

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

by John Doe

Submission date: 24-Nov-2020 10:50AM (UTC+0700)

Submission ID: 1454393156

File name: Kajian_Pustaka_17523137.pdf (195.98K)

Word count: 4181

Character count: 26662

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

Abstrak—Kajian pustaka ini menganalisis sejauh mana dan metode apa yang digunakan di dalam penelitian-penelitian sebelumnya terkait dengan permasalahan deteksi pelanggaran lalu lintas menggunakan *image processing* dan *deep learning*. Dari sebelas literatur yang dikaji, diketahui bahwa 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 ketepatan dan nilai akurasi hasil model.

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

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 mempengaruhi 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 Brigjen Pol. Dr Chryshnanda Dwilaksana, M.Si. (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 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.

Beberapa pertanyaan yang dibahas dalam kajian pustaka ini di antaranya: (a) metode 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 dari sepuluh tahun terakhir.

C. Kata Kunci dan Kombinasinya dalam Pencarian Literatur

- 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

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*, dimana 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 [8], [10], [13], [14], dan [17]. Pendeteksian objek-objek ini bertujuan untuk proses deteksi pelanggaran pada lalu lintas. Untuk mendeteksi dan klasifikasi objek tersebut dari video dan citra, penelitian [8] – [11] dan [14] – [17] 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 [7] dan *edge detection* [12]. Selain itu, ada juga yang menggunakan metode *evolutionary programming* seperti Genetic Algorithm yang digunakan pada penelitian [13].

Dari sebelas literatur yang dikaji, penelitian [7], [9], [11], dan [14] – [16] berfokus hanya pada pendeteksian objek saja. Penelitian [7], [9], dan [16] melakukan deteksi objek kendaraan seperti mobil dan sepeda motor, sedangkan penelitian [11], [14], dan [15] berfokus hanya dalam pendeteksian sepeda motor saja.

Penelitian [7] dengan judul "Deteksi Jenis Kendaraan di Jalan Menggunakan OpenCV" menggunakan bahasa pemrograman Python dan *library* OpenCV dalam pengembangannya. Penelitian ini menggunakan metode Haar-like Feature untuk melakukan deteksi kendaraan. 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 mempengaruhi akurasi deteksi adalah sudut pandang kendaraan terhadap kamera, jarak antar kendaraan, serta waktu tempuh kendaraan dalam memasuki hingga keluar dari wilayah deteksi.

Penelitian [9] dengan judul "Research on vehicle detection algorithm based on convolutional neural network and combining color and depth images" mempelajari algoritma pendeteksian kendaraan berdasarkan *convolutional neural network* 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 [11] dengan judul "Convolutional Neural Network for Person and Car Detection using YOLO Framework". Penelitian ini 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 konvolusional, 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 [14] dengan judul "Pemanfaatan Deep Learning pada Video Dash Cam untuk Deteksi Pengendara Sepeda Motor" menggunakan algoritma Convolutional Neural Network (CNN) untuk melakukan deteksi pengendara sepeda motor dari video *dash cam* yang beresolusi 1080 HD. 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 1 dan eksperimen 2 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 [16] dengan judul "Motorcycle detection and classification in urban Scenarios using a model based on Faster R-CNN" 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).

C. Deteksi Pelanggaran

Berdasarkan literatur-literatur yang ada, pelanggaran lalu lintas dapat dideteksi dengan cara mendeteksi objek kendaraan bersama dengan objek pelanggarannya [8]. 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 [8] dengan judul "Algorithm for detecting violations of traffic rules based on computer vision approaches" 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 [10] dengan judul "Traffic Signal Violation Detection using Artificial Intelligence and Deep Learning" 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 [13] dengan judul "Automated Traffic Violation Apprehension System Using Genetic Algorithm and Artificial Neural Network" 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 plat, *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 [14] dengan judul "Automated Helmet Detection for Multiple Motorcycle Riders using CNN" mengklasifikasikan pelanggaran lalu lintas dengan cara

meneteksi 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.

Define Penelitian [17] dengan judul "Deteksi Helm pada Pengguna Sepeda Motor dengan Metode Convolutional Neural Network" 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.

TABEL I. PERBANDINGAN METODE

| Pustaka Nomor | Metode/ Algoritma | Metode Pengujian Akurasi | Hasil |
|---------------|--------------------|---|--|
| [7] | Haar-like Feature. | Tidak disebutkan. | Akurasi rata-rata 77.8% untuk kondisi jalan sepi, 47.5% untuk kondisi jalan normal, dan 28.2% untuk kondisi jalan padat. |
| [8] | Faster R-CNN | Membuat kerangka uji yang membandingkan frame pada urutan video | Efektivitas algoritma ini ditunjukkan dalam keberhasilannya saat mendeteksi pelanggaran yang |

| | | | |
|------|---|--|---|
| | | yang sama pada pejalan kaki, kendaraan, dan <i>zebra cross</i> . Jika pejalan kaki dan kendaraan terdeteksi secara bersamaan melintasi <i>zebra cross</i> 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. | dilakukan pengendara mobil pada kerangka uji yang telah dibuat. |
| [9] | Faster R-CNN. | Kinerja dari tiga algoritma identifikasi kendaraan dan dianalisis. | Algoritma untuk mengidentifikasi kendaraan berdasarkan <i>migration learning</i> yang diusulkan dalam makalah ini memiliki rata-rata tingkat identifikasi 96,89% pada lingkungan cerah, mendung, hujan dan kondisi lainnya, serta performansi identifikasinya lebih baik daripada metode tradisional. |
| [10] | YOLO v3, Convolutional Neural Network (CNN) | Pengujian akurasi pada model ini dilakukan dengan cara membandingkan jumlah kendaraan pelanggar yang terdeteksi oleh model, dengan jumlah kendaraan yang melanggar aturan lalu lintas | Sistem memiliki akurasi 97.67% untuk deteksi jumlah kendaraan dan akurasi 89.24% untuk mendeteksi kecepatan kendaraan. Penelitian ini menunjukkan bahwa algoritma YOLOv3 cocok untuk deteksi pelanggaran lalu lintas. |
| [11] | YOLO v3, Convolutional Neural Network (CNN) | Presisi dan akurasi sistem diuji dengan beberapa metode. Alat dan metodologi Hoim digunakan untuk setiap pengujian kelas untuk melihat false positive peringkat teratas. Setiap prediksi diklasifikasikan | 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 |

| | | | |
|------|---|--|---|
| | | 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 <i>grid</i> 11 x 11 bersama dengan model YOLO asli menggunakan sel <i>grid</i> 7 x 7. | dengan mAP sebesar 59,2%. Pada penelitian ini, diamati juga bahwa akurasi pendeteksian meningkat dengan bertambahnya jumlah sel <i>grid</i> . |
| [12] | Backpropagation, Edge Detection (Dengan menggunakan operator Sobel) | Untuk mendapatkan nilai ketelitian pengujian pada sistem, dilakukan 2 jenis pengujian pada sistem ini yaitu pengujian secara manual dan secara aplikasi. Untuk mendapatkan persentase dari perhitungan akurasi dilakukan dengan mencari <i>error</i> terlebih dahulu, yaitu perbandingan antara selisih jumlah kendaraan yang dideteksi oleh sistem dengan jumlah yang dilihat oleh mata manusia | Tingkat pengujian sistem pada pagi, siang, malam secara rata-rata adalah 94,63% , 93,85% , dan 68,32%. |
| [13] | Genetic Algorithm, Artificial Neural Network (ANN) | Mencari <i>fitness plot</i> terbaik pada pelanggaran dan deteksi pelat. | Sistem telah diuji pada 47 citra dengan akurasi keseluruhan 90,67%. Waktu proses program rata-rata sistem dihitung sebagai jumlah waktu kerja rata-rata dari setiap bagian sistem, yang ternyata 1,34 detik sehingga sistem tidak berlaku untuk kamera dengan frekuensi citra tinggi. |
| [14] | YOLO v3, Convolutional Neural Network (CNN) | Pengujian akurasi dilakukan dengan mencari nilai rata-rata AP (Accuracy Precision) dari membandingkan jumlah objek | Model yang diusulkan bekerja cukup baik untuk mendeteksi helm dalam berbagai skenario dengan akurasi 96,23%. |

| | | | |
|------|---|---|---|
| | | helm yang bisa dideteksi dari keseluruhan data yang di uji. | |
| [15] | Convolutional Neural Networks (CNN) | Evaluasi model dilakukan dengan cara pembagian <i>data set</i> menjadi 2 eksperimen dan menguji kinerja bobot dari masing-masing eksperimen dengan menghitung <i>f1-score</i> | 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. |
| [16] | Faster-RCNN | Model di evaluasi dengan 3 <i>data set</i> berbeda dan dibandingkan dengan model AlexNet. | Akurasi yang dihasilkan mencapai hasil yang menjanjikan, yaitu 75% dalam rata-rata presisi (AP) bahkan dengan banyaknya sepeda motor yang sedikit tertutup dengan objek lain, sudut pengambilan yang rendah, dan kamera yang bergerak. Model ini juga dievaluasi pada dataset dengan oklusi rendah, dan mencapai hasil hingga 92% AP. |
| [17] | YOLO v3, Convolutional Neural Network (CNN) | Pengujian dilakukan dengan menghitung rata-rata waktu tunggu melalui Simulation of Urban Mobility (SUMO). | YOLOv3 yang digunakan masih mengalami kesalahan dalam mengenal sepeda atau sepeda motor. YOLOv3 juga mengalami kesalahan ketika 2 objek motor berdekatan karena akan dianggap satu region sepeda motor. Convolutional Neural Network (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%. |

D. Data set

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

TABEL II. DATA SET YANG DIGUNAKAN MASING-MASING LITERATUR

| Pustaka Nomor | Data set yang Digunakan |
|---------------|---|
| [1] | Data Set Intersection Redoubt Road and Great South Road of South of Auckland. |
| [3] | Pascal VOC 2007 dan KITTI vehicle data set |
| [10] | MSCOCO dataset |
| [11] | Pascal VOC 2007, Pascal VOC 2012, dan INRIA Dataset |
| [16] | MatLab Dataset, Las Vegas Dataset, dan Motorbike Urban Dataset |

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 juga dapat digunakan untuk mendeteksi objek dengan akurasi yang berbeda-beda tergantung jenis objek dan kondisi pengamatan. Rata-rata akurasi yang dicapai dari penggunaan berbagai metode pada penelitian-penelitian diatas juga sudah cukup baik.

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 dataset dan beragamnya sudut pandang pada gambar pada proses pelatihan berpengaruh pada kecepatan dan nilai akurasi hasil model.

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] 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.
- [8] 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.
- [9] 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.
- [10] R. J. Franklin, "Traffic Signal Violation Detection using Artificial Intelligence and Deep Learning," no. Icces, pp. 839-844, 2020.
- [11] 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.
- [12] 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.
- [13] 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.
- [14] 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.
- [15] 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.
- [16] 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.
- [17] 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.

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

ORIGINALITY REPORT

13%

SIMILARITY INDEX

13%

INTERNET SOURCES

0%

PUBLICATIONS

7%

STUDENT PAPERS

PRIMARY SOURCES

1

humaspolresbantul.blogspot.com

Internet Source

7%

2

www.researchgate.net

Internet Source

3%

3

kabar-terhangat.blogspot.com

Internet Source

2%

4

amp.kompas.com

Internet Source

2%

Exclude quotes On

Exclude matches Off

Exclude bibliography On