

Penelitian Terkini Tentang Sistem Pendeteksi Pelanggaran Lalu Lintas Berbasis Deep Learning: Sebuah Kajian Pustaka

Dimas Ariyoga
Jurusan Informatika
Universitas Islam Indonesia
Yogyakarta
17523137@students.uii.ac.id

Ridho Rahmadi
Jurusan Informatika
Universitas Islam Indonesia
Yogyakarta
095230410@uui.ac.id

Rian Adam Rajagede
Jurusan Informatika
Universitas Islam Indonesia
Yogyakarta
190230101@uui.ac.id

Abstrak— Kajian pustaka ini menganalisis sejauh mana dan metode apa yang digunakan di dalam penelitian-penelitian sebelumnya terkait dengan permasalahan deteksi pelanggaran lalu lintas. Dari sebelas literatur yang dikaji, diketahui bahwa penelitian-penelitian ini menggunakan algoritma-algoritma *Deep Learning* seperti YOLO, CNN, *Faster R-CNN* dan metode-metode dari *Image Processing* seperti *Haar-like Feature* dan *Edge Detection* serta metode *Evolutionary Programming* seperti *Genetic Algorithm* dalam pengembangan masing-masing sistemnya. Metode-metode yang digunakan memperoleh nilai akurasi dan ketepatan yang cukup dan bahkan sangat baik. Namun, terdapat beberapa kelemahan pada pendeteksian kendaraan dan pelanggaran pada keadaan minim cahaya. Selain itu, ditemukan juga bahwa banyaknya *data set* dan beragamnya sudut pandang pada gambar pada proses pelatihan berpengaruh pada kecepatan dan nilai akurasi hasil model. Di antara metode lainnya, CNN dan YOLOv3 menjadi metode dan algoritma yang paling efektif digunakan dengan hasil akurasi yang paling tinggi yaitu di atas 90%.

Kata Kunci—*Deteksi Pelanggaran Pada Lalu Lintas, Kajian Pustaka, Deep Learning, Image Processing*

I. PENDAHULUAN

Tingginya jumlah kecelakaan lalu lintas selalu menyita perhatian masyarakat. Sebab, kecelakaan lalu lintas terus merenggut korban jiwa serta menyebabkan kerugian finansial dan dapat memengaruhi psikologis korban. Menurut data POLRI, terdapat 107.500 kecelakaan lalu lintas sepanjang tahun 2019. Angka ini merupakan peningkatan 3% dari 2018, yakni sebanyak 103.672 kecelakaan [1].

Menurut Dirkomsel Korlantas POLRI (2018), kecelakaan lalu lintas akibat pelanggaran lalu lintas seperti menerobos marka jalan dan tidak menggunakan helm menyumbang angka kematian yang paling besar pada kasus kecelakaan seperti yang tercatat pada Ditlantas Polda Metro Jaya [2]. Bahkan menurut data WHO, kecelakaan akibat mengabaikan aturan lalu lintas telah menelan korban sebanyak 2,4 juta jiwa manusia setiap tahunnya. Jumlah angka kematian yang diakibatkan kecelakaan tersebut menduduki peringkat ketiga sebagai penyebab kematian manusia setelah HIV/AIDS dan TBC [3].

Tingginya dampak pelanggaran aturan lalu lintas terhadap terjadinya kecelakaan lalu lintas telah mendapat respons oleh polisi di Indonesia dengan melakukan aksi tilang. Tilang sendiri terbukti telah berhasil dalam mengurangi pelanggaran lalu lintas yang terjadi karena dapat memberikan efek jera [4]. Namun dalam penerapannya, terdapat beberapa masalah dalam upaya penilangan ini, salah satunya adalah bahwa tidak

mungkin ada polisi yang berjaga selama 24 jam di suatu area tertentu [5].

Dari permasalahan tersebut sebuah sistem teknologi informasi yang mampu mengawasi aktivitas lalu lintas selama 24 jam sangat dibutuhkan. Sistem ini diharapkan mampu mendeteksi pelanggaran yang dilakukan oleh pengendara mobil dan sepeda motor.

Kajian pustaka ini dibuat untuk mengetahui sejauh mana perkembangan penelitian-penelitian terkait pendeteksian pada objek kendaraan dan pelanggaran lalu lintas. Terdapat beberapa pembahasan yang jadi fokus utama dalam kajian pustaka ini, yaitu metode yang digunakan dan objek yang dideteksi. Dari pembahasan ini, akan diketahui metode-metode yang mempunyai nilai akurasi tinggi dalam pendeteksian objek dan objek apa saja yang dapat berfungsi sebagai parameter utama dalam deteksi pelanggaran lalu lintas.

Beberapa pertanyaan yang dibahas dalam kajian pustaka ini di antaranya: (a) metode atau algoritma apa saja yang telah digunakan untuk deteksi objek kendaraan dan pelanggaran lalu lintas?; dan (b) metode apa yang bisa bekerja secara efektif dan efisien?

Analisis dan temuan akan disajikan sebagai berikut. Subbab 2 menjelaskan strategi seleksi literatur. Subbab 3 menjelaskan temuan yang ditemukan dalam penelitian-penelitian yang dikaji. Subbab 4 menjelaskan kesimpulan dari kajian pustaka ini.

II. STRATEGI SELEKSI LITERATUR

Kajian pustaka ini ditulis dengan mengkaji literatur-literatur terdahulu yang berkaitan dengan sistem deteksi pelanggaran pada lalu lintas. Terdapat beberapa kriteria dalam menyeleksi literatur yang akan dikaji, di antaranya:

A. Portal Literatur yang Digunakan

Literatur yang ada pada kajian pustaka ini dapat di temukan pada situs Google Scholar.

B. Batasan Seleksi Literatur

Literatur yang dipilih sebagai bahan kajian merupakan pustaka-pustaka berupa jurnal yang ditulis dalam bahasa Inggris dan bahasa Indonesia dari sepuluh tahun terakhir.

C. Kata Kunci dan Kombinasinya dalam Pencarian Literatur

Sebelas literatur yang dikaji, dicari menggunakan kata kunci:

- *Deep Learning* untuk Klasifikasi Jenis Kendaraan
- *Deep Learning Algorithm for Traffic Violation*.
- *Deep Learning for Object Detection*
- *Helmet Detection Using Deep Learning*
- *Vehicle Detection Neural Network*
- *Traffic Violation Neural Network*.
- *Object Detection Computer Vision*
- *Object Detection*

Didapatkan 25 literatur dalam pencarian dengan kombinasi kata kunci seperti di atas, namun hanya sebelas yang cocok terhadap pembahasan deteksi pelanggaran lalu lintas.

III. TEMUAN

A. Gambaran Umum Literatur

Kajian pustaka ini mengkaji sebelas penelitian mengenai deteksi dan klasifikasi objek kendaraan dan pelanggaran lalu lintas. Dari kajian ini, diketahui bahwa penelitian-penelitian tersebut menggunakan berbagai macam algoritma, arsitektur, model, dan metode yang berbeda. Hasil dari penelitian-penelitian ini adalah sistem untuk deteksi dan klasifikasi objek kendaraan dan deteksi pelanggaran lalu lintas oleh kendaraan bermotor.

B. Deteksi Kendaraan

Deteksi kendaraan merupakan salah satu masalah yang berkaitan dengan *object detection*, di mana kita bermaksud untuk mencari posisi dari objek tersebut. Dengan *object detection*, kendaraan seperti mobil dan sepeda motor yang melakukan pelanggaran lalu lintas dapat dideteksi sehingga diharapkan dapat mempermudah dalam memantau keadaan lalu lintas [6].

Selain kendaraan, ada objek-objek lain yang dideteksi pada literatur-literatur ini, seperti *zebra cross*, helm, pelat nomor, dan pejalan kaki [7], [8], [9], [10], dan [11]. Pendeteksian objek-objek ini bertujuan untuk proses deteksi pelanggaran pada lalu lintas. Untuk mendeteksi dan klasifikasi objek tersebut dari video dan citra, penelitian [7], [8], dan [10] – [15] telah mengusulkan penggunaan algoritma-algoritma *deep learning* seperti YOLO, CNN, dan *Faster R-CNN*, sedangkan penelitian lainnya melakukan deteksi dan klasifikasi objek menggunakan metode-metode dari *image processing* seperti *Haar-like Feature* [16] dan *Edge Detection* [17]. Selain itu, ada juga yang menggunakan metode *evolutionary programming* seperti *Genetic Algorithm* yang digunakan pada penelitian [9].

Dari sebelas literatur yang dikaji, penelitian [10] dan [12] – [16] berfokus hanya pada pendeteksian objek saja. Penelitian [12], [15], dan [16] melakukan deteksi objek kendaraan seperti mobil dan sepeda motor, sedangkan penelitian [10], [13], dan [14] berfokus hanya dalam pendeteksian sepeda motor saja.

Penelitian [10] yang melakukan deteksi pengendara sepeda motor dari video *dash cam*, menggunakan algoritma *Convolutional Neural Network* (CNN). Bahasa pemrograman yang digunakan dalam metode ini adalah Python untuk versi Windows dan proses pelatihan dilakukan menggunakan *library Keras*.

Sliding window dan *heat map* digunakan dalam makalah ini untuk mencari *region* atau area pengendara sepeda motor. Dua eksperimen dilakukan dalam makalah ini. Eksperimen pertama terdiri atas tiga bobot yang sudah dilatih sedangkan eksperimen kedua mengandung satu bobot yang sudah dilatih. Kinerja bobot terhadap data pengujian pada eksperimen pertama dan eksperimen kedua diukur melalui *f1-score* masing-masing 0,977, 0,988, 0,989, dan 0,986. Dari hasil percobaan menggunakan *sliding window*, eksperimen 2 memiliki tingkat kesalahan yang lebih rendah untuk memprediksi pengendara sepeda motor dibandingkan dengan eksperimen 1 karena data pelatihan pada eksperimen 1 lebih banyak jumlahnya dan mengandung citra yang lebih variatif.

Stochastic Gradient Descent (SGD) digunakan untuk proses pelatihan yang bertujuan untuk meminimalkan kesalahan dan memperbarui bobot dengan nilai parameter *learning rate* sebesar 0,01, *decay* 5×10^{-4} , dan momentum 0,9. Parameter tersebut digunakan untuk mengurangi kesalahan pada proses pelatihan. Sebagian besar nilai parameter dan metode pelatihan mengikuti artikel *AlexNet* [14]. Berdasarkan hasil eksperimen, deteksi pengendara sepeda motor dengan menggunakan CNN mampu menangani fitur yang kompleks dan variatif. Waktu pelatihan bobot terhadap data dengan ukuran yang besar jauh lebih lama dibandingkan dengan ukuran data yang lebih kecil. Selain itu, fungsi aktivasi *relu* mampu mempercepat pelatihan dari *epoch* pertama sampai *epoch* ke-10. Kinerja bobot terhadap data pengujian pada eksperimen satu dan eksperimen dua menghasilkan *f1-score* masing-masing 0,977, 0,988, 0,989, dan 0,986. *Sliding Window* dan *heat map* mampu mendeteksi lokasi pengendara sepeda motor. Kecepatan *sliding window* pada eksperimen satu jauh lebih cepat dibandingkan dengan kecepatan *sliding window* pada eksperimen dua. Namun, eksperimen dua memiliki tingkat *error* yang lebih rendah untuk memprediksi pengendara sepeda motor dibandingkan dengan eksperimen 1. Hal ini dikarenakan data pelatihan yang lebih banyak dan mengandung citra blur serta citra tidak blur.

Penelitian [12] mempelajari algoritma pendeteksian kendaraan berdasarkan *Convolutional Neural Network* (CNN) yang mengintegrasikan warna dan kedalaman citra, mempelajari pengaruh parameter pembelajaran pada kinerja jaringan selama *pelatihan Deep Neural Network* serta mengusulkan sebuah strategi pembelajaran dinamis berdasarkan rekombinasi sampel yang sulit. Penelitian ini memverifikasi kinerja algoritma, akurasi algoritma, dan kemampuan identifikasi oleh model dengan uji simulasi. Hasil pengujian menunjukkan bahwa, algoritma untuk mengidentifikasi kendaraan berdasarkan *Migration Learning* yang diusulkan dalam penelitian ini memiliki rata-rata tingkat identifikasi 96,89% pada lingkungan cerah, mendung, hujan dan keadaan lainnya, serta performa identifikasinya lebih baik daripada metode tradisional.

Penelitian [13] yang melakukan pendeteksian objek mobil dan orang, didasarkan pada YOLO yang dimodifikasi dengan menggunakan 7 lapisan *convolutional neural network*. Sel *grid* sistem divariasikan untuk mengevaluasi efektivitas dan kemampuannya dalam mendeteksi objek orang dan mobil

yang berukuran kecil dalam citra dunia nyata. Hasil eksperimen menunjukkan bahwa bahkan dengan 7 lapisan *convolutional*, sistem ini mampu memberikan akurasi deteksi yang baik dalam operasi secara *real time*. Pada penelitian ini, diamati juga bahwa akurasi pendeteksian meningkat dengan bertambahnya jumlah sel *grid*. Menggunakan sel *grid* yang lebih besar memungkinkan YOLO yang dimodifikasi untuk meningkatkan deteksi objek kecil. *Mean Average Precision* (mAP) dari YOLO_11x11 lebih tinggi dari YOLO_7x7 dan YOLO_9x9 masing-masing sebesar 1,5% dan 3,2%. YOLO_11x11 dengan mAP 41.1% lebih rendah 18.3% dibandingkan dengan YOLO dengan mAP sebesar 59.2%. Karena batasan *framework* YOLO asli adalah untuk mendeteksi objek kecil, maka mengubah parameter sel *grid* diyakini sebagai alternatif yang baik dalam meningkatkan akurasi.

Penelitian [15] mengusulkan model CNN yang berbasis *Faster R-CNN* untuk mendeteksi sepeda motor dalam skenario perkotaan. Penggunaan *Faster R-CNN* juga dilakukan untuk meningkatkan atau mempercepat proses pelatihan data. Model ini terbukti dapat menangani citra yang sedikit tertutup objek lain dan mencapai akurasi 75% pada AP. Seperti kebanyakan arsitektur *deep learning* yang dipelajari, model tersebut menyajikan hasil yang lebih baik dengan menggunakan banyak data untuk pembelajaran. Penggunaan banyak data juga menjadikan proses pelatihan sebagai tugas yang memakan waktu, bahkan dengan penggunaan arsitektur *Graphical Processing Unit* (GPU).

Penelitian [16] yang melakukan pendeteksian kendaraan di jalan, menggunakan bahasa pemrograman Python dan *library* OpenCV dalam pengembangannya. Penelitian ini menggunakan *Haar-like Feature* sebagai metode untuk melakukan deteksi kendaraan pada lalu lintas. Kesalahan-kesalahan saat penggolongan jenis kendaraan pada penelitian ini disebabkan oleh faktor jarak antar objek kendaraan yang cenderung lebih rapat atau bahkan lebih cepat. Kemudian, faktor kedua adalah sudut pandang kamera yang tidak sesuai, dan yang terakhir adalah karena objek kendaraan bergerak lebih lambat dari nilai batas waktu maksimal yang ditetapkan. Masing-masing skenario uji coba (kondisi jalan sepi, normal, dan padat) menggunakan 4 nilai batas waktu maksimal objek kendaraan untuk melewati wilayah deteksi, yaitu 25, 30, 35, dan 40. Program pada penelitian ini memiliki akurasi rata-rata 77.8% untuk kondisi jalan sepi, 47.5% untuk kondisi jalan normal, dan 28.2% untuk kondisi jalan padat. Hal-hal yang memengaruhi akurasi deteksi adalah sudut pandang kendaraan terhadap kamera, jarak antar kendaraan, serta waktu tempuh kendaraan dalam memasuki hingga keluar dari wilayah deteksi.

C. Deteksi Pelanggaran

Berdasarkan literatur-literatur yang ada, pelanggaran lalu lintas dapat dideteksi dengan cara mendeteksi objek kendaraan bersama dengan objek pelanggarannya [7]. Misalnya pada sepeda motor, pelanggaran akan dideteksi dengan mengklasifikasikan pengendara sepeda motor yang menggunakan helm dan pengendara sepeda motor yang tidak menggunakan helm. Ada juga yang mendeteksi pelanggaran dengan melihat apakah objek kendaraan seperti mobil dan sepeda motor berada pada *zebra cross* saat ada pejalan kaki yang menyeberang, hal ini juga termasuk pelanggaran lalu lintas.

Pada bagian ini, akan dibahas mengenai cara penelitian-penelitian tersebut mendeteksi pelanggaran pada lalu lintas serta hasil dan akurasi yang diperoleh dari model dan metode yang diterapkan.

Penelitian [7] yang melakukan deteksi pelanggaran pada lalu lintas, menggunakan *data set* berupa video yang menampilkan pejalan kaki, mobil, dan *zebra cross* pada lalu lintas. Penelitian ini mengusulkan algoritma baru untuk mendeteksi secara otomatis pelanggaran peraturan lalu lintas untuk keamanan pejalan kaki. Algoritma ini menggunakan proses *multi-step*. Setelah memasukkan data *input*, selanjutnya video dikonversi menjadi sejumlah *frame*. Setelah itu dilakukan pendeteksian tiga kelas objek, yaitu deteksi *zebra cross*, deteksi mobil, dan deteksi pejalan kaki. Untuk deteksi mobil, penelitian ini menggunakan salah satu *tool* yang ada pada *deep learning*, yaitu *Faster R-CNN*. Proses pendeteksian *zebra cross* dilakukan dengan melakukan proses Segmentasi, sedangkan pendeteksian pejalan kaki dilakukan dengan *Motion-Based Multiple Object Tracking*. Pada penelitian ini, pelanggaran lalu lintas diketahui dengan cara membandingkan *frame* pada video *sequence* yang sama pada pejalan kaki, kendaraan, dan *zebra cross*. Jika pejalan kaki dan kendaraan terdeteksi secara bersamaan melintasi *zebra cross* di dalam *frame* pada urutan video yang sama, berarti kendaraan tersebut telah melanggar peraturan lalu lintas, yaitu tidak diperbolehkan melaju saat pejalan kaki sedang menyeberang. Efektivitas algoritma ini ditunjukkan dalam keberhasilannya saat mendeteksi pelanggaran yang dilakukan pengendara mobil pada kerangka uji yang telah dibuat.

Penelitian [8] mendeteksi pelanggaran lalu lintas dengan cara menempatkan daerah *Region of Interest* (ROI) pada area jalan yang dilewati oleh kendaraan sebagai garis merah. Garis ini menunjukkan garis sinyal di mana kendaraan harus berhenti selama lampu merah. Jadi, jika ada kendaraan yang melewati area ROI ini, maka kendaraan tersebut terdeteksi telah melanggar lalu lintas. Selain itu, pelanggaran berupa melanggar standar kecepatan pada jalan raya juga dideteksi dengan cara melihat perubahan objek pada video *frame* demi *frame* dan menentukan kecepatan dari kendaraan tersebut menggunakan parameter *anchor point*. Penelitian ini menggunakan YOLOv3 sebagai algoritma untuk deteksi objek. Pendeteksian dilakukan dengan *neural network* dan model *object detection* yang digunakan untuk mengklasifikasikan objek bergerak ke dalam kelas yang berbeda, sehingga klasifikasi kendaraan dan pelanggarannya dapat dilakukan. Hasil menunjukkan bahwa deteksi beberapa pelanggaran lalu lintas dari satu sumber *input* dapat diarsipkan. Sistem memiliki akurasi 97.67% untuk deteksi jumlah kendaraan dan akurasi 89.24% untuk mendeteksi kecepatan kendaraan. Waktu deteksi lebih rendah untuk arus lalu lintas dengan kepadatan tinggi. Dengan demikian, kecepatan operasi sistem tergantung pada kepadatan lalu lintas. Penelitian ini menunjukkan bahwa algoritma YOLOv3 cocok untuk deteksi pelanggaran lalu lintas.

Penelitian [9] yang mendeteksi pelanggaran lalu lintas, menggunakan *Genetic Algorithm* untuk mengetahui apakah kendaraan telah melanggar salah satu aturan lalu lintas yang telah ditetapkan, yaitu *swerving lane* dan kendaraan yang menutupi jalur pejalan kaki. Dalam proses deteksi pelanggaran, algoritma deteksi pelanggaran *swerving lane* lebih cepat dibandingkan algoritma pendeteksian kendaraan yang melanggar dengan menutupi jalur pejalan kaki. Perbedaan waktu konvergensi ini dapat dikaitkan dengan

perbedaan persyaratan dan kesesuaian antara keduanya. Dengan demikian, sistem membutuhkan lebih sedikit iterasi, generasi, dan *runtime* program dalam mendeteksi *swerving*. Dapat juga disimpulkan bahwa deteksi *swerving* lebih sederhana daripada deteksi pemblokiran jalur pejalan kaki. Untuk sub proses pengenalan pelat dari sistem digunakan *Artificial Neural Network* (ANN). Untuk proses lokalisasi pelat, *Genetic Algorithm* mampu menyatu dengan nilai fitness yang diinginkan. Penelitian ini juga menggunakan teknik *preprocessing* untuk mengatasi citra pelat yang terlalu kecil, buram, dan berkualitas buruk sebelum melakukan segmentasi. Secara umum, sistem telah diuji dengan akurasi keseluruhan 90,67%. Kekurangan pada sistem ini yaitu *runtime* program yang lambat, hal ini dapat ditingkatkan dengan menggunakan komputer dengan spesifikasi prosesor yang lebih cepat.

Penelitian [10] yang melakukan deteksi dan klasifikasi pada pengendara sepeda motor, mengklasifikasikan pelanggaran lalu lintas dengan cara mendeteksi objek helm pada pengendara sepeda motor. Penelitian ini menggunakan arsitektur YOLOv3 untuk mendeteksi objek orang atau pengendara dan sepeda motor. Pada tahap kedua, arsitektur *lightweight* CNN digunakan untuk melakukan deteksi pada objek helm. Arsitektur *lightweight* CNN yang ringan digunakan untuk komputer non-GPU yang terinspirasi dari YOLO-LITE. Jaringan yang dibangun memiliki kecepatan proses yang tinggi karena ukuran citra yang digunakan dalam proses *input* deteksi helm lebih kecil. Jadi lebih sedikit pula data yang akan melewati jaringan, dan hal ini dapat meningkatkan kecepatan jaringan. Karena normalisasi batch tidak penting untuk jaringan kecil, jadi tidak diperlukan perhitungan perantara untuk jaringan tersebut di setiap lapisan jaringan. Oleh karena itu, tidak terjadi kehilangan waktu tambahan dalam proses *feed-forward*. *Stochastic Gradient Descent with Momentum* (SGDM) diterapkan di sini sebagai algoritma pengoptimalan untuk melatih jaringan. Penelitian ini juga menggunakan algoritma *backpropagation* untuk mencapai tingkat akurasi yang diharapkan. Model yang diusulkan bekerja cukup baik untuk deteksi helm dengan berbagai skenario, 818 dari sekitar 850 citra helm yang ada dalam *data set* berhasil dideteksi dengan akurasi 96,23% AP.

Penelitian [11] melakukan deteksi helm pada pengguna sepeda motor menggunakan 2 metode, yaitu *You Only Look Once* (YOLO) dan *Convolutional Neural Network* (CNN). Metode YOLO digunakan untuk mencari region dari sepeda motor dan pengendara sepeda motor, sedangkan metode CNN digunakan untuk mengklasifikasi helm pada pengendara sepeda motor. Di dalam metode *Convolutional Neural Network* ini dilakukan 3 tahap penting, yaitu *preprocessing*, *training*, dan *testing* yang dibutuhkan untuk mendapatkan *weights* dan model yang tepat agar dapat digunakan untuk mengklasifikasi pengendara yang menggunakan helm dan pengendara yang tidak menggunakan helm.

Hasil dari klasifikasi CNN tadi dihitung menggunakan *confusion matrix* agar mendapatkan akurasi dari prediksi yang benar. Dari tabel matriks yang didapatkan akan dihitung akurasi, presisi, *f-score*, dan *recall* berdasarkan kondisi data yang diprediksi atau diklasifikasi. Akurasi yang didapatkan antara pengendara sepeda motor yang mengemudi dengan helm dan tanpa helm adalah 70.49%. Hasil program dari penelitian ini akan mengidentifikasi pengguna helm pada pengendara motor dalam video yang tentu saja dapat dihubungkan dengan pelanggaran lalu lintas.

Berikut tabel perbandingan metode yang dipakai kesebelas literatur yang dikaji beserta hasil pengujian masing-masing metodenya.

TABEL I. PERBANDINGAN METODE

Pustaka	Metode/ Algoritma	Hasil
[7]	<i>Faster R-CNN</i>	Efektivitas algoritma ini ditunjukkan dalam keberhasilannya saat mendeteksi pelanggaran yang dilakukan pengendara mobil pada kerangka uji yang telah dibuat.
[8]	YOLO v3, <i>Convolutional Neural Network</i> (CNN)	Sistem memiliki akurasi 97.67% untuk deteksi jumlah kendaraan dan akurasi 89.24% untuk mendeteksi kecepatan kendaraan.
[9]	<i>Genetic Algorithm</i> , <i>Artificial Neural Network</i> (ANN)	Sistem telah diuji pada 47 citra dengan akurasi keseluruhan 90,67%.
[10]	YOLO v3, <i>Convolutional Neural Network</i> (CNN)	Model yang diusulkan bekerja cukup baik untuk mendeteksi helm dalam berbagai skenario dengan akurasi 96,23%.
[11]	YOLO v3, <i>Convolutional Neural Network</i> (CNN)	<i>Convolutional Neural Network</i> (CNN) memiliki <i>precision</i> yang lebih rendah pada pengendara sepeda motor yang tidak menggunakan helm, yaitu sebesar 37.5% dan hasil untuk pengendara sepeda motor yang menggunakan helm sebesar 82.22%.
[12]	<i>Faster R-CNN</i> .	Algoritma yang diusulkan dalam makalah ini memiliki rata-rata tingkat identifikasi 96,89% pada lingkungan cerah, mendung, hujan dan kondisi lainnya.
[13]	YOLO v3, <i>Convolutional Neural Network</i> (CNN)	<i>Mean average precision</i> (mAP) dari YOLO_11x11 lebih tinggi dari YOLO_7x7 dan YOLO_9x9 masing-masing sebesar 1,5% dan 3,2%. YOLO_11x11 dengan mAP 41.1% lebih rendah 18.3% dibandingkan dengan YOLO dengan mAP sebesar 59.2%. Pada penelitian ini, diamati juga bahwa akurasi pendeteksian meningkat dengan bertambahnya jumlah sel <i>grid</i> .
[14]	<i>Convolutional Neural Networks</i> (CNN)	Kinerja bobot terhadap data pengujian pada eksperimen 1 dan eksperimen 2 menghasilkan <i>f1-score</i> masing-masing 0,977, 0,988, 0,989, dan 0,986.
[15]	<i>Faster-RCNN</i>	Akurasi yang dihasilkan mencapai hasil yang menjanjikan, yaitu 75% dalam rata-rata presisi (AP). Model ini juga dievaluasi pada <i>data set</i> dengan oklusi rendah, dan mencapai hasil hingga 92% AP.
[16]	<i>Haar-like Feature</i> .	Akurasi rata-rata 77.8% untuk kondisi jalan sepi, 47.5% untuk kondisi jalan normal, dan 28.2% untuk kondisi jalan padat.
[17]	<i>Backpropagation</i> , <i>Edge Detection</i> (Dengan menggunakan operator <i>Sobel</i>)	Tingkat pengujian sistem pada pagi, siang, malam secara rata-rata adalah 94,63% , 93,85% , dan 68,32%.

Hasil evaluasi berupa akurasi dan presisi yang diperoleh dari metode-metode pada Tabel I di atas didapatkan dengan melakukan pengujian dengan cara yang berbeda-beda. Dari

semua penelitian di atas, hanya penelitian [16] yang tidak menjelaskan cara pengujian modelnya.

Penelitian [7] membuat kerangka uji yang membandingkan *frame* pada video yang sama pada pejalan kaki, kendaraan, dan *zebra cross*. Jika pejalan kaki dan kendaraan terdeteksi secara bersamaan melintasi *zebra cross* di dalam *frame* pada video yang sama, berarti kendaraan tersebut telah melanggar peraturan lalu lintas, yaitu tidak diperbolehkan melaju saat pejalan kaki sedang menyeberang. Pengujian akurasi model pada penelitian [8] dilakukan dengan cara membandingkan jumlah kendaraan pelanggar yang terdeteksi oleh model, dengan jumlah kendaraan yang sebenarnya melanggar aturan lalu lintas.

Penelitian [9] menguji sistemnya dengan cara mencari *fitness plot* terbaik pada pelanggaran dan deteksi pelat. Pengujian akurasi pada penelitian [10] dilakukan dengan mencari nilai rata-rata AP (*Accuracy Precision*) dari perbandingan jumlah objek helm yang bisa dideteksi dari keseluruhan data yang di uji. Penelitian [11] melakukan pengujian dengan menghitung rata-rata waktu tunggu melalui *Simulation of Urban MObility* (SUMO). Penelitian [12] melakukan pengujian dengan cara membandingkan kinerja algoritma identifikasi yang telah dibuat dengan algoritma *Support Vector Machine* dan *Template Machine*.

Presisi dan akurasi sistem pada penelitian [13] diuji dengan beberapa metode. Alat dan metodologi *Hoiem* digunakan untuk setiap pengujian kelas untuk melihat *false positive* peringkat teratas. Setiap prediksi diklasifikasikan sebagai benar atau termasuk dalam jenis kesalahan tertentu sesuai dengan batasan yang telah ditentukan. Jenis kesalahan di dua kelas diuji menggunakan model YOLO yang dimodifikasi menggunakan sel *grid* 11 x 11 bersama dengan model YOLO asli menggunakan sel *grid* 7 x 7.

Evaluasi model pada penelitian [14] dilakukan dengan cara membagi *data set* menjadi dua eksperimen dan menguji kinerja bobot dari masing-masing eksperimen dengan menghitung *f1-score*. Model pada penelitian [15] model di evaluasi dengan 3 *data set* berbeda dan dibandingkan dengan model *AlexNet*.

Untuk mendapatkan nilai ketelitian pengujian pada sistem, penelitian [17] melakukan dua jenis pengujian pada sistem, yaitu pengujian secara manual dan secara aplikasi. Untuk mendapatkan persentase dari perhitungan akurasi dilakukan dengan mencari *error* terlebih dahulu, yaitu perbandingan antara selisih jumlah kendaraan yang dideteksi oleh sistem dengan jumlah yang dilihat oleh mata manusia.

Dari pembahasan di atas, diketahui bahwa algoritma dan metode deteksi yang digunakan pada sebelas literatur yang dikaji, yaitu algoritma-algoritma *deep learning* seperti YOLO, CNN, dan *Faster R-CNN* serta metode-metode dari *image processing* seperti *Haar-like Feature* dan *Edge Detection*. Selain itu, ada juga yang menggunakan metode *evolutionary programming* seperti *Genetic Algorithm*. Di antara metode lainnya, CNN dan YOLOv3 menjadi metode dan algoritma yang paling efektif dan efisien dalam melakukan deteksi objek dan deteksi pelanggaran lalu lintas dengan hasil akurasi yang tinggi, yaitu di atas 90%.

D. Data set

Beberapa literatur di atas menyebutkan *data set* yang digunakan dalam proses penelitian. Tabel II menyebutkan data yang digunakan oleh masing-masing literatur.

TABEL II. DATA SET YANG DIGUNAKAN MASING-MASING LITERATUR

Pustaka	Data set yang Digunakan
[8]	MSCOCO <i>data set</i>
[12]	Pascal VOC 2007 dan KITTI <i>vehicle data set</i>
[13]	Pascal VOC 2007, Pascal VOC 2012, dan INRIA <i>Data set</i>
[15]	MatLab <i>Dataset</i> , Las Vegas <i>Dataset</i> , dan Motorbike Urban <i>Dataset</i>
[16]	<i>Data Set Intersection Redoubt Road and Great South Road of South of Auckland.</i>

Data set yang di sebutkan pada Tabel II berisi data aktivitas lalu lintas dalam bentuk citra dan video. Literatur yang tidak disebutkan pada Tabel II hanya menyebutkan bahwa *data set* yang digunakan berisi rekaman aktivitas lalu lintas dan tidak menyebutkan nama *data set* yang digunakan.

IV. KESIMPULAN

Dari kajian literatur yang telah dilakukan, dapat disimpulkan bahwa perkembangan teknologi *Object Detection*, *Computer Vision*, *Image Processing*, dan *Deep Learning* sangat bisa dimanfaatkan untuk membuat sistem untuk deteksi kendaraan pada lalu lintas dan deteksi otomatis pelanggaran pada lalu lintas. Pada masing-masing teknologi, terdapat berbagai macam metode yang dapat digunakan untuk mendeteksi objek dengan akurasi yang berbeda-beda tergantung jenis objek dan kondisi pengamatannya. Algoritma dan metode deteksi yang digunakan pada sebelas literatur yang dikaji, yaitu YOLO, CNN, *Faster R-CNN*, *Haar-like Feature*, *Edge Detection*, dan *Genetic Algorithm*. Rata-rata akurasi yang dicapai dari penggunaan berbagai metode pada penelitian-penelitian diatas juga sudah cukup baik. Di antara metode lainnya, CNN dan YOLOv3 menjadi metode dan algoritma yang paling umum dipakai dengan hasil akurasi yang paling tinggi, yaitu di atas 90%.

Dari pembahasan sebelas literatur yang ada, dapat disimpulkan juga bahwa rata-rata kelemahan dari penggunaan metode-metode di atas adalah kecilnya akurasi yang di peroleh bahkan ketidakmampuan model dalam melakukan pendeteksian di dalam kondisi minim cahaya. Posisi dan jarak kamera dengan objek dan pencahayaan memiliki pengaruh besar dalam pengenalan objek, untuk itu masih diperlukan metode yang lebih efisien untuk pendeteksian di malam hari atau pada kondisi minim cahaya. Selain itu, banyaknya *data set* dan beragamnya sudut pandang pada gambar pada proses pelatihan berpengaruh pada kecepatan dan nilai akurasi hasil model.

Berdasarkan temuan ini, penulis menilai bahwa CNN dan YOLOv3 dapat digunakan pada penelitian "Sistem Pendeteksi Pelanggaran Lalu Lintas Berbasis *Deep Learning*" karena kemampuan deteksi serta akurasinya yang tinggi. Objek helm, motor, mobil, dan *zebra cross* juga dapat dijadikan parameter yang bisa digunakan untuk deteksi pelanggaran pada lalu lintas. Selain itu ada beberapa hal yang harus diperhatikan untuk ke depannya, yaitu mengatasi masalah deteksi pada kondisi minim cahaya dan sudut pandang kamera terhadap objek.

REFERENSI

- [1] A. Ramadhan, "Polri Sebut Jumlah Kecelakaan Lalu Lintas Meningkat pada 2019," Jakarta, p. 1, Dec. 28, 2019.
- [2] A. Aszhari "Tekan Angka Kecelakaan, Jangan Pernah Melanggar Lalu Lintas," *Liputan6*, 2018. <https://www.liputan6.com/otomotif/read/3657076/tekan-angka-kecelakaan-jangan-pernah-melanggar-lalu-lintas> (accessed Jul. 16, 2020).
- [3] WHO (World Health Organisation), "Global Status Report on Road," *World Heal. Organ.*, p. 20, 2018, [Online]. Available: <http://apps.who.int/bookorders>.
- [4] Wagiyah, Holilulloh dan M. M. A. "Pengaruh Sanksi Tilang Bagi Pelanggar Terhadap Kedisiplinan Dalam Berlalu Lintas," 2014.
- [5] R. Setiawan, "Yang Perlu Diketahui tentang Tilang Elektronik untuk Sepeda Motor," *Tirto.id*, 2020. <https://tirto.id/yang-perlu-diketahui-tentang-tilang-elektronik-untuk-sepeda-motor-exuW> (accessed Jul. 16, 2020).
- [6] T. K. Gautama, A. Hendrik, and R. Hendaya, "Pengenalan Objek pada Computer Vision dengan Pencocokan Fitur Menggunakan Algoritma SIFT Studi Kasus: Deteksi Penyakit Kulit Sederhana," *J. Tek. Inform. dan Sist. Inf.*, vol. 2, no. 3, pp. 437–450, 2016, doi: 10.28932/jutisi.v2i3.554.
- [7] S. Ibadov, R. Ibadov, B. Kalmukov, and V. Krutov, "Algorithm for detecting violations of traffic rules based on computer vision approaches," *MATEC Web Conf.*, vol. 132, 2017, doi: 10.1051/mateconf/201713205005.
- [8] R. J. Franklin, "Traffic Signal Violation Detection using Artificial Intelligence and Deep Learning," no. Icces, pp. 839–844, 2020.
- [9] A. C. P. Uy *et al.*, "Automated traffic violation apprehension system using genetic algorithm and artificial neural network," *IEEE Reg. 10 Annu. Int. Conf. Proceedings/TENCON*, pp. 2094–2099, 2017, doi: 10.1109/TENCON.2016.7848395.
- [10] M. Dasgupta, O. Bandyopadhyay, and S. Chatterji, "Automated helmet detection for multiple motorcycle riders using CNN," *2019 IEEE Conf. Inf. Commun. Technol. CICT 2019*, pp. 1–4, 2019, doi: 10.1109/CICT48419.2019.9066191.
- [11] K. Gunadi, E. Setyati, and J. S. Surabaya, "Deteksi Helm pada Pengguna Sepeda Motor dengan Metode Convolutional Neural Network," *J. Infra*, vol. 8, no. 1, pp. 295–301, 2020.
- [12] W. Dong, Z. Yang, W. Ling, Z. Yonghui, L. Ting, and Q. Xiaoliang, "Research on vehicle detection algorithm based on convolutional neural network and combining color and depth images," *2019 2nd Int. Conf. Inf. Syst. Comput. Aided Educ. ICISCAE 2019*, pp. 274–277, 2019, doi: 10.1109/ICISCAE48440.2019.221634.
- [13] M. H. Putra, Z. M. Yussof, K. C. Lim, and S. I. Salim, "Convolutional neural network for person and car detection using YOLO framework," *J. Telecommun. Electron. Comput. Eng.*, vol. 10, no. 1–7, pp. 67–71, 2018.
- [14] S. E. Limantoro, Y. Kristian, and D. D. Purwanto, "Pemanfaatan Deep Learning pada Video Dash Cam untuk Deteksi Pengendara Sepeda Motor," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 7, no. 2, pp. 3–9, 2018, doi: 10.22146/jnteti.v7i2.419.
- [15] J. E. Espinosa, S. A. Velastin, and J. W. Branch, "Motorcycle detection and classification in urban Scenarios using a model based on Faster R-CNN," *arXiv*, no. August, 2018.
- [16] A. Andrew, J. L. Buliali, and A. Y. Wijaya, "Deteksi Kecepatan Kendaraan Berjalan di Jalan Menggunakan OpenCV," *J. Tek. ITS*, vol. 6, no. 2, 2017, doi: 10.12962/j23373539.v6i2.23489.
- [17] R. Adistya and M. A. Muslim, "Deteksi dan Klasifikasi Kendaraan menggunakan Algoritma Backpropagation dan Sobel," *J. Mech. Eng. Mechatronics*, vol. 1, no. 2, pp. 65–73, 2016.