk dan lingkungan perkotaan yang kompleks [15]. Selain itu, penggabungan data dari sensor termal dan RGB telah terbukti meningkatkan kinerja deteksi objek dalam kondisi pencahayaan rendah [16]. Oleh karena itu, adaptasi YOLOv9 terhadap konteks lokal Indonesia memerlukan pendekatan teknis yang fleksibel dan hemat sumber daya, termasuk peningkatan kualitas data pelatihan, integrasi sensor multimodal, dan optimasi arsitektur model untuk lingkungan dengan keterbatasan infrastruktur.

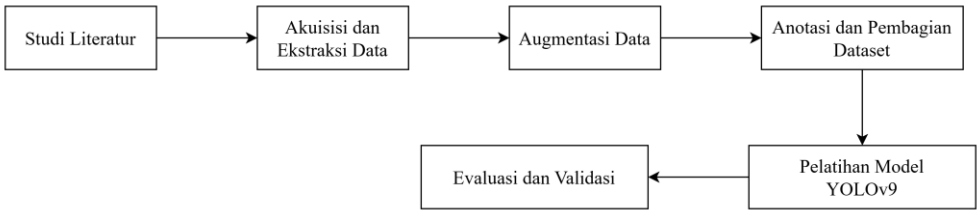
Selain menjadi penyebab utama kemacetan, pelanggaran parkir juga berdampak pada penurunan efektivitas sistem transportasi cerdas (ITS) di kawasan perkotaan. Untuk mengatasi masalah ini, diperlukan pendekatan berbasis teknologi yang mampu bekerja secara adaptif dan real-time. Salah satu teknologi yang menonjol dalam bidang deteksi visual adalah YOLO, yang telah berevolusi hingga versi terbaru, yaitu YOLOv9. YOLOv9 dirancang dengan arsitektur CSP-enhanced dan backbone yang lebih ringan, sehingga lebih efisien untuk digunakan dalam sistem deteksi otomatis yang dijalankan di perangkat terbatas [10].

Studi ini juga menjelajahi area yang belum banyak dikaji dalam penelitian terdahulu, seperti kemampuan YOLOv9 dalam menangani lingkungan lalu lintas padat dengan objek bertumpang tindih dan kondisi cuaca yang fluktuatif. YOLOv9, dengan peningkatan arsitektur Generalized Efficient Layer Aggregation Network (GELAN), lebih baik dalam mendeteksi objek yang tumpang tindih berkat kemampuannya mengintegrasikan informasi dari berbagai skala. Selain itu, YOLOv9 juga lebih adaptif terhadap perubahan pencahayaan, seperti pada kondisi cuaca buruk. Tinjauan sistematik oleh Diwan et al. menunjukkan bahwa YOLOv9 lebih unggul dalam mendeteksi objek dalam kondisi kompleks dibandingkan versi sebelumnya [10].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menerapkan algoritma YOLOv9 dalam sistem deteksi pelanggaran parkir di bahu jalan. Penelitian ini difokuskan pada optimalisasi pemodelan YOLOv9 melalui pemilihan arsitektur yang tepat, proses pelabelan data berdasarkan zona pelanggaran, serta evaluasi performa menggunakan metrik seperti Confusion Matrix, Precision, Recall, F1-Score, dan Mean Average Precision (mAP). Dengan pendekatan ini, diharapkan sistem dapat memberikan kontribusi nyata dalam meningkatkan efektivitas pengawasan pelanggaran parkir secara otomatis berbasis kecerdasan buatan.

II. METODE

Penelitian ini bertujuan mengembangkan sistem pendeteksian pelanggaran parkir berbasis algoritma YOLOv9, dengan menekankan pada proses augmentasi data dan optimalisasi pelatihan model untuk menghasilkan deteksi objek yang akurat dan efisien. Proses kerja penelitian dibagi menjadi beberapa tahap, sebagaimana digambarkan pada Gambar 1.



Gambar. 1. Diagram Alur Metodologi

A. Studi Literatur

Studi literatur dilakukan untuk mengkaji metode deteksi objek berbasis deep learning, terutama algoritma YOLO (You Only Look Once) dari generasi awal hingga versi YOLOv9 merupakan pengembangan signifikan dari versi sebelumnya, dengan peningkatan pada arsitektur backbone, pengolahan fitur spasial, dan efisiensi komputasi [1][2]. Literatur juga membahas efektivitas teknik augmentasi data dalam pelatihan model untuk mengatasi overfitting dan memperkuat performa model pada kondisi variative [17].

B. Akuisisi dan Ekstraksi Data

Dataset diperoleh dari video yang merekam aktivitas kendaraan di ruas jalan umum. Video tersebut diolah menjadi potongan frame citra dengan resolusi disesuaikan, menggunakan interval tertentu untuk efisiensi pemrosesan. Proses ekstraksi dilakukan tanpa menitikberatkan pada lokasi atau konteks geografis, karena penelitian ini fokus pada generalisasi kemampuan algoritma deteksi objek terhadap skenario lalu lintas umum.

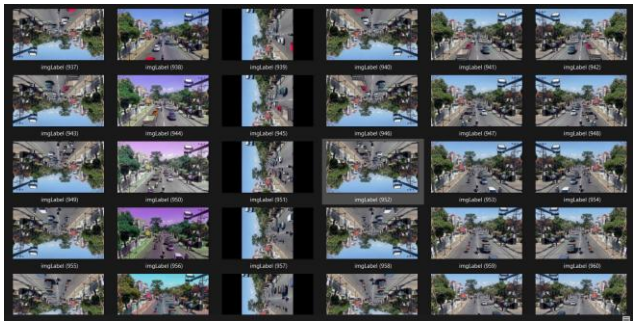
JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.148-155

C. *Augmentasi Data*

Sebagai bagian penting dalam pelatihan model, data hasil ekstraksi diperkuat menggunakan teknik augmentasi citra untuk menambah variasi dan meningkatkan ketahanan model terhadap perubahan sudut pandang dan pencahayaan. Augmentasi yang diterapkan meliputi:

- Rotasi (±15–30°)
- Flipping horizontal dan vertical
- Penyesuaian brightness dan kontras
- Gaussian blur
- Modifikasi hue

Variasi teknik augmentasi yang diterapkan ditunjukkan pada Gambar 2. Teknik augmentasi ini terbukti mampu meningkatkan robustitas model dalam berbagai kondisi, sebagaimana dilaporkan oleh Shorten dan Khoshgoftaar [3].



Gambar. 2. Transformasi Augmentasi Citra pada Dataset Pelatihan

D. *Anotasi dan Pembagian Dataset*

Video pengujian diperoleh dari kamera statis dengan sudut pandang 45° terhadap badan jalan. Setiap video berdurasi kurang lebih 5 menit dan merekam berbagai jenis kendaraan, seperti mobil pribadi, angkot, kendaraan besar, dan sepeda motor. Dari video tersebut, dihasilkan sekitar 1.200 frame yang kemudian diubah menjadi citra digital dengan resolusi 1020×500 piksel agar sesuai dengan input model YOLOv9.

Setiap frame kemudian dianotasi secara manual menggunakan platform Roboflow. Proses pelabelan dilakukan dengan memberikan label "Melanggar" dan "Tidak Melanggar" pada objek kendaraan berdasarkan posisinya terhadap zona pelanggaran. Zona pelanggaran ditentukan sebagai area bahu jalan yang tidak diperbolehkan untuk parkir, dan ditandai secara manual menggunakan koordinat poligon. Ilustrasi proses anotasi manual ditunjukkan pada Gambar 3. Zona ini hanya digunakan sebagai acuan klasifikasi saat inferensi, bukan sebagai fokus penelitian.



Gambar. 3. Ilustrasi Tahapan Proses Pelabelan Data

Dataset yang telah dianotasi kemudian dibagi menjadi tiga bagian, yaitu 70% untuk pelatihan, 20% untuk validasi, dan 10% untuk pengujian. Pembagian ini bertujuan untuk menjaga objektivitas evaluasi model dan menghindari overfitting. Selain augmentasi standar seperti flipping dan brightness adjustment, digunakan pula mosaic augmentation untuk memperkaya konteks spasial dan memperluas cakupan latar belakang dalam satu citra. Teknik ini direkomendasikan oleh Wang et al., dalam pelatihan YOLOv5 dan YOLOv7 karena terbukti mampu meningkatkan generalisasi model terhadap variasi latar belakang dan intensitas cahaya [17].

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.148-155

E. Pelatihan Model YOLOv9

Model deteksi objek yang digunakan adalah YOLOv9C, yaitu varian dari YOLOv9 yang dirancang untuk efisiensi tinggi pada perangkat dengan sumber daya terbatas. Model dilatih selama 50 epoch menggunakan framework Ultralytics dan library PyTorch. Proses pelatihan memanfaatkan dataset hasil augmentasi dan pelabelan untuk mengoptimalkan performa deteksi. Detail spesifikasi perangkat keras dan perangkat lunak yang digunakan dalam proses pelatihan disajikan pada Tabel I.

TABEL I
TABEL SPESIFIKASI HARDWARE DAN SOFTWARE PELATIHAN

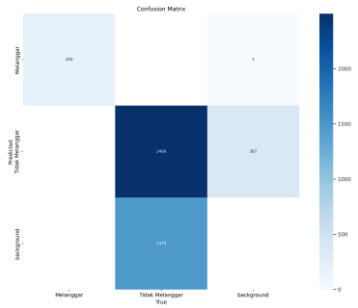
Komponen	Spesifikasi
CPU	Intel Core i7-10750H @ 2.60GHz
GPU	NVIDIA RTX 2060 6GB
RAM	16 GB DDR4
OS	Windows 11
Software	Python 3.10, PyTorch 1.13.1, OpenCV 4.7, Ultralytics YOLOv9 (v8.1.0), Roboflow

F. Evaluasi dan Validasi

Evaluasi dilakukan untuk mengukur kinerja model YOLOv9C dalam mendeteksi pelanggaran parkir menggunakan data uji yang tidak digunakan selama pelatihan. Metrik yang digunakan mencakup Confusion Matrix, Precision, Recall, F1-Score, dan Mean Average Precision (mAP) sebagai indikator utama. Evaluasi model juga mempertimbangkan Intersection over Union (IoU) untuk mengukur ketepatan lokasi deteksi, sebagaimana juga diterapkan pada penelitian sebelumnya terhadap model YOLOv8 [18]. Confusion Matrix digunakan untuk memvisualisasikan distribusi hasil prediksi. Selain evaluasi kuantitatif, dilakukan juga validasi visual pada 100 frame acak guna memastikan kesesuaian antara hasil deteksi dengan kondisi sebenarnya di dalam citra.

III. HASIL DAN PEMBAHASAN

Model YOLOv9C dilatih menggunakan dataset hasil augmentasi citra selama 50 epoch dengan batch size sebesar 16. Proses pelatihan dilakukan secara bertahap, dengan pengamatan terhadap perkembangan performa pada epoch ke-10, 20, 30, hingga 50. Grafik hasil pelatihan menunjukkan bahwa model mengalami peningkatan kinerja yang konsisten terhadap metrik evaluasi utama seperti confusion, precision, recall, dan F1-score. Gambar 4 menyajikan confusion matrix model YOLOv9C yang menggambarkan distribusi prediksi terhadap ground truth untuk masing-masing kelas.

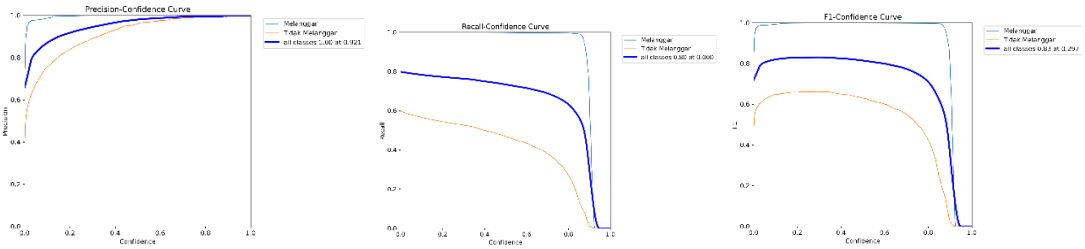


Gambar. 4. Grafik *Confusion Matrix* YOLOv9C

Berdasarkan hasil evaluasi akhir, model menunjukkan performa sangat baik pada kelas Melanggar, dengan precision sebesar 0.995, recall 0.998, dan F1-score 0.997. Sebaliknya, kinerja pada kelas Tidak Melanggar masih lebih rendah, dengan recall hanya sebesar 0.527. Ketimpangan ini mengindikasikan bahwa model memiliki kecenderungan bias terhadap kelas mayoritas. Penyebab utamanya adalah distribusi data yang tidak seimbang, di mana jumlah sampel pelanggaran jauh lebih banyak dibandingkan data kendaraan yang berlalu lalang. Selain itu, faktor visual seperti kemiripan tampilan kendaraan di dekat batas zona pelanggaran turut menyulitkan model dalam membedakan kategori secara akurat.

Temuan ini sejalan dengan studi oleh Qu et al. yang menunjukkan bahwa ketidakseimbangan data dalam klasifikasi citra dapat menurunkan sensitivitas terhadap kelas minor karena model lebih sering "berlatih" pada pola mayoritas. Mereka menyimpulkan bahwa oversampling hingga ketidakseimbangan dihilangkan sepenuhnya adalah metode yang paling efektif untuk mengatasi masalah ini, tanpa menyebabkan overfitting [19].

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.148-155



Gambar. 5. Grafik *Precision, Recall*, dan *F-1 Score* Model YOLOv9C

Untuk memahami stabilitas model selama proses pelatihan, grafik evaluasi dari epoch ke-10 hingga ke-50 dianalisis secara bertahap. Gambar 5 menunjukkan kurva precision, recall, dan F1-score yang mulai menunjukkan kestabilan setelah epoch ke-30, menandakan bahwa model telah mencapai konvergensi. Namun, kestabilan ini juga membuka kemungkinan terjadinya overfitting terhadap kelas tertentu, terutama kelas mayoritas. Oleh karena itu, perlu dipertimbangkan penggunaan teknik regularisasi seperti dropout, weight decay, atau data balancing, untuk memastikan generalisasi yang lebih baik. Studi oleh Srivastava et al. menyatakan bahwa dropout secara signifikan mampu mengurangi overfitting dalam arsitektur deep neural networks tanpa mengorbankan akurasi pada data uji [20].

Performa model juga dievaluasi terhadap variasi kondisi lingkungan, seperti pencahayaan rendah, bayangan keras, serta sudut kamera yang miring. Pada skenario pencahayaan rendah, model masih mampu mendeteksi pelanggaran, meskipun beberapa instance menunjukkan bounding box yang kurang presisi. Hal ini dapat disebabkan oleh informasi visual yang hilang pada objek di kondisi pencahayaan buruk, di mana fitur-fitur penting seperti bentuk dan warna objek menjadi kurang jelas bagi model. Demikian pula pada sudut kamera ekstrem, model mengalami penurunan akurasi dalam menentukan batas zona pelanggaran. Ini mungkin terkait dengan distorsi geometris pada objek yang terjadi akibat sudut pandang yang tidak ideal, yang menyebabkan model kesulitan dalam mengidentifikasi objek dengan tepat.

Meskipun YOLOv9C adaptif terhadap kondisi nyata, tantangan dalam deteksi objek pada lingkungan non-ideal masih perlu diatasi. Temuan ini didukung oleh hasil riset dari Bento et al., yang menemukan bahwa variasi sudut kamera dan pencahayaan ekstrem dapat memengaruhi akurasi deteksi pada sistem berbasis YOLO [21]. Selain itu, Li et al. mengembangkan metode deteksi objek untuk kondisi pencahayaan rendah yang disebut DimNet. Metode ini mengoptimalkan model melalui peningkatan fusi fitur multi-skala, ekstraksi fitur, kepala deteksi, dan fungsi kerugian. Hasil eksperimen menunjukkan bahwa DimNet mampu meningkatkan akurasi deteksi objek dalam kondisi pencahayaan rendah secara signifikan [22]. Untuk meningkatkan performa YOLOv9C, pengembangan lebih lanjut dapat melibatkan penggunaan teknik data augmentation untuk menciptakan lebih banyak variasi pencahayaan dalam dataset atau integrasi dengan sensor lain seperti sensor inframerah untuk mengatasi kondisi pencahayaan yang sangat buruk.

Ringkasan hasil evaluasi kinerja model secara kuantitatif disajikan pada Tabel II, yang mencakup nilai mAP, precision, recall, F1-score, dan rata-rata waktu inferensi per frame. Dibandingkan dengan penelitian oleh Tanuwijaya & Fatichah (2020) yang menggunakan YOLOv3 dan menghasilkan mAP sebesar 94,49% dalam sistem deteksi pelanggaran, penelitian ini mencatat mAP yang lebih tinggi yaitu 99,5% untuk kelas pelanggaran, sekaligus waktu inferensi yang lebih singkat [5]. Ini memperkuat bahwa YOLOv9C dapat menjadi solusi unggul dalam sistem real-time berbasis deep learning. Temuan ini diperkuat lagi oleh studi Dewi et al., yang menunjukkan bahwa arsitektur YOLOv9, khususnya varian YOLOv9s, dapat mencapai mAP@50 sebesar 99,3% dalam aplikasi deteksi pelat nomor kendaraan secara real-time, dengan stabilitas dan efisiensi yang tinggi [14].

TABEL II
TABEL RINGKASAN EVALUASI KINERJA MODEL YOLOV9C

Class	Precision	Recall	F1-Score	mAP
Melanggar	0.995	0.998	0.997	0.995
Tidak Melanggar	0.861	0.527	0.654	0.648
Rata-rata	0.928	0.764	0.837	0.822

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.148-155

Secara visual, performa deteksi objek oleh model ditunjukkan dalam Gambar 6, yang menampilkan hasil deteksi pada sampel frame dari dataset uji. Anotasi bounding box dan label prediksi menunjukkan bahwa lebih dari 90% frame memiliki kesesuaian dengan ground truth berdasarkan validasi terhadap 100 frame acak.



Gambar. 6. Visualisasi Hasil Deteksi Objek oleh YOLOv9C pada Citra Uji

Performa sistem deteksi objek juga diuji dalam hal efisiensi waktu eksekusi. Rata-rata waktu inferensi per frame adalah 0.082 detik, menunjukkan bahwa sistem mampu mendeteksi secara real-time. Kecepatan ini dicapai karena penggunaan arsitektur YOLOv9C yang lebih ringan. Namun, dalam simulasi skenario padat lalu lintas dengan lebih dari 60 frame per detik secara beruntun (contoh lalu lintas di persimpangan besar), ditemukan sedikit penurunan performa GPU dalam hal throughput pemrosesan, yang mengindikasikan bahwa sistem mulai mengalami peningkatan latensi. Hal ini menunjukkan bahwa meskipun sistem dapat menangani volume data tinggi dalam jangka pendek, penurunan akurasi atau peningkatan waktu respons dapat terjadi ketika data yang diproses meningkat secara signifikan. Untuk mengatasi hal ini, perlu dilakukan optimasi tambahan seperti batch processing, model pruning, atau pemanfaatan edge accelerator yang dapat mendukung pemrosesan lebih cepat tanpa mengorbankan efisiensi. Sistem deteksi real-time yang digunakan dalam kota besar memerlukan tidak hanya akurasi tinggi, tetapi juga kemampuan untuk menangani latensi rendah secara konsisten dalam aliran data tinggi [23]. Optimasi lebih lanjut dalam manajemen sumber daya komputasi dan distribusi beban kerja pada perangkat edge atau server terpusat mungkin diperlukan untuk memastikan kinerja tetap optimal meskipun dalam skenario volume data yang lebih tinggi.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa kombinasi augmentasi data yang tepat, pemanfaatan arsitektur YOLOv9C yang efisien, serta pengaturan pelatihan yang sistematis, mampu menghasilkan sistem deteksi pelanggaran parkir yang efektif dan potensial untuk diimplementasikan dalam skenario nyata. Meskipun demikian, beberapa keterbatasan masih ditemukan, seperti sensitivitas model terhadap objek yang berada di sekitar batas zona pelanggaran serta ketidakseimbangan akurasi antar kelas. Oleh karena itu, pengembangan lebih lanjut dapat diarahkan pada pengayaan dataset, penerapan teknik penyeimbangan data, atau integrasi pendekatan tambahan seperti segmentasi kontekstual dan pelacakan multi-objek (multi-object tracking) guna meningkatkan robustness sistem secara keseluruhan.

IV. KESIMPULAN

Penelitian ini telah berhasil mengembangkan sistem deteksi pelanggaran parkir berbasis algoritma YOLOv9C dengan pendekatan augmentasi data sebagai strategi utama dalam pelatihan model. Proses pelatihan dilakukan selama 50 epoch dengan konfigurasi batch size sebesar 16 dan menggunakan dataset hasil augmentasi yang mencerminkan kondisi visual bervariasi. Hasil evaluasi menunjukkan bahwa model mampu mencapai precision sebesar 0.995, recall sebesar 0.998, dan F1-score sebesar 0.997 untuk kelas “Melanggar”, serta rata-rata mAP sebesar 0.822.

Keberhasilan model dalam mendeteksi pelanggaran parkir secara akurat menunjukkan bahwa kombinasi antara arsitektur YOLOv9C dan strategi augmentasi dapat menghasilkan sistem yang adaptif terhadap kondisi lapangan. Meskipun demikian, hasil pada kelas “Tidak Melanggar” menunjukkan adanya tantangan pada deteksi objek ambigu atau yang berada di dekat batas zona pelanggaran, serta ketidakseimbangan distribusi kelas dalam dataset.

Sebagai tindak lanjut, pengembangan sistem ke depan disarankan untuk mempertimbangkan penerapan teknik data balancing, integrasi dengan metode segmentasi semantik, serta pengujian pada lingkungan yang lebih kompleks dan bervariasi. Selain itu, sistem ini memiliki potensi untuk dikembangkan menjadi solusi monitoring otomatis berbasis edge computing dalam mendukung penegakan aturan lalu lintas di kawasan perkotaan.

DAFTAR PUSTAKA

[1] R. Ramadhan, "EVEKTIVITAS PENERTIBAN PARKIR LIAR KOTA SURABAYA BERDASARKAN PERDA NOMOR 3 TAHUN 2018," *OURT Rev. J. Penelit. Huk. (e-ISSN 2776-1916)*, vol. 4, no. 06, pp. 20–29, 2024.

[2] N. R. P. Kosudiwandi, "Implementasi Algoritma You Only Look Once (Yolo) Untuk Mendeteksi Pelanggaran Rambu Dilarang Parkir," *Univ. Komput. Indones.*, 2020, [Online]. Available: http://library.oum.edu.my/repository/725/2/Chapter_1.pdf

[3] T. M. Shorten, C., Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0197-0.

[4] G. Liang, Q., Yao, R., Zhang, R., Chen, Z., & Wu, "Agent-Based Simulation Evaluation of CBD Tolling: A Case Study from New York City," *Forum Innov. Sustain. Transp. Syst.*, 2024, doi: 10.1109/FISTS60717.2024.10485607.

[5] Y. H. Jung, J. H., & Eom, "Empirical analysis of congestion spreading in Seoul traffic network," *Phys. Rev. E*, vol. 108, no. 5, pp. 1–12, 2023, doi: 10.1103/PhysRevE.108.054312.

[6] S. W. Kwon, Y., Lee, M. J., & Son, "Quantifying Traffic Patterns with Percolation Theory: A Case Study of Seoul Roads," *J. Korean Phys. Soc.*, pp. 1–8, 2025, doi: 10.1007/s40042-025-01328-3.

[7] S. Bose, "I-ROBOT New AI traffic lights being tested give priority to cyclists over cars in hope to 'encourage more people to cycle,'" The Irish Sun. Accessed: May 05, 2025. [Online]. Available: https://www.thesun.co.uk/motors/30396037/ai-traffic-lights-stop-cars-cyclists/

[8] F. Jupiter, "Implementasi Algoritma CNN dan YOLO untuk Mendeteksi Jenis Kendaraan pada Jalan Raya," *J. Sist. Inf. dan Telemat. (Telekomunikasi, Multimed. dan Inform.*, vol. 14, no. 2, 2023, doi: 10.36448/jsit.v14i2.3259.

[9] F. M. Alwafi, "Pengembangan Sistem Deteksi Objek Pada Kendaraan Parkir Liar Menggunakan Metode You Only Look Once dan Optical Flow," *J. (Doctoral Diss. Inst. Teknol. Kalimantan)*, 2025.

[10] J. V. Diwan, T., Anirudh, G., & Tembhurne, "Object detection using YOLO: challenges, architectural successors, datasets and applications," *Multimed. Tools Appl.*, vol. 82, no. 6, pp. 9243–9275, 2023.

[11] P. Suarjaya, I. M. B., Wiriasto, G. W., & Paniran, "Deteksi Ketersediaan Lahan Parkir Mobil Menggunakan Yolo V4 Berbasis Website," *Smart Comp Jurnalnya Orang Pint. Komput.*, vol. 14, no. 105, pp. 218–229, 2025.

[12] Ultralytics, "YOLOv9: A Leap Forward in Object Detection Technology," Ultralytics YOLO Docs. Accessed: May 06, 2025. [Online]. Available: https://docs.ultralytics.com/models/yolov9/

[13] Y. He, Y., Su, Y., Wang, X., Yu, J., & Luo, "An improved method MSS-YOLOv5 for object detection with balancing speed-accuracy," *Front. Phys.*, vol. 10, no. January, pp. 1–13, 2023, doi: 10.3389/fphy.2022.1101923.

[14] A. M. Suparwito, H., Prakoso, B. H. G., Kumalasanti, R. A., & Polina, "Real-Time Vehicle Detection and Air Pollution Estimation Using YOLOv9," *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 14, no. 1, pp. 23–30, 2025.

[15] G. An, R., Zhang, X., Sun, M., & Wang, "GC-YOLOv9: Innovative smart city traffic monitoring solution," *Alexandria Eng. J.*, vol. 106, no. June, pp. 277–287, 2024, doi: 10.1016/j.aej.2024.07.004.

[16] I. B. Murat Bakirci, "YOLOv9-Enabled Vehicle Detection for Urban Security and Forensics Applications," *IEEE Xplore*, 2024, doi: https://doi.org/10.1109/ISDFS60797.2024.10527304.

[17] H. Y. M. Wang, C. Y., Bochkovskiy, A., & Liao, "YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors," 2023, doi: 10.1109/cvpr52729.2023.00721.

[18] B. Prasetio and N. Pratiwi, "Deteksi sampah organik dan anorganik menggunakan model yolov8," vol. 10, no. 1, pp. 494–506, 2025.

[19] P. N. Qu, W., Balki, I., Mendez, M., Valen, J., Levman, J., & Tyrrell, "Assessing and mitigating the effects of class imbalance in machine learning with application to X-ray imaging," *Int. J. Comput. Assist. Radiol. Surg.*, vol. 15, no. 12, pp. 2041–2048, 2020, doi: 10.1007/s11548-020-02260-6.

[20] R. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting," *J. Mach. Learn. Res.*, vol. 15, no. 1, pp. 1929–1958, 2014.

[21] A. B. Bento, J., Paixão, T., & Alvarez, "Performance Evaluation of YOLOv8 , YOLOv9 , YOLOv10 , and YOLOv11 for Stamp Detection in Scanned Documents," *Appl. Sci.*, vol. 15, no. 6, 2025.

[22] J. Li, Z., Xiang, J., & Duan, "A low illumination target detection method based on a dynamic gradient gain allocation strategy," *Sci. Rep.*, vol. 14, no. 1, 2024, doi: 10.1038/s41598-024-80265-w.

[23] J. Oh, S., Kwon, Y., & Lee, "Optimizing Real-Time Object Detection in a Multi-Neural Processing Unit System," *Sensors*, vol. 25, no. 5, 2025, doi: 10.3390/s25051376.