

BAB I

PENDAHULUAN

A. Latar Belakang

Jalan merupakan salah satu prasarana transportasi darat yang memainkan peran penting dalam mobilitas masyarakat dan distribusi barang antarwilayah (Andani et al., 2021). Perannya sebagai penghubung antar wilayah ini membantu mengefisiensi proses transportasi dan distribusi barang serta jasa. Infrastruktur dengan tingkat mobilitas tinggi, salah satunya jalan tol yang berperan dalam meningkatkan efisiensi dan kecepatan proses perdagangan, baik pada tingkat domestik maupun internasional. Sementara itu, infrastruktur dengan aksesibilitas tinggi, seperti jalan raya lokal memberikan kemudahan akses transportasi darat yang dapat mendukung perkembangan aktivitas komersial dan sosial di area tersebut (Ng et al., 2019).

Seiring dengan manfaat yang diberikan, keberadaan jalan raya juga dapat berisiko jika tidak diimbangi dengan pengelolaan dan pengawasan yang baik. Masalah seperti kerusakan jalan, kemacetan di daerah padat, dan kurangnya sistem keamanan jalan dapat menghambat efisiensi transportasi hingga membahayakan keselamatan pengguna jalan. *World Health Organization* (WHO) menyebutkan bahwa sebanyak 1.19 juta jiwa meninggal setiap tahunnya akibat kecelakaan lalu lintas di seluruh dunia. Berdasarkan data Badan Pusat Statistik (BPS) (2022), angka kecelakaan lalu lintas di Indonesia meningkat sebanyak 34% dari 103.645 kasus menjadi 139.258. Kecelakaan tersebut mengakibatkan 28.131 korban jiwa meninggal dunia, 13.364 korban luka berat, 160.449 korban luka ringan, dan kerugian material sebesar 280.009 juta rupiah.

Perilaku dan keterampilan pengemudi menjadi penyebab utama kecelakaan lalu lintas di Indonesia yang menyumbang 61% dari total insiden, diikuti dengan faktor kondisi infrastruktur dan lingkungan sebesar 30%, serta kondisi kendaraan sebesar 9% (Susanto & Yuniarto, 2023). Beberapa perilaku pengemudi yang sering menjadi penyebab kecelakaan di lalu lintas ini meliputi pelanggaran batas

kecepatan, pelanggaran rambu lalu lintas, menerobos lampu merah, pengemudi yang melawan arah, hingga penggunaan jalur yang tidak sesuai dengan aturan (Fowode et al., 2023; Mawaddah, 2023; Moral-García et al., 2019; Sagberg et al., 2015)

Tindakan melawan arah sering kali dilakukan oleh pengemudi karena ingin menghindari rute panjang atau memotong waktu perjalanan tanpa memikirkan risiko yang dapat membahayakan pengguna jalan lain. Melawan arah sangat berpotensi menyebabkan tabrakan frontal yang beresiko pada kecelakaan serius hingga fatal (Jiang et al., 2021). Pelanggaran tidak hanya membahayakan pelaku, tetapi juga pengguna jalan lain yang memiliki hak prioritas sehingga meningkatkan risiko kecelakaan lalu lintas. Selain itu, tindakan melawan arah dapat menyebabkan gangguan arus lalu lintas karena memakan ruang jalur yang bukan peruntukannya (Cohn et al., 2020).

Untuk mengatasi permasalahan ini, diperlukan pengawasan yang ketat dan efektif. Pengawasan dapat dilakukan secara manual oleh petugas untuk memantau setiap aktivitas pelanggaran yang beresiko bagi pengendara lain. Namun, metode ini memakan biaya dan tenaga kerja yang besar dengan jangkauan pantau yang terbatas (Hao, 2023). Oleh karena itu, penerapan teknologi yang canggih dalam sistem pengawasan lalu lintas perlu dilakukan untuk meningkatkan efektivitas dan efisiensi deteksi pelanggaran.

Sistem pengawasan yang efisien dapat dilakukan melalui kamera pengawas (CCTV) yang terintegrasi dalam *Intelligent Transportation System* (ITS). ITS adalah sebuah sistem yang menggunakan teknologi, salah satunya algoritma *computer vision* untuk membantu mendeteksi pelanggaran lalu lintas secara otomatis dan *real-time* (Yusfian et al., 2022). Selain kemudahan dalam instalasi, petugas dapat memberikan respons lebih cepat terhadap pelanggaran atau potensi kecelakaan, menghemat biaya operasional, hingga dapat meningkatkan kepuasan pengguna jalan (Limsoonthrakul et al., 2021). Contoh negara yang sudah menerapkan ITS secara luas adalah Amerika Serikat. Berbagai studi menunjukkan bahwa teknologi dalam ITS, seperti sinkronisasi sinyal lalu lintas, pengukuran kecepatan kendaraan, dan penerapan batas kecepatan dinamis, mampu mengurangi

kemacetan, meningkatkan kepastian waktu perjalanan, serta memperbaiki tingkat keselamatan lalu lintas (Hou, 2023; Yan & Lv, 2024).

Berbagai pendekatan teknologi telah dirancang untuk mengembangkan sistem deteksi objek yang efektif dan efisien. Sebelum perkembangan teknologi seperti sekarang, teknik deteksi objek tradisional lebih mengandalkan ekstraksi fitur dari gambar, seperti tepi atau tekstur (Y. Liu et al., 2021). Klasifikator seperti *Support Vector Machines* (SVM) atau *Decision Trees* digunakan untuk mengklasifikasikan objek berdasarkan fitur yang telah diekstraksi tersebut sehingga diperoleh label dari objek yang telah terdeteksi. Wahyono et al. (2015) mengembangkan pendekatan dengan menggunakan *background subtraction* untuk mengidentifikasi kandidat area yang diam, kemudian memverifikasi kendaraan yang ada dengan mengekstrak fitur *Scalable Histogram of Oriented Gradient* (SHOG) yang dilanjutkan dengan klasifikasi menggunakan *Support Vector Machines* (SVM). Metode ini menunjukkan performa yang baik meskipun ada perubahan pencahayaan, tetapi desain fitur SHOG kompleks dan kurang efektif dalam menangani kondisi cuaca yang ekstrem. Secara umum, sebagian besar metode tradisional yang ada sangat rentan terhadap pengaruh faktor-faktor lingkungan, seperti perubahan pencahayaan, keterhalangan objek (*occlusion*), dan kondisi cuaca yang tidak stabil (Tang et al., 2020).

Seiring perkembangan teknologi, metode *deep learning* pun muncul sebagai solusi yang lebih modern dengan memanfaatkan jaringan saraf tiruan (*neural networks*). *Deep learning* memberikan prospek yang baik untuk segmentasi gambar, terutama *Convolutional Neural Networks* (CNN) yang dirancang khusus untuk tugas pengenalan pola (Hussain et al., 2017). Deteksi objek dengan memanfaatkan *deep learning* umumnya dapat dikelompokkan menjadi dua pendekatan utama, yaitu metode berbasis wilayah (*region proposal*) dan metode berbasis regresi (X. Wu et al., 2019). Metode *two-stage* yang bekerja dengan mengidentifikasi wilayah-wilayah yang berpotensi mengandung objek target untuk kemudian diklasifikasi untuk menentukan jenis objek tersebut (X. Chen et al., 2017). Salah satu contohnya adalah *Region-based Convolutional Neural Network* (R-CNN). R-CNN memiliki performa *mean Average Precision* (mAP)

yang tinggi, tetapi bekerja dengan lambat dikarenakan harus melatih beberapa jaringan untuk menyelesaikan berbagai tugas pada tahap inferensi yang berbeda (T. Wang et al., 2020). Selain itu, pendekatan menggunakan metode *two-stage* juga memerlukan sumber daya komputasi yang tinggi. Hal ini menjadi kendala untuk perangkat *mobile* atau *wearable* yang umumnya memiliki kapasitas penyimpanan dan kemampuan komputasi terbatas (Edozie et al., 2025).

Metode kedua adalah metode berbasis regresi dan bekerja secara *single-stage*. Cara kerjanya adalah mendeteksi dan mengklasifikasi semua objek pada citra dalam satu langkah (Peng et al., 2022). Meskipun metode *single-stage* menghasilkan akurasi yang lebih rendah dibandingkan pendekatan *two-stage*, tetapi metodenya yang lebih sederhana ini unggul dalam kecepatan pemrosesan (X. Chen et al., 2017). Hal ini menjadikannya lebih cocok untuk deteksi *real-time* di jalan raya yang membutuhkan respons cepat dengan tingkat akurasi yang dapat diandalkan untuk mendeteksi objek yang bergerak dengan cepat.

Dari berbagai pendekatan dalam metode *single-stage*, algoritma *You Only Look Once* (YOLO) menjadi salah satu algoritma yang populer dan banyak digunakan di antara berbagai algoritma deteksi objek lain (Ahmed et al., 2024). Algoritma ini mampu mendeteksi objek secara *real-time* dengan kecepatan tinggi, efisien, dan akurat (Gheorghe et al., 2024). Jaringan deteksi objek YOLO meningkatkan akurasi dan kecepatan dengan menggunakan teknik-teknik inovatif seperti struktur *lightweight*, *backbone* baru, *cascading*, metode piramida, dan fungsi *loss* yang teroptimasi (Xie et al., 2024). Teknik-teknik ini membuat YOLO cocok untuk diterapkan dalam berbagai skenario aplikasi *real-time*, salah satunya dalam pemantauan lalu lintas (Ariwibowo & Ismi, 2022).

Pemilihan YOLOv11 didasari oleh beberapa faktor. YOLOv11 merupakan versi terbaru dari YOLO sehingga menggunakan arsitektur jaringan saraf yang diperbarui dan dirancang untuk meningkatkan efisiensi dalam memproses gambar dan video dibandingkan dengan versi sebelumnya (Wei et al., 2024). YOLOv11 mendukung kemampuan yang beragam, dimulai dari deteksi objek, segmentasi, klasifikasi, hingga estimasi pose (L. He et al., 2024). Selain itu, YOLOv11 memiliki kemampuan yang lebih unggul dalam mengidentifikasi objek yang tertutup

sebagian oleh objek lain daripada versi YOLO lainnya sehingga membantu dalam proses *objek tracking* pada lalu lintas yang padat (Y. He et al., 2024; Wan et al., 2024). Versi terbaru YOLO ini mengalami peningkatan signifikan dalam waktu pelatihan dan memiliki performa paling baik dibandingkan versi lainnya sehingga paling cocok digunakan pada perangkat terbatas.

Penelitian oleh Y. He et al. (2024) mengusulkan model deteksi kebakaran yang ringan dan efisien menggunakan 8 metode yang berbeda-beda, yaitu Fast R-CNN, RetinaNet, YOLOv7, YOLOv7x, YOLOv8, BF_MB-YOLOv5, YOLOv11, dan FireNet (YOLOv8 modifikasi oleh Y. He et al.). Model ini dirancang untuk mengatasi tantangan deteksi kebakaran tradisional, seperti kebisingan latar belakang, perubahan pencahayaan, dan kesulitan dalam mendeteksi objek kecil. FireNet menunjukkan performa unggul pada dataset *Fire Scene* dengan mAP@0.5 sebesar 80.2%, *recall* 78.4%, presisi 82.6%, dan waktu inferensi 26.7 ms. Hasil modifikasi ini berada di urutan kedua dalam segi performa dengan model YOLOv11 yang menghasilkan performa paling baik dibanding model lainnya, yaitu mAP@0.5 sebesar 80.3%, *recall* 78.5%, presisi 82.7%, dan waktu inferensi 27 ms. Hal ini membuktikan bahwa YOLOv11 dapat bersaing dengan model hasil modifikasi dan menjadi solusi efisien untuk kebutuhan pemantauan *real-time*.

Dalam proses segmentasi, YOLOv11 menghasilkan performa yang unggul dibandingkan dengan YOLOv8 dan Mask R-CNN. Berdasarkan penelitian yang dilakukan oleh Sapkota et al. (2024), YOLOv8-seg menghasilkan presisi sebesar 0,90 dengan *recall* 0,95 mengungguli Mask R-CNN yang hanya mencapai 0,81 dalam presisi dengan *recall* 0,81. Bahkan dalam penggunaan dataset yang berbeda, segmentasi YOLOv8 tetap memiliki performa akurasi dan efisiensi yang unggul sehingga cocok digunakan dalam pengaplikasian *real-time* yang dapat diandalkan. Dalam penelitian lainnya, yaitu oleh Sapkota & Karkee (2025), dilakukan perbandingan antara berbagai konfigurasi YOLOv11-seg dan YOLOv8-seg untuk tugas *instance segmentation* pada buah apel hijau di lingkungan kebun modern. Penelitian ini mengkaji performa model dalam kondisi occluded maupun non-occluded, serta mengevaluasi efisiensi komputasi dan waktu pelatihan. Hasil menunjukkan bahwa meskipun YOLOv8-seg memiliki waktu inferensi yang lebih

cepat, segmentasi YOLOv11 secara konsisten mendominasi dalam performa, baik segmentasi maupun deteksi.

Algoritma YOLO didukung oleh komunitas yang luas dan aktif sehingga berperan dalam pengembangan berkelanjutan melalui pembaruan serta peningkatan fitur. Dukungan dari komunitas menyediakan berbagai sumber daya dan panduan teknis yang mempermudah proses implementasi YOLO untuk berbagai keperluan. Dengan keunggulan-keunggulan tersebut, YOLOv11 menjadi solusi yang ideal untuk mendeteksi pelanggaran lalu lintas di jalan raya.

Prinsip pertama dari cara kerja YOLO adalah pembagian gambar input menjadi grid dengan ukuran $m \times m$. Setiap sel dalam grid ini bertanggung jawab untuk mendeteksi objek yang terletak di dalamnya. Setiap sel menghasilkan n *bounding boxes* dengan skor kepercayaan objek yang berbeda-beda. Pada model YOLO, lapisan terakhir menghasilkan baik probabilitas klasifikasi maupun koordinat dari bounding box yang sesuai. Semua output ini dinormalisasi dalam rentang 0 hingga 1. Secara keseluruhan, output dari setiap sel grid akan dikodekan sebagai tensor dengan ukuran $m \times m \times (n \times 5 + \text{jumlah kelas})$ (Peng et al., 2022).

Berbagai penelitian telah membuktikan keefektifan sistem berbasis YOLO dalam mendeteksi beragam pelanggaran lalu lintas, seperti ketidakpatuhan penggunaan helm pada pengendara sepeda motor (Ariwibowo & Ismi, 2022; Waris et al., 2022) serta pelanggaran umum lainnya seperti menerobos lampu merah, berpindah jalur sembarangan, dan melebihi batas kecepatan (Rosario et al., 2021; Gehani et al., 2024). Sistem-sistem ini biasanya memproses rekaman video dari kamera pengawas yang dipasang di jalan raya dan persimpangan, memungkinkan identifikasi dan pemantauan pelanggaran lalu lintas secara otomatis (Gehani et al., 2024).

Penelitian terkait deteksi pelanggaran lawan arah dilakukan oleh (Suttiponpisarn et al., 2022) menunjukkan akurasi yang sangat tinggi mencapai 95,23% dengan mengembangkan kerangka kerja otonom bernama WrongWay-LVDC berdasarkan rekaman video *Closed-Circuit Television* (CCTV). Penelitian ini memberikan tiga kontribusi utama. Pertama, pengembangan algoritma yang ditingkatkan untuk deteksi batas jalur jalan pada video CCTV menggunakan teknik

pengolahan citra, yang disebut dengan *improved Road Lane Boundary-CCTV* (*improved RLB-CCTV*). Kedua, algoritma *Distance-Based Direction Detection* (DBDD) yang mengadopsi metode *deep learning* untuk validasi dan deteksi kendaraan yang melaju salah arah. Ketiga, algoritma *Inside Boundary Image* (IBI) yang mampu mengambil gambar kendaraan melawan arah dengan presisi tinggi. Kerangka kerja ini berhasil diimplementasikan pada sistem *embedded* dengan kecepatan rata-rata *real-time* sebesar 24 *frame* per detik (FPS) sehingga sangat berpotensi dalam aplikasi *Internet of Things* (IoT) di bidang pemantauan lalu lintas.

Dalam sistem pengawasan, kinerja sering kali bergantung pada faktor seperti kualitas gambar, resolusi kamera, dan kondisi lingkungan yang dapat memengaruhi akurasi dan keandalan deteksi. Oleh karena itu, diperlukan sistem dengan algoritma yang lebih tangguh dan adaptif untuk menangani beragam skenario lalu lintas dan kondisi lingkungan (Biswas et al., 2023). Salah satu pendekatan yang umum digunakan adalah peningkatan citra. Metode ini bersifat spesifik tergantung pada konteks aplikasi. Contohnya penggunaan teknik peningkatan untuk citra satelit tidak selalu sesuai diterapkan pada citra medis karena perbedaan karakteristik antar objek seperti tingkat detail, rentang warna, dan pola visual. Oleh sebab itu, pemilihan metode peningkatan citra harus disesuaikan dengan tujuan analisis dan karakteristik citra yang diolah (Umbaugh, 2023).

Penggunaan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) dapat menjadi pilihan yang cocok untuk kondisi malam hari di jalan raya yang dibuktikan pada penelitian oleh Chen et al. (2023) yang dilakukan untuk meningkatkan kualitas citra dari tanda di jalan raya pada malam hari. Pada penelitian tersebut, model YOLOv2 sampai YOLOv5 digunakan untuk sebagai perbandingan metode yang terbaik untuk digunakan dalam deteksi tanda di jalan raya. Selain CLAHE, digunakan pula metode *Contrast Stretching* (CS) dan *Histogram Equalization* (HE) untuk mencari metode *low-light image enhancement* terbaik. Penelitian menggunakan dataset berupa tanda lalu lintas yang sebenarnya di jalan raya umum di Taiwan, termasuk tanda untuk belok kanan atau kiri, pembatasan kecepatan, *zebra crossing*, dan garis berhenti. Hasil eksperimen

menunjukkan bahwa CLAHE memberikan hasil terbaik dengan rata-rata mAP 88,10% pada set pelatihan, diikuti oleh CS dengan 87,98%, HE dengan 87,85%, dan gambar tanpa *enhancement* yang memperoleh mAP terendah 87,70%. Kesimpulannya, metode CLAHE terbukti mampu meningkatkan efektivitas deteksi tanda jalan pada kondisi malam hari dengan hasil yang lebih baik dibandingkan metode CS dan HE. Penelitian yang dilakukan oleh Staroverov et al. (2018) membuktikan bahwa citra yang dihasilkan oleh CLAHE memiliki nilai piksel yang lebih tinggi dibandingkan dengan citra aslinya serta mampu menampilkan lebih banyak detail dan struktur. Penelitian lainnya oleh Saenpaen et al. (2019) juga menyimpulkan bahwa CLAHE efektif dalam mempertahankan tingkat kecerahan citra (Mohd-Isa et al., 2021).

Berdasarkan latar belakang di atas, penelitian ini berfokus pada pengembangan sistem pendeteksian pelanggaran kendaraan lawan arah di jalan. Sistem dirancang agar efektif dalam berbagai kondisi lingkungan dengan memanfaatkan model deteksi objek YOLOv11 serta teknik peningkatan citra CLAHE guna meningkatkan akurasi deteksi. Dataset yang digunakan mencakup berbagai kondisi sehingga mampu merepresentasikan situasi secara *real-time* dengan lebih akurat. Selain dilakukan evaluasi dengan data uji, model yang telah dilatih diintegrasikan dengan model pelacakan ByteTrack untuk mendeteksi pelanggaran yang terjadi dalam citra video. Model dievaluasi berdasarkan hasil presisi, *recall*, mAP, dan *F1-score* untuk melihat performa hasil pelatihan yang diperoleh. Sementara itu, sistem diuji dengan menghitung akurasi, *false positive rate* (FPR), dan *frame per second* (FPS) menggunakan citra video untuk menilai kemampuan sistem dalam mendeteksi pelanggaran dengan benar dan meminimalkan kesalahan deteksi. Hasil didemonstrasikan melalui web dengan input file video maupun URL video *live streaming* di jalan untuk melakukan deteksi pelanggaran lalu lintas secara *real-time*.

Dengan adanya penelitian ini, diharapkan dapat menghasilkan sistem deteksi pelanggaran lawan arah pada jalan satu arah berbasis citra video yang efektif dan efisien. Hal ini akan meningkatkan keselamatan di jalan raya karena memungkinkan pihak berwenang untuk lebih cepat bertindak dalam mengatasi atau

meminimalkan potensi insiden yang mempengaruhi keselamatan dan keamanan bagi para pengguna jalan.

B. Perumusan Masalah

Berdasarkan pada latar belakang di atas maka masalah dalam penelitian ini dapat dirumuskan sebagai berikut:

1. Bagaimana performa model YOLOv11n-seg dalam segmentasi jalan raya?
2. Bagaimana performa model YOLOv11n dalam deteksi kendaraan?
3. Bagaimana performa sistem dalam mendeteksi pelanggaran kendaraan lawan arah pada citra video dengan kondisi pencahayaan yang berbeda-beda?

C. Pembatasan Masalah

Berdasarkan perumusan masalah di atas, terdapat batasan masalah yang melingkupi penelitian ini, yaitu:

1. Arsitektur desain dibatasi pada penggunaan model YOLOv11n untuk deteksi objek dan YOLOv11n-seg untuk segmentasi objek.
2. Segmentasi jalan dikhususkan pada area jalan dengan bentuk relatif lurus atau memiliki belokan ringan serta tidak mencakup jalan dengan struktur kompleks seperti percabangan atau persimpangan yang rumit.
3. Deteksi objek difokuskan pada kendaraan yang berada di area jalan raya, dengan klasifikasi terbatas pada bus, mobil, sepeda motor, pikap, dan truk.
4. Penerapan CLAHE dibatasi pada nilai *clip limit* (CL) antara 0,01, 0,1, 0,25, 0,5, 0,75, 1,0, 1,5, dan 2,0 serta *number of tiles* (NT) antara 4x4, 8x8, dan 16x16.
5. Deteksi pelanggaran difokuskan pada kondisi jalan satu arah. Apabila ditemukan jalan dua arah, maka arah dominan kendaraan akan digunakan sebagai acuan utama dalam klasifikasi arah pelanggaran.

D. Tujuan Penelitian

Tujuan umum penelitian ini adalah mengembangkan sistem deteksi pelanggaran lawan arah di jalan berbasis citra video menggunakan detektor objek YOLOv11, CLAHE, dan *object tracking ByteTrack*.

E. Manfaat Penelitian

Penelitian yang dilakukan memiliki manfaat sebagai berikut.

1. Memberikan kontribusi terhadap pengembangan teknologi pengawasan lalu lintas yang lebih efisien dan efektif dalam mendeteksi kendaraan di jalan raya.
2. Meningkatkan keselamatan di jalan raya dengan mendeteksi pelanggaran yang berpotensi berbahaya dan mengganggu lalu lintas.
3. Menambah literatur ilmiah dan menjadi acuan bagi penelitian selanjutnya dalam bidang pengawasan lalu lintas dan penerapan algoritma pembelajaran mesin untuk aplikasi serupa.

