

DETEKSI JUMLAH KENDARAAN YANG MASUK DAN KELUAR JALAN TOL MENGUNAKAN YOLOv5 DAN DEEP SORT

DETECTING THE NUMBER OF VEHICLES ENTERING AND EXITING TOLL ROADS USING YOLOv5 AND DEEP SORT

Stevanus Januar Latuluma¹, Magdalena A. Ineke Pakereng²

Teknik Informatika, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana^{1,2}

672022050@student.uksw.edu¹

ABSTRAK

The development of computer vision technology allows the traffic monitoring process to be carried out automatically through vehicle detection, tracking, and counting. This study aims to build a vehicle detection and tracking system using the YOLOv5 and Deep SORT algorithms on toll road traffic videos. The dataset used was obtained from the process of taking images and videos independently, then annotated using Roboflow with three vehicle classes, namely cars, buses, trucks. The dataset consists of 326 vehicle objects, including 242 cars, 70 trucks, and 14 buses. The YOLOv5s model was trained using 100 epochs with an image size of 640x640 pixels and a batch size of 16. The test results showed that the model obtained a precision value of 94.7%, a recall of 92.6%, $mAP@0.5$ of 98.1% and $mAP@0.5:0.95$ of 66.9%. Furthermore, the detection results were integrated with the Deep SORT algorithm to provide a unique identity for each vehicle so that its movement can be tracked consistently between frames. Testing was conducted using a 3-minute, 38-second traffic video. The count showed 16 cars entering and 32 cars exiting, 2 buses entering without any bus vehicles exiting, and 7 trucks exiting without any incoming trucks detected. Based on these results, the combination of YOLOv5 and Deep SORT is capable of automatically detecting, tracking, and counting vehicles with good results under the observed traffic conditions.

Keywords: YOLOv5, Deep SORT, vehicle detection, object tracking, line counting, toll roads.

ABSTRAK

Perkembangan teknologi *computer vision* memungkinkan proses pemantauan lalu lintas dilakukan secara otomatis melalui deteksi, pelacakan, dan perhitungan kendaraan. Penelitian ini bertujuan untuk membangun sistem deteksi dan pelacakan kendaraan menggunakan algoritma YOLOv5 dan Deep SORT pada video lalu lintas jalan tol. Dataset yang digunakan diperoleh dari proses pengambilan gambar dan video secara mandiri, kemudian dilakukan anotasi menggunakan Roboflow dengan tiga kelas kendaraan yaitu *car*, *bus*, *truck*. Dataset terdiri dari 326 objek kendaraan yaitu meliputi 242 mobil, 70 truk, dan 14 bis. Model YOLOv5s dilatih menggunakan 100 *epoch* dengan ukuran citra 640x640 piksel dan *batch size* 16. Hasil pengujian menunjukkan bahwa model memperoleh nilai *precision* sebesar 94,7%, *recall* sebesar 92,6% $mAP@0.5$ sebesar 98,1% dan $mAP@0.5:0.95$ sebesar 66,9%. Selanjutnya, hasil deteksi diintegrasikan dengan algoritma Deep SORT untuk memberikan identitas unik pada setiap kendaraan sehingga pergerakannya dapat dilacak secara konsisten antar *frame*. Pengujian dilakukan menggunakan video lalu lintas berdurasi 3 menit 38 detik. Hasil penghitungan menunjukkan terdapat 16 mobil masuk dan 32 mobil keluar, 2 bus masuk tanpa kendaraan bus keluar, serta 7 truk keluar tanpa ditemukan truk yang masuk. Berdasarkan hasil tersebut, kombinasi YOLOv5 dan Deep SORT mampu melakukan deteksi, pelacakan, serta penghitungan kendaraan secara otomatis dengan hasil yang baik pada kondisi lalu lintas yang diamati.

Kata Kunci : YOLOv5, Deep SORT, deteksi kendaraan, pelacakan objek, *counting line*, jalan tol.

PENDAHULUAN

Jalan tol adalah elemen penting dalam sistem transportasi modern yang memiliki peran utama dalam mendukung kelancaran arus lalu lintas serta meningkatkan efisiensi mobilitas masyarakat dan distribusi barang antar daerah. Keberadaan jalan tol memberikan kontribusi yang signifikan terhadap

pertumbuhan ekonomi karena dapat mempercepat waktu perjalanan dan mengurangi kemacetan di jalan arteri [1]. Di Provinsi Jawa Tengah, salah satu ruas tol yang strategis adalah Tol Semarang-Salatiga. Ruas ini menghubungkan dua titik penting yaitu Kota Semarang, yang berfungsi sebagai pusat ekonomi, dan Salatiga yang berfungsi sebagai jalur

menuju wilayah selatan provinsi. Oleh karena itu, jalan tol ini sangat krusial, terutama dalam mengatasi lonjakan kendaraan selama periode tertentu, seperti libur nasional, akhir pekan panjang, dan hari raya besar seperti Idulfitri dan Natal.

Situasi ini menjadi nyata selama periode mudik Lebaran 2026. Menurut data dari PT Trans Marga Jateng (TMJ), total 184.211 kendaraan tercatat melewati Gerbang Tol Banyumanik menuju Solo selama periode mudik awal, khususnya dari tanggal 11 Maret hingga 16 Maret 2026. Angka ini menunjukkan peningkatan sebesar 33,5% dibandingkan volume lalu lintas normal, yang biasanya rata-rata sekitar 137.957 kendaraan. Lonjakan ini menegaskan bahwa pergerakan para mudik yang menuju wilayah selatan dan timur Jawa Tengah mulai menyebabkan kemacetan di jalur trans-Jawa lebih awal dari puncak arus mudik yang diperkirakan. Fenomena ini menjadi bukti nyata bahwa volume kendaraan di jalan tol strategis dapat meningkat secara dramatis dalam waktu singkat, menyoroti perlunya sistem pemantauan yang andal dan responsif.

Pada periode-periode tersebut, peningkatan jumlah kendaraan terkadang menyebabkan kemacetan yang cukup parah di beberapa titik krusial, terutama di sekitar area gerbang tol. Kemacetan ini tidak hanya mengganggu kenyamanan pengguna jalan, tetapi juga dapat mengakibatkan kerugian ekonomi akibat keterlambatan distribusi logistik dan waktu tempuh yang cukup lama. Oleh karena itu, diperlukan sistem penghitungan kendaraan yang efisien dan *real-time* untuk membantu pengelola tol dalam merumuskan kebijakan strategis terkait pengaturan arus lalu lintas [2].

Salah satu pendekatan yang sering digunakan dalam pengembangan sistem pemantauan lalu lintas adalah dengan memanfaatkan *computer vision* yang berbasis pada Kecerdasan Buatan (AI). Dalam konteks ini, model deteksi objek yang utama adalah algoritma *You Only Look Once* versi 5 atau yang dikenal dengan YOLOv5. YOLOv5 merupakan salah satu

pengembangan terbaik dari keluarga YOLO, yang terkenal memiliki kecepatan serta akurasi tinggi dalam mengenali berbagai jenis objek, termasuk kendaraan dalam berbagai kondisi pencahayaan dan sudut pengambilan gambar. Model ini mampu memproses input video secara *real-time* dan menghasilkan deteksi objek yang sangat presisi [3].


Untuk menyelesaikan proses deteksi, algoritma DeepSORT (*Simple Online and Realtime Tracking with a Deep Association Metric*) berfungsi sebagai pelacak kendaraan. DeepSORT mampu mempertahankan identitas setiap objek yang terdeteksi oleh YOLOv5, bahkan ketika objek tersebut [4]. Kombinasi antara YOLOv5 dan DeepSORT dapat menghasilkan sistem yang tidak hanya mampu mendeteksi keberadaan kendaraan, tetapi juga dapat melacak pergerakannya secara akurat dari satu titik ke titik lainnya.

Selain dua algoritma utama tersebut, sistem ini juga didukung oleh Pustaka *Open Source Computer Vision Library* (OpenCV), yang berkontribusi dalam pengolahan citra digital, seperti pra-pemrosesan video, konversi format, dan penandaan objek [5]. Sebuah sistem yang komprehensif dan responsif terhadap kondisi lalu lintas di lapangan dibangun melalui integrasi ketiga teknologi ini.

Hasil dari sistem ini diharapkan mampu mengumpulkan data secara *real-time* mengenai jumlah kendaraan yang keluar dan masuk di Gerbang Tol Semarang–Salatiga. Data tersebut kemudian dapat dimanfaatkan untuk menganalisis pola kepadatan lalu lintas, menyusun sistem peringatan dini, serta membantu pengelola jalan tol dan otoritas terkait dalam pengambilan keputusan mengenai manajemen lalu lintas. Sistem yang berbasis kecerdasan buatan ini diharapkan dapat meningkatkan layanan jalan tol dengan mengurangi kemacetan yang sering terjadi ketika volume kendaraan meningkat [6].

METODE

Pada bagian ini akan menjelaskan beberapa tahapan penelitian yang dilakukan, tahapan penelitian dapat dijabarkan melalui blok diagram seperti pada Gambar 1.




Gambar 1. Tahap Penelitian

Data yang digunakan dalam studi kasus ini mencakup gambar dan video lalu lintas kendaraan di jalan raya, yang dikumpulkan secara mandiri. Proses anotasi, pelabelan kelas, dan manajemen dataset dilakukan secara manual menggunakan Roboflow Labeling Tool. Kotak pembatas dibuat untuk tiga representasi kelas kendaraan target: *car* (1189, *truck* 363, dan *bus* 73). Penggunaan platform ini memfasilitasi integrasi manajemen, augmentasi, dan ekspor langsung dataset ke dalam format arsitektur YOLOv5 [5]. Untuk memastikan transparansi mengenai kuantitas data yang digunakan dalam pelatihan model YOLOv5s, uraian rinci tentang jumlah gambar beserta total *instance* (objek yang terdeteksi) per kelas diuraikan secara komprehensif dalam Tabel 1 [5].

Tabel 1. Dataset Kendaraan yang Digunakan

Gambar	Sumber
	



<https://app.roboflow.com/pepen-bldei/datasetmanual-sjxd4/5>

Pada fase kedua penelitian, dilakukan pemrosesan data yang meliputi anotasi, augmentasi data, pembagian dataset, pelatihan model YOLOv5s, dan evaluasi kinerja model. Proses anotasi dilakukan menggunakan platform Roboflow, di mana setiap objek kendaraan diberi label secara manual pada gambar yang dikumpulkan. Setiap kendaraan diberi bounding box sesuai dengan jenisnya, yaitu mobil, truk, dan bus. Tahap ini bertujuan untuk menghasilkan dataset yang telah dianotasi yang dapat digunakan dalam pelatihan model deteksi objek. Setelah proses anotasi selesai, augmentasi data dilakukan untuk meningkatkan kuantitas dan keragaman dataset tanpa perlu pengambilan video baru. Teknik augmentasi yang diterapkan meliputi pemotongan untuk mengubah orientasi dan skala objek, pembalikan *horizontal* untuk mensimulasikan kendaraan dari arah berlawanan, dan penyesuaian pencahayaan untuk merepresentasikan berbagai kondisi cuaca dan intensitas cahaya. Proses augmentasi ini bertujuan untuk meningkatkan ketahanan model YOLOv5s terhadap variasi kondisi dunia nyata di jalan raya dan untuk mengurangi risiko *overfitting* [5].

Sebelum proses pelatihan dimulai, dataset dibagi menjadi dua bagian: 70% untuk *set* pelatihan, 20% untuk *set* validasi dan 10% untuk *set* *test* [5]. Data pelatihan

digunakan untuk mempelajari karakteristik visual kendaraan, seperti bentuk roda, lampu, dan dimensi bodi. Sementara itu, data validasi digunakan untuk mengevaluasi kinerja model secara objektif selama proses pelatihan, memungkinkan pemantauan rutin terhadap peningkatan kemampuan deteksi model.

Fase pelatihan model dilakukan menggunakan arsitektur YOLOv5s dengan parameter pelatihan yang ditetapkan menjadi 100 epoch, ukuran gambar 640×640 piksel, dan ukuran *batch* 16, menggunakan file konfigurasi *data.yaml* yang berisi informasi mengenai lokasi folder *train*, *valid*, serta daftar kelas objek yang digunakan dalam penelitian, seperti car, bus, truck. Selama proses pelatihan, YOLOv5s mengoptimalkan parameter jaringan dengan menggunakan tiga komponen loss fungsional : *bounding box loss* untuk meningkatkan akurasi lokasi objek, *objectness loss* untuk menentukan lokasi objek di area tertentu, dan *classification loss* untuk mengklasifikasikan objek ke dalam kategori yang sesuai. Proses optimasi dilakukan secara iteratif hingga diperoleh model dengan performa deteksi optimal. [10].

Setelah fase pelatihan selesai, model YOLOv5s dievaluasi menggunakan beberapa metrik deteksi objek standar, yaitu *Precisi*, *Recall*, *F1-score*, *mAP@0.5*, dan *mAP@0.5:0.95*. Metrik *Precisi* digunakan untuk menilai akurasi prediksi positif model, sedangkan *Recall* mewakili kemampuan model untuk mendeteksi semua objek aktual dalam dataset. Keseimbangan antara nilai *Precisi* dan *Recall* dievaluasi secara harmonis menggunakan *F1-score*. Selanjutnya, *mean Average Precision (mAP)* berfungsi sebagai indikator utama untuk mengukur kinerja kumulatif model di berbagai ambang batas *Intersection over Union (IoU)*, dengan mengacu pada standar *benchmarking PASCAL VOC* dan *COCO* [12]. Dalam studi ini, model dianggap berkinerja baik jika mencapai nilai *mAP@0.5* $\geq 0,95$. Jika

hasil evaluasi menunjukkan kesenjangan kinerja antar kelas dengan perbedaan nilai *mAP* melebihi 0,20, kelas-kelas tersebut akan dianalisis lebih lanjut berdasarkan faktor distribusi data target. Menurut kriteria ini, menunjukkan bahwa model YOLOv5s mampu mengenali ketiga jenis kendaraan dengan Tingkat akurasi yang sangat baik meskipun distribusi jumlah objek antar kelas tidak seimbang.

$$\text{Precision} = \frac{TP}{TP + FP} \quad \text{Recall} = \frac{TP}{TP + FN}$$

$$F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Tahap ketiga ini, proses kendaraan dilakukan menggunakan algoritma *Deep SORT* sebagai hasil akhir deteksi objek yang dihasilkan oleh model YOLOv5s. Setiap frame video diproses oleh YOLOv5s untuk menentukan kendaraan dan menghasilkan informasi seperti koordinat *bounding box*, kelas objek, dan *confidence*. Hasil deteksi tersebut kemudian dimasukkan ke dalam algoritma *Deep SORT* untuk melakukan proses deteksi secara berurutan. Untuk memprediksi posisi objek pada frame berikutnya, *Deep SORT (Simple Online and Realtime Tracking with a Deep Association Metric)* dikombinasikan dengan [11] *Hungarian Algorithm* sebagai metode *data association* untuk mencocokkan deteksi baru dengan objek yang sudah memiliki *ID* sebelumnya, serta *appearance feature encoder* yang membantu mempertahankan konsistensi identitas objek meskipun terjadi perubahan posisi, skala, atau sebagian objek tertutup oleh kendaraan lain.

Melalui penggabungan antara YOLOv5 dan *Deep SORT* [2], setiap kendaraan akan diberikan *ID* yang unik seperti "car#15" atau "truck#8", sehingga pergerakannya dapat dilacak secara konsisten dari frame awal hingga akhir video. Pendekatan ini sangat efektif dalam mengurangi terjadinya *ID switching* meskipun kondisi video menunjukkan lalu lintas yang padat, objek yang bertumpuk, atau perubahan kecepatan kendaraan [12].

Sistem pelacakan juga dilengkapi dengan mekanisme tambahan, seperti *centroid smoothing* untuk menstabilkan pergerakan titik tengah kendaraan, label *locking* untuk meminimalkan kesalahan perubahan kelas akibat prediksi model yang tidak stabil, serta *cooldown counting* untuk memastikan objek hanya dihitung satu kali saat melintas garis perhitungan. Dengan demikian, tahap implementasi ini memungkinkan sistem untuk mendeteksi, mengidentifikasi, dan melacak setiap kendaraan secara akurat dan *real-time* sepanjang durasi video.

Terakhir yaitu Mekanisme penghitungan kendaraan. Dalam penelitian ini dilakukan dengan memanfaatkan satu garis *horizontal* yang ditempatkan pada area tertentu di dalam video sebagai garis penghitung. Setiap kendaraan yang berhasil terdeteksi oleh YOLOv5 kemudian dilacak pergerakannya menggunakan *Deep SORT*, sehingga setiap objek memiliki *ID* unik yang konsisten selama kendaraan muncul di dalam *frame* [13]. Pergerakan kendaraan dianalisis berdasarkan posisi *centroid* dari *bounding box*. Ketika *centroid* suatu kendaraan bergerak melewati garis tersebut, sistem menentukan arah pergerakan untuk mengklasifikasikan apakah kendaraan tersebut termasuk kategori masuk (*entering*) atau keluar (*leaving*).

Kendaraan yang bergerak dari arah atas ke bawah yang melintasi garis akan dikategorikan sebagai kendaraan yang masuk, sedangkan kendaraan yang bergerak dari bawah ke atas akan dikategorikan sebagai kendaraan yang keluar. Agar sistem tidak menghitung kendaraan lebih dari satu kali, setiap *ID* kendaraan hanya dihitung satu kali, dan logika tambahan seperti penghitungan *cooldown*, penguncian label, serta pelacakan *centroid* yang halus digunakan untuk menjaga stabilitas dan mencegah terjadinya perhitungan ganda akibat fluktuasi prediksi atau perubahan posisi objek. Dengan pendekatan ini, sistem dapat menghitung jumlah kendaraan secara otomatis dan akurat meskipun terdapat

gangguan seperti perubahan kecepatan, tumpang tindih antar objek, atau variasi sudut pandang kamera [2].

HASIL DAN PEMBAHASAN

Berikut merupakan hasil pelatihan YOLOv5, yang dimana Pelatihan model YOLOv5s ini dilaksanakan dengan memanfaatkan *dataset* kendaraan yang telah dianotasi secara manual melalui *platform Roboflow*. Proses pelatihan berlangsung selama 100 *epoch* dengan ukuran citra 640 x 640 *piksel* dan ukuran *batch* 16. Hasil evaluasi menunjukkan bahwa model ini mampu mendeteksi objek kendaraan dengan performa yang cukup baik, terutama pada kelas mobil dan truk [13].


Tabel 2. Hasil pengujian pada data validasi

Class	Images	Instances	P	R	mAP 50	mAP 50-95
all	73	326	0.947	0.926	0.981	0.669
bus	73	14	0.925	0.884	0.986	0.732
cars	73	242	0.967	0.909	0.979	0.6
truck	73	70	0.949	0.986	0.98	0.673

Berdasarkan hasil pengujian pada data validasi, diperoleh nilai *precision*, *recall*, *F1-score*, dan *mAP* yang berbeda untuk setiap kelas. Kelas bus memperoleh *precision* sebesar 92,5% dan *recall* sebesar 88,4%, menghasilkan *F1-score* sebesar 90,4% dengan nilai *mAP@0.5* sebesar 98,6%. Hasil ini menunjukkan bahwa meskipun model dapat mengenali bus secara tepat (*precision tinggi*), model masih memiliki keterbatasan dalam menemukan seluruh objek bus yang ada di dalam gambar (*recall rendah*), yang disebabkan oleh jumlah data bus yang relatif lebih sedikit [12].

Pada kelas mobil, model menunjukkan kinerja yang sangat baik dengan *precision* sebesar 96,7% dan *recall* sebesar 90,9%, sehingga menghasilkan *F1-score* sebesar 93,7%. Nilai *mAP@0.5* untuk


kelas ini mencapai 97,9%, yang menunjukkan bahwa model mampu mendeteksi kendaraan jenis mobil dengan akurasi tinggi dalam berbagai kondisi pencahayaan dan posisi serta memiliki Tingkat kesalahan deteksi yang rendah. Kelas truk menjadi kelas dengan performa terbaik, memiliki *precision* sebesar 94,9% dan *recall* sebesar 98,6%, serta *F1-score* sebesar 96,7%. Nilai *mAP@0.5* yang diperoleh sebesar 98,0% menunjukkan bahwa model sangat efektif dalam mengenali truk, baik dari segi lokasi maupun klasifikasinya. Secara keseluruhan, kinerja model menunjukkan bahwa YOLOv5s mampu berfungsi dengan baik dalam konteks deteksi kendaraan, terutama karena proses pelatihan yang menggunakan *dataset* hasil anotasi manual serta augmentasi yang memperluas variasi data. Meskipun demikian, kinerja yang kurang optimal pada kelas bus menunjukkan adanya kebutuhan untuk memperbesar dan menyeimbangkan dataset agar hasil deteksi lebih merata di semua kelas [13].



Gambar 2. Precision per Class



Gambar 3. Recall per Class



Gambar 4. F1 Score per Clas

Kemudian berikutnya yaitu hasil pelacakan kendaraan menggunakan Deep SORT yang dimana hasil pelacakan kendaraan menunjukkan bahwa kombinasi model YOLOv5 sebagai detektor dan Deep SORT sebagai pelacak dapat berfungsi secara efektif dalam mengidentifikasi, memberikan ID, dan melacak kendaraan dari satu *frame* ke *frame* lainnya. Setelah YOLOv5 menghasilkan koordinat *bounding box* dan prediksi kelas pada setiap *frame* video, Deep SORT memproses informasi tersebut dengan memanfaatkan Kalman Filter untuk memprediksi posisi objek pada *frame* selanjutnya serta Hungarian Algorithm untuk menghubungkan deteksi baru dengan ID objek yang sudah ada [12]. Proses ini memberikan kestabilan dalam pelacakan meskipun terdapat perubahan arah kendaraan, perbedaan kecepatan, atau tumpang tindih antar objek dalam kondisi jalan tol yang dinamis.

Sistem juga menerapkan mekanisme tambahan berupa *centroid smoothing* untuk menstabilkan pergerakan titik tengah kendaraan, serta *label locking* untuk memastikan bahwa prediksi kelas tetap konsisten selama proses pelacakan. Mekanisme ini berfungsi untuk mengurangi masalah umum seperti *ID switch*, *fluktuasi* dalam prediksi kelas, dan kehilangan identitas objek ketika kendaraan bergerak cepat atau terhalang oleh kendaraan lain [8].

Secara keseluruhan, pelacakan kendaraan berlangsung dengan stabil dan mampu mempertahankan ID unik untuk setiap kendaraan saat melintasi area

pengamatan. Hasil *visualisasi* pelacakan menunjukkan bahwa *bounding box* dan *ID* kendaraan dapat dipertahankan dengan baik hingga kendaraan keluar dari *frame*, sehingga sistem dapat menghasilkan perhitungan kendaraan yang akurat [14].



Gambar 5. Cuplikan video tracking

Berdasarkan video berdurasi 3 menit 38 detik yang diuji, dapat diperoleh hasil perhitungan kendaraan sebagai berikut :

Tabel 3. Hasil perhitungan kendaraan

Kategori	Entering	Leaving
Car	16	32
Bus	2	0
Truck	0	7

Proses menghitung jumlah kendaraan dilakukan dengan memanfaatkan pergerakan titik tengah objek yang melewati garis penghitung yang sudah ditentukan di area video. Setiap kendaraan yang berhasil terdeteksi oleh YOLOv5s akan dilacak menggunakan algoritma Deep SORT. Dengan cara ini, kendaraan tersebut mendapatkan identitas (*ID*) yang unik dan tetap sama selama ada dalam frame video. Dengan cara ini, setiap kendaraan hanya dihitung satu kali saat titik tengah objek melewati garis penghitung sesuai dengan arah pergerakannya.[5]. Berdasarkan hasil pemrosesan video uji, sistem menghasilkan data mengenai jumlah kendaraan yang masuk (*entering*) dan keluar (*leaving*) dengan rincian sebagai berikut: kategori mobil tercatat sebanyak 16 kendaraan yang memasuki area (*entering*) dan 32 kendaraan yang meninggalkan area (*leaving*). Pada kategori bus, sistem mendeteksi 2 kendaraan masuk dan tidak terdapat

kendaraan yang keluar selama pengamatan. Begitu juga pada truk tidak ditemukan kendaraan yang masuk, namun sistem berhasil mendeteksi 7 truk yang keluar.

Hasil ini menunjukkan bahwa gabungan antara YOLOv5s dan Deep SORT bisa melakukan deteksi, pelacakan, dan penghitungan kendaraan secara otomatis dalam kondisi lalu lintas yang nyata. Pemberian *ID* yang unik oleh Deep SORT membantu sistem untuk menjaga identitas kendaraan dengan cara yang konsisten, sehingga dapat mengurangi kemungkinan terjadinya penghitungan ganda. Selain itu, penggunaan metode pelacakan *centroid* dan mekanisme garis hitung terbukti efektif dalam mengklasifikasikan arah pergerakan kendaraan ke dalam kategori masuk dan keluar secara waktu nyata.[9].

ANALISIS SISTEM

Proses menghitung kendaraan dilakukan dengan melihat pergerakan titik pusat objek yang melewati garis penghitung yang telah ditentukan di area video. Setiap kendaraan yang terdeteksi oleh model YOLOv5s akan dilacak dengan menggunakan algoritma Deep SORT. Dengan cara ini, setiap kendaraan akan mendapatkan identitas (*ID*) yang unik dan tetap sama selama ada dalam video. Dengan cara ini, setiap kendaraan hanya akan dihitung satu kali saat titik pusat objek melewati garis penghitung sesuai dengan arah geraknya. Berdasarkan hasil pengujian pada video lalu lintas di jalan tol, sistem ini berhasil mendeteksi, melacak, dan menghitung kendaraan secara otomatis. Hasil perhitungan menunjukkan bahwa kategori kendaraan mobil memiliki jumlah terbanyak, yaitu 16 kendaraan yang masuk dan 32 kendaraan yang keluar. Pada kategori bus, sistem mendeteksi ada 2 kendaraan yang masuk dan tidak ada kendaraan yang keluar selama waktu pengamatan. Sementara itu, untuk kategori truk, tidak ada kendaraan yang tercatat masuk, tetapi sistem berhasil mendeteksi 7 kendaraan yang keluar. Hasil ini

menunjukkan bahwa sistem dapat dengan baik mengidentifikasi arah gerakan kendaraan menggunakan kombinasi metode deteksi objek *YOLOv5s* dan pelacakan *Deep SORT*. Penggunaan *ID* unik untuk setiap kendaraan membantu menjaga identitas objek tetap konsisten, sehingga bisa mengurangi kemungkinan terjadinya penghitungan ganda. Selain itu, penggunaan pelacakan *centroid* dan garis penghitung terbukti berhasil dalam membedakan kendaraan yang masuk dan keluar secara langsung. Dengan cara ini, sistem yang dibuat memiliki kemampuan untuk digunakan sebagai solusi yang secara otomatis memantau jumlah kendaraan di jalan tol dan jalan raya lainnya. [12].

Kemudian pada tahap deteksi kendaraan dengan algoritma *Deep SORT* bekerja dengan stabil sesuai yang dijelaskan pada analisis sistem deteksi kendaraan, yang dimana Mekanisme ini sangat penting agar memastikan bahwa setiap kendaraan hanya dapat dihitung satu kali dan tidak mengalami *ID switch*. Penggunaan *label locking* dalam sistem dapat meningkatkan konsistensi klasifikasi selama proses pelacakan. Dengan menjaga label yang paling dominan dari riwayat deteksi, sistem ini berhasil mengurangi kesalahan klasifikasi yang sering muncul akibat perubahan sudut pandang atau ukuran objek di setiap *frame*. Secara keseluruhan, integrasi antara *YOLOv5* dan *Deep SORT* menghasilkan proses pelacakan yang lebih stabil, akurat, dan dapat diandalkan [4].

Dan yang terakhir, dalam proses penghitungan kendaraan, sistem secara umum dapat mencatat jumlah kendaraan yang masuk dan keluar dengan baik. Namun, masih terdapat beberapa kesalahan kecil, terutama ketika dua kendaraan bergerak berdampingan atau saling menutupi tepat saat melewati garis penghitungan. Situasi ini membuat *centroid* kendaraan sulit untuk dibedakan oleh algoritma, sehingga *Deep SORT* berpotensi melakukan kesalahan dalam asosiasi *ID* (*ID switching*) atau melewatkan salah satu

objek. Meskipun demikian, kesalahan ini hanya terjadi dalam situasi tertentu dengan kepadatan kendaraan yang berdekatan, sedangkan dalam kondisi normal, sistem mampu menghitung kendaraan dengan stabil dan konsisten [11].

EVALUASI

Pertama, Sistem yang dikembangkan masih memiliki beberapa keterbatasan yang perlu diperhatikan. Pertama, jumlah dataset untuk kelas bus sangat terbatas, sehingga model cenderung kurang optimal dalam mendeteksi bus dibandingkan dengan kelas mobil dan truk yang memiliki dataset lebih banyak. Kedua, kualitas serta sudut pengambilan video mempengaruhi kinerja sistem. Video yang dipakai dalam penelitian ini diambil dengan orientasi potret dan sudut pandang tertentu. Akibatnya, beberapa kendaraan yang berada jauh terlihat lebih kecil ukurannya. Selain itu, keadaan kendaraan yang berada dekat satu sama lain atau tertutup sebagian (*occlusion*) bisa mengurangi akurasi dalam mendeteksi dan melacak, terutama saat jumlah kendaraan di jalan semakin banyak. Ketiga, meskipun algoritma *Deep SORT* dapat menjaga identitas kendaraan dengan baik, masih ada kemungkinan kehilangan objek (*lost track*) atau perubahan identitas kendaraan (*ID switching*) ketika kendaraan bergerak sangat cepat, tiba-tiba keluar dari area pengamatan, atau tertutup oleh kendaraan lain dalam beberapa frame berturut-turut. Keadaan itu bisa memengaruhi hasil perhitungan jumlah kendaraan yang masuk dan keluar. [4].

SIMPULAN

Berdasarkan hasil dari pelatihan, pengujian, pelacakan, dan penghitungan kendaraan yang telah dilakukan, dapat disimpulkan bahwa sistem deteksi dan pelacakan kendaraan yang menggunakan *YOLOv5s* dan *Deep SORT* dapat berfungsi dengan baik di kondisi lalu lintas jalan tol. Model *YOLOv5s* yang dilatih dengan dataset yang dianotasi secara manual melalui *Roboflow* berhasil mendapatkan

nilai *precision* sebesar 94,7%, *recall* sebesar 92,6%, *mAP@0.5* sebesar 98,1%, dan *mAP@0.5:0.95* sebesar 66,9%. Hasil ini menunjukkan bahwa model sangat baik dalam mengenali objek kendaraan dari tiga jenis yang ada, yaitu mobil, bus, dan truk.[9].

Di tahap pelacakan, algoritma *Deep SORT* dapat menjaga identitas kendaraan dengan baik dengan memberikan *ID* unik untuk setiap objek yang terdeteksi. Menggabungkan *YOLOv5s* dan *Deep SORT* membuat proses pelacakan kendaraan bisa terus berjalan meskipun ada perubahan posisi, perbedaan kecepatan, atau keadaan lalu lintas yang cukup padat. Penggunaan mekanisme *centroid smoothing*, pemungutan suara mayoritas untuk label, dan penghitungan *cooldown* juga membantu meningkatkan kestabilan pelacakan dan mengurangi kemungkinan terjadinya penghitungan ganda [11].

Dalam proses menghitung kendaraan, sistem dapat mengklasifikasikan arah pergerakan kendaraan berdasarkan pergerakan *centroid* yang melewati garis penghitung. Berdasarkan hasil pengujian video lalu lintas yang berdurasi 3 menit 38 detik, sistem mencatat 16 mobil yang masuk dan 32 mobil yang keluar, 2 bus yang masuk tanpa ada bus yang keluar, serta 7 truk yang keluar sementara tidak ada truk yang masuk. Hasil ini menunjukkan bahwa sistem dapat menghitung kendaraan secara otomatis dan langsung, sambil menjaga konsistensi identitas objek selama proses pelacakan. Namun, penelitian ini masih memiliki beberapa batasan, terutama terkait dengan ketidakseimbangan jumlah data di setiap kelas. Kelas bus hanya memiliki 14 contoh, sementara kelas mobil memiliki 242 contoh dan kelas truk memiliki 70 contoh. Karena itu, penelitian berikutnya bisa difokuskan pada penambahan jumlah dataset yang lebih seimbang, penggunaan video dengan berbagai kondisi cuaca dan pencahayaan yang berbeda, serta penerapan model deteksi yang lebih modern untuk

meningkatkan akurasi dan keandalan sistem di berbagai kondisi lalu lintas.[15].

SARAN PENGEMBANGAN

Berdasarkan temuan dari penelitian yang sudah dilakukan, ada beberapa hal yang bisa ditingkatkan untuk memperbaiki kinerja sistem di penelitian berikutnya. Pertama, jumlah dataset harus ditambah, terutama untuk kelas bus yang hanya memiliki 14 contoh, sementara kelas mobil memiliki 242 contoh dan kelas truk memiliki 70 contoh. Diharapkan dengan penambahan data yang lebih seimbang, model bisa lebih baik dalam mengenali semua jenis kendaraan secara lebih merata.

Kedua, penelitian berikutnya bisa menggunakan dataset yang lebih bervariasi dengan berbagai kondisi cuaca, tingkat pencahayaan yang berbeda, waktu pengambilan gambar (baik siang maupun malam), serta variasi dalam kepadatan lalu lintas. Tujuan dari ini adalah untuk memperbaiki kemampuan model dalam menggeneralisasi saat digunakan dalam situasi dunia nyata yang lebih rumit.

Ketiga, kita bisa mempertimbangkan untuk menggunakan model deteksi objek yang lebih baru, seperti *YOLOv8* atau *YOLOv10*, agar bisa mendapatkan akurasi deteksi dan kecepatan inferensi yang lebih baik dibandingkan model *YOLOv5s* yang dipakai dalam penelitian ini.

Keempat, cara menghitung kendaraan bisa ditingkatkan dengan menggunakan penghitungan multi-lini atau penghitungan berbasis area. Dengan begitu, sistem dapat menganalisis lalu lintas dengan lebih mendalam, seperti perhitungan kendaraan berdasarkan jalur, arah pergerakan, maupun Tingkat kepadatan lalu lintas secara otomatis.

Kelima, kita juga harus memperhatikan kualitas dan posisi kamera. Menggunakan kamera yang memiliki resolusi lebih tinggi dan sudut pengambilan gambar yang lebih baik bisa meningkatkan kualitas dalam mendeteksi dan melacak kendaraan, terutama untuk objek yang

berada jauh atau yang tertutup oleh objek lain.

DAFTAR PUSTAKA

- [1] J. Tian, N. Ma, Y. Zhou, Y. Lv, W. Chi, and L. Sun, "An Efficient End-to-End Lightweight Object Detection Method Based on YOLOv5 for Intelligent Sweeping Robots An Efficient End-to-End Lightweight Object Detection Method Based on YOLOv5 for Intelligent Sweeping Robots," *IECON 2023- 49th Annu. Conf. IEEE Ind. Electron. Soc.*, no. March 2024, pp. 1–8, 2023, doi: 10.1109/IECON51785.2023.10311823.
- [2] S. Kumar, S. K. Singh, S. Varshney, S. Singh, and P. Kumar, "Fusion of Deep Sort and Yolov5 for Effective Vehicle Detection and Tracking Scheme in Real-Time Traffic Management Sustainable System," 2023.
- [3] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, "YOLOv4: Optimal Speed and Accuracy of Object Detection," 2020, [Online]. Available: <http://arxiv.org/abs/2004.10934>
- [4] C. Series, "Multiple Object Tracking Based on YOLOv5 and Optimized DeepSORT Algorithm Multiple Object Tracking Based on YOLOv5 and Optimized DeepSORT Algorithm", doi: 10.1088/1742-6596/2547/1/012022.
- [5] A. J. M. Plompen *et al.*, "The joint evaluated fission and fusion nuclear data library , JEFF-3 . 3," *Eur. Phys. J. A*, vol. 56, no. 7, pp. 1–108, 2020, doi: 10.1140/epja/s10050-020-00141-9.
- [6] Y. Zhang, Z. Guo, J. Wu, Y. Tian, H. Tang, and X. Guo, "Real-Time Vehicle Detection Based on Improved YOLO v5," 2022.
- [7] H. Wibowo and I. S. Sitanggang, "Large-Scale Oil Palm Trees Detection from High-Resolution Remote Sensing Images Using Deep Learning," 2022.
- [8] Z. B. Khabibullah, "Tracking Soccer Player Based on Deepsort Algorithm with YOLOV8 Framework," vol. 9, no. 1, 2025.
- [9] M. Everingham, L. Van Gool, C. K. I. Williams, J. Winn, and A. Zisserman, "Edinburgh Research Explorer The PASCAL Visual Object Classes (VOC) Challenge The PASCAL Visual Object Classes (VOC) Challenge," vol. 88, no. 2, 2010, doi: 10.1007/s11263-009-0275-4.
- [10] N. J. Hayati, D. Singasatia, and M. R. Muttaqin, "Object Tracking Menggunakan Algoritma You Only Look Once (YOLO)v8 untuk Menghitung Kendaraan," *Komputa J. Ilm. Komput. dan Inform.*, vol. 12, no. 2, pp. 91–99, 2023, doi: 10.34010/komputa.v12i2.10654.
- [11] N. Wojke, A. Bewley, and D. Paulus, "Simple online and realtime tracking with a deep association metric," *Proc. - Int. Conf. Image Process. ICIP*, vol. 2017-Sept, pp. 3645–3649, 2017, doi: 10.1109/ICIP.2017.8296962.
- [12] B. A. Jamiu, A. T. Oladele, M. Issa, M. Asaduzzaman, and A. Bari, "Advanced Vehicle Tracking System : Leveraging Gabor Feature Extraction and YOLOv5-Deep SORT for Real-Time Multi- Class Traffic Monitoring .," no. January, 2025, doi: 10.35629/5252-0701217231.
- [13] R. Khanam and M. Hussain, "W yolo 5: a," pp. 3–10, 2024.
- [14] Z. Huang, L. Li, G. C. Krizek, and L. Sun, "Research on Traffic Sign Detection Based on Improved YOLOv8," *J. Comput. Commun.*, vol. 11, no. 07, pp. 226–232, 2023, doi: 10.4236/jcc.2023.117014.
- [15] M. Rahman *et al.*, "Real-Time Vehicle Type Detection and Counting for Emission Pollution Monitoring and Traffic Violation Identification," vol. 9, no. 2, pp. 959–976, 2025.