

# Pengembangan Sistem Pengenalan Pola Citra Spion Kendaraan Motor untuk Deteksi Pelanggaran Arus Lalu Lintas pada Jalan Satu Arah

Sitti Mawaddah Umar<sup>1\*</sup>, Justam<sup>2</sup>

<sup>1</sup>Manajemen Informasi Kesehatan, Politeknik Kesehatan Megarezky, Makassar, Indonesia

<sup>2</sup> Program Studi Informatika, Universitas Mega Buana Palopo

Email: <sup>1</sup>sittimawaddahumar05@gmail.com, <sup>2</sup> Justam@umegabuana.ac.id

Email Penulis Korespondensi: <sup>1</sup>sittimawaddahumar05@gmail.com

**Abstrak**— Penelitian ini bertujuan untuk mendeteksi pelanggaran lalu lintas, khususnya sepeda motor yang melawan arus di jalan satu arah, dengan memanfaatkan teknologi visi komputer untuk mengenali pola tampak belakang kendaraan. Metode yang digunakan adalah penerapan model deep learning Faster-RCNN untuk deteksi objek, dengan data citra yang diperoleh dari kamera IP yang dipasang pada tiang setinggi 2,5 meter dengan sudut kemiringan 45 derajat, sehingga dapat memantau kendaraan dari belakang secara optimal. Proses pelabelan gambar dilakukan menggunakan aplikasi LabelImg, sedangkan pelatihan dan klasifikasi model dilakukan menggunakan framework TensorFlow. Sistem yang dikembangkan berhasil mencapai akurasi deteksi sebesar 88%, menunjukkan efektivitas pendekatan ini dalam mengenali sepeda motor yang melawan arus. Temuan ini menegaskan potensi visi komputer sebagai solusi otomatis dan real-time dalam pengawasan lalu lintas, yang dapat membantu menurunkan tingkat pelanggaran berbahaya dan meningkatkan keselamatan di jalan raya. Dengan demikian, penelitian ini memberikan kontribusi penting bagi pengembangan sistem deteksi pelanggaran lalu lintas yang lebih canggih dan efisien.

**Kata Kunci:** Faster R-CNN, Pengenalan sepeda motor, Pelanggaran sepeda motor, Deteksi kendaraan

**Abstract**— This study aims to detect traffic violations, specifically motorcycles riding against the flow on one-way roads, by utilizing computer vision technology to recognize the rearview patterns of vehicles. The method employed involves applying the deep learning model Faster-RCNN for object detection, using image data captured from an IP camera mounted on a pole at a height of 2.5 meters with a 45-degree tilt angle to optimally monitor vehicles from behind. Image labeling was performed using the LabelImg application, while model training and classification were conducted using the TensorFlow framework. The developed system achieved a detection accuracy of 88%, demonstrating the effectiveness of this approach in identifying motorcycles violating traffic direction. These findings highlight the potential of computer vision as an automatic and real-time solution for traffic monitoring, which can help reduce dangerous violations and enhance road safety. Therefore, this research contributes significantly to the development of more advanced and efficient traffic violation detection systems.

**Keywords:** faster R-CNN, motorcycle recognition, motorcycle violation, vehicle detection

## 1. PENDAHULUAN

Penggunaan sepeda motor, terutama di kota-kota besar, telah mengalami peningkatan yang signifikan dalam beberapa tahun terakhir. Peningkatan jumlah kendaraan ini tidak diimbangi dengan pengembangan infrastruktur jalan yang memadai. Akibatnya, kemacetan lalu lintas menjadi masalah utama yang mengganggu kenyamanan perjalanan, menyebabkan kelelahan, dan membuang waktu yang merugikan pengendara [1]. Transportasi yang ideal adalah sistem yang memiliki waktu perjalanan yang singkat, bebas dari kemacetan, aman dari kecelakaan, serta memberikan kenyamanan bagi penggunaannya.

Di sisi lain, salah satu langkah yang diambil untuk mengurangi kemacetan adalah dengan penerapan sistem jalan satu arah. Meskipun solusi ini cukup efektif untuk mengatur arus lalu lintas, muncul masalah baru berupa pelanggaran yang dilakukan oleh pengendara yang melawan arah [2]. Tindakan ini sangat berbahaya dan dapat menyebabkan kecelakaan serius, memperburuk kemacetan, dan menurunkan tingkat keselamatan lalu lintas. Berdasarkan data yang diperoleh dari artikel mengenai Undang-Undang Lalu Lintas, pada 23 Oktober 2019, sebanyak 1.547 kendaraan terjaring razia karena melawan arah di wilayah Jakarta Barat (Undang-undang., 2019). Pelanggaran semacam ini berpotensi meningkatkan angka kecelakaan dan membahayakan keselamatan pengguna jalan lainnya. Dalam Undang-Undang No. 22 Tahun 2009 tentang Lalu Lintas dan Angkutan Jalan (LLAJ) Pasal 287 Ayat 1, dijelaskan bahwa pelanggaran terhadap rambu jalan satu arah akan dikenakan sanksi berupa denda atau hukuman penjara, namun pengawasan yang minim seringkali membuat pengendara merasa bebas untuk melawan arus, terutama karena dianggap lebih cepat daripada mengikuti rambu yang benar [3].

Sebagai upaya untuk mengatasi masalah tersebut, dibutuhkan sistem pemantauan yang efektif dan dapat berjalan sepanjang waktu untuk mendeteksi pelanggaran ini secara otomatis. Dengan adanya sistem pemantauan 24 jam yang dapat mendeteksi kendaraan yang melawan arah, pelanggar dapat diberi sanksi dengan cepat, sehingga dapat menciptakan efek jera bagi pengendara lain. Oleh karena itu, penelitian ini berfokus pada pengembangan sistem pemantauan lalu lintas dengan menggunakan teknologi kamera yang dilengkapi dengan teknik visi komputer, guna mendeteksi dan mengidentifikasi pelanggaran kendaraan yang melawan arus secara real-time [4].

Seiring dengan perkembangan teknologi, berbagai penelitian telah dilakukan untuk mengoptimalkan pengawasan arus lalu lintas dengan memanfaatkan teknologi komputer. Salah satu metode yang banyak digunakan adalah visi

komputer berbasis deep learning, yang telah terbukti efektif dalam berbagai aplikasi pengawasan lalu lintas. Pada 2017, [5] mengembangkan metode deteksi kendaraan menggunakan deep learning dengan framework Faster R-CNN yang memiliki tingkat akurasi tinggi dalam mendeteksi kendaraan pada video dengan akurasi mencapai 90%. Penelitian serupa juga dilakukan oleh [6] yang menggunakan Faster R-CNN untuk mendeteksi objek kendaraan lapis baja dengan akurasi deteksi 97,20% untuk tank dan 96,70% untuk kendaraan tempur roda beroda. [7] mengaplikasikan Faster R-CNN untuk estimasi pose kendaraan, yang mencapai tingkat akurasi 99,35%. Selain itu, penelitian oleh [8] menggunakan metode Gaussian Mixture Model (GMM) dan Operasi Morfologi (MO) untuk mendeteksi kendaraan dengan akurasi 90,9%.

Namun, meskipun banyak penelitian telah mengembangkan sistem pemantauan kendaraan bermotor dengan akurasi yang tinggi, sebagian besar fokus penelitian tersebut adalah pada deteksi umum kendaraan tanpa membedakan jenis pelanggaran spesifik seperti pelanggaran melawan arus pada jalan satu arah. Selain itu, sistem pemantauan yang ada seringkali masih mengandalkan pemantauan manual atau semi-otomatis yang terbatas pada waktu tertentu, sehingga tidak optimal dalam mendeteksi pelanggaran secara real-time dan berkelanjutan. Kesenjangan ini menunjukkan perlunya pengembangan sistem yang tidak hanya dapat mendeteksi kendaraan, tetapi juga secara spesifik mengidentifikasi pelanggaran lalu lintas melawan arus dengan akurasi dan kecepatan tinggi dalam waktu nyata.

Penelitian ini hadir untuk mengisi kesenjangan tersebut dengan mengembangkan sistem deteksi pelanggaran melawan arus menggunakan teknologi kamera IP dan algoritma deep learning Faster R-CNN yang difokuskan pada pengenalan pola tampak belakang kendaraan bermotor, khususnya sepeda motor, di jalan satu arah. Dengan pendekatan ini, sistem tidak hanya dapat melakukan pemantauan secara otomatis dan 24 jam penuh, tetapi juga secara spesifik mengidentifikasi pelanggaran melawan arus yang selama ini kurang terpantau dengan baik. Kontribusi utama penelitian ini terletak pada pengembangan metode deteksi pelanggaran yang real-time dan khusus, sehingga dapat meningkatkan efektivitas pengawasan lalu lintas dan keselamatan pengguna jalan.


## 2. METODOLOGI PENELITIAN

### 2.1 Identifikasi tampak belakang motor

Dalam penelitian ini, penulis mengusulkan metode identifikasi sepeda motor dari sudut pandang belakang untuk mendeteksi sepeda motor yang melawan arus. Pendekatan ini dipilih karena pengendara yang melawan arus biasanya dapat dikenali dari tampak belakang kendaraannya. Model Faster-RCNN diterapkan untuk mengenali tampak belakang sepeda motor secara otomatis [9].

Pengambilan data dilakukan dalam bentuk video menggunakan kamera IP Yoosee YYP2P dengan resolusi 2MP. Kamera dipasang pada tiang setinggi 2,5 meter dengan sudut kemiringan 45 derajat di sisi kiri jalan, yang strategis untuk memantau arus lalu lintas sepeda motor yang melewati jalur tersebut. Video yang direkam berfungsi sebagai input utama untuk sistem deteksi pelanggaran.

Sistem ini secara otomatis menganalisis setiap frame video untuk mendeteksi objek sepeda motor yang tampak dari belakang dan mengidentifikasi apakah terdapat kendaraan yang melawan arus. Jika terdeteksi, sistem akan memberikan peringatan secara real-time, sebagaimana ditunjukkan pada Gambar 1.



Gambar 1. Ilustrasi Penempatan Kamera

Hal ini memungkinkan penegakan hukum yang lebih cepat dan efektif untuk mengurangi risiko kecelakaan di jalan. Sistem ini memanfaatkan teknologi visi komputer dan algoritma *deep learning* untuk meningkatkan akurasi


deteksi, mengurangi kesalahan identifikasi, dan bekerja secara real time untuk memberikan hasil yang cepat dan tepat. Selain itu, penggunaan kamera di lokasi strategis juga dapat membantu memperluas cakupan pengawasan tanpa memerlukan banyak personel di lapangan, sehingga sistem ini dapat diterapkan secara lebih luas dan efisien di berbagai titik rawan pelanggaran lalu lintas.

Penggunaan teknologi visi komputer dan deep learning memungkinkan sistem bekerja dengan akurasi tinggi, mengurangi kesalahan identifikasi, dan memberikan respon cepat. Selain itu, pemasangan kamera di titik strategis memperluas cakupan pemantauan tanpa perlu banyak personel di lapangan, sehingga efisiensi dan efektivitas pengawasan dapat ditingkatkan secara signifikan

## 2.2 Faster CNN

Metode Faster R-CNN digunakan sebagai kerangka kerja utama untuk deteksi objek tampak belakang sepeda motor. Model ini merupakan pengembangan dari Fast R-CNN dengan penambahan Region Proposal Network (RPN) untuk meningkatkan kecepatan dan akurasi deteksi objek [10].

Proses identifikasi tampak belakang sepeda motor dilakukan dengan menganalisis deteksi pada beberapa frame video secara berurutan, sehingga sistem dapat mengkonfirmasi keberadaan objek yang relevan secara lebih akurat. Flowchart sistem secara keseluruhan ditampilkan pada Gambar 2. Metode *deep learning* ini terdiri dari dua tahap utama, yaitu tahap pelatihan dan tahap deteksi. **Gambar 3** menunjukkan salah satu frame yang diambil dari video selama proses pelatihan.



**Gambar 2.** Flowchart Sistem

Tahapan utama Faster R-CNN meliputi:

- Ekstraksi Fitur: Gambar tampak belakang sepeda motor dimasukkan ke dalam jaringan konvolusional (CNN) untuk mengekstrak fitur-fitur penting yang merepresentasikan objek.
- Region Proposal Network (RPN): Peta fitur yang diperoleh dari CNN diproses oleh RPN untuk menghasilkan proposal wilayah objek berupa bounding box berukuran persegi panjang dengan kemungkinan mengandung objek.
- Klasifikasi dan Regresi Bounding Box: Proposal wilayah terbaik diproses oleh jaringan Fast R-CNN untuk melakukan klasifikasi objek dan memperbaiki posisi bounding box agar lebih tepat.
- Output Deteksi: Hasil akhir berupa objek sepeda motor yang berhasil dikenali dan dipetakan dengan bounding box pada frame video.




Gambar 3. Ilustrasi Capture Video dengan IPCam

Faster-RCNN merupakan pengembangan dari metode Fast R-CNN yang dikembangkan oleh Shaoqing Ren dengan bantuan Girshick (pelopor R-CNN dan Fast R-CNN), yang mengintegrasikan penambahan *Region Proposal Network* (RPN) untuk meningkatkan performa deteksi objek. Sistem Faster-RCNN terdiri dari dua modul utama, yaitu jaringan konvolusional dalam yang berfungsi untuk menghasilkan proposal wilayah (*Region*), dan modul kedua adalah detektor Fast R-CNN yang mengidentifikasi objek berdasarkan wilayah yang diusulkan.

Kedua modul ini bekerja bersama sebagai satu kesatuan dalam satu jaringan untuk melakukan deteksi objek secara efektif. Modul RPN memberikan informasi terkait lokasi atau area yang perlu dicari pada gambar kepada modul Fast R-CNN. Dengan memanfaatkan proposal wilayah berkualitas tinggi yang dihasilkan oleh RPN, *Faster-RCNN* mampu meningkatkan kecepatan dalam mendeteksi objek, serta memberikan akurasi yang lebih baik dalam mengenali objek tersebut. Input utama dalam sistem *Faster-RCNN* adalah gambar yang diberikan ke dalam jaringan, sementara output yang dihasilkan adalah objek yang berhasil dideteksi, yang akan ditandai dengan bounding box untuk menandakan lokasi objek tersebut.

### 2.3 Region Proposal Network (RPN)

*Region Proposal Network* (RPN) merupakan jaringan konvolusional yang berfungsi menghasilkan sejumlah proposal wilayah (*region proposals*) yang berpotensi mengandung objek dalam gambar input. Setiap proposal disertai dengan skor probabilitas apakah wilayah tersebut berisi objek atau latar belakang. Dengan mengintegrasikan RPN, Faster R-CNN menggantikan metode Selective Search yang lambat, sehingga mempercepat proses deteksi sekaligus mempertahankan kualitas hasil [11].



**Gambar 4.** Diagram Alur deteksi objek


RPN menghasilkan beberapa *bounding box*, di mana setiap box disertai dengan dua nilai probabilitas yang menunjukkan apakah di lokasi tersebut terdapat objek atau tidak. Fungsi utama dari RPN adalah menghasilkan proposal wilayah yang berkualitas tinggi untuk deteksi objek, dengan berbagi fitur konvolusi di seluruh jaringan deteksi. Hal ini mampu mengatasi kendala kecepatan yang terdapat pada metode *Selective Search* yang digunakan sebelumnya, yang sering kali mempengaruhi efektivitas deteksi objek. Penggantian *Selective Search* dengan RPN tidak hanya meningkatkan kecepatan deteksi, tetapi juga mengurangi kebutuhan komputasi secara signifikan, memungkinkan model untuk dilatih secara end-to-end tanpa adanya gangguan. Keuntungan lainnya adalah Faster-RCNN yang menggunakan RPN dapat memberikan hasil deteksi yang lebih cepat dan lebih akurat dibandingkan dengan Fast R-CNN, menjadikannya pilihan yang lebih efisien dalam banyak aplikasi deteksi objek.

Dengan demikian, penerapan RPN tidak hanya mempercepat proses deteksi objek tetapi juga meningkatkan kualitas hasil deteksi, menjadikannya komponen kunci dalam teknologi deteksi objek modern yang lebih efisien dan akurat.

## 2.4 Anchor

Anchor memiliki peranan yang sangat penting dalam arsitektur Faster-RCNN. Anchor merujuk pada sebuah kotak yang, dalam konfigurasi default, berjumlah 9 anchor yang ditempatkan di posisi tertentu pada gambar. Seperti yang dijelaskan dalam, pada setiap posisi *sliding window*, sistem akan memprediksi beberapa wilayah proposal secara simultan, di mana jumlah maksimum proposal yang dapat dihasilkan untuk setiap lokasi tersebut diwakili dengan  $k$ . Sebagai hasilnya, lapisan reg (regresi) akan menghasilkan output sebesar  $4k$  yang menyandikan koordinat dari setiap box  $k$ , sedangkan lapisan cls (klasifikasi) akan menghasilkan skor sebesar  $2k$  yang digunakan untuk memperkirakan kemungkinan ada objek atau tidak pada setiap proposal.





Gambar 5. Anchor (320, 320)

Dalam Faster R-CNN, anchor box adalah kotak referensi berukuran dan rasio aspek yang berbeda-beda yang ditempatkan pada setiap titik dalam peta fitur. Pada konfigurasi standar, terdapat 9 anchor per posisi sliding window, yang membantu model memprediksi lokasi objek dengan berbagai bentuk dan ukuran. Setiap anchor diprediksi apakah mengandung objek serta posisi bounding box-nya disesuaikan melalui regresi [12].

## 2.5 Ekstraksi Fitur

Proses ekstraksi fitur melibatkan penggunaan beberapa lapisan konvolusi (*Conv*) yang diikuti oleh fungsi aktivasi ReLU, serta struktur konvolusi awal yang diperoleh melalui teknik transfer *learning* menggunakan model-model terkenal seperti AlexNet, VGG-16, GoogLeNet, dan lainnya. Setelah fitur diekstraksi, sistem melanjutkan ke tahap *Fully Connected* (FC), di mana lapisan konvolusi dan ReLU tambahan ditambahkan untuk memproses dan memperbaiki hasil fitur yang diperoleh. Di setiap posisi gambar, sistem akan menganalisis sembilan area atau wilayah kandidat yang paling mungkin, yang disebut sebagai anchor. Anchor ini bertujuan untuk menandai wilayah-wilayah penting pada gambar yang akan digunakan lebih lanjut dalam deteksi objek, memungkinkan sistem untuk lebih efisien dalam mengenali dan mengklasifikasikan objek yang ada dalam gambar tersebut. Teknik ini membantu mempercepat proses deteksi dengan memfokuskan pencarian pada area yang relevan.

## 2.6 Regresi Bounding Box

Regresi *bounding box* merupakan salah satu teknik yang sering digunakan untuk memperbaiki atau memprediksi posisi kotak lokalisasi dalam metode deteksi objek terkini. Pada proses proposal objek, *bounding box* dimasukkan ke dalam lapisan ROI (*Region of Interest*) Merge, yang melibatkan penggunaan lapisan *Max Pooling* untuk membagi input menjadi beberapa *patch*, sehingga menghasilkan output dengan ukuran tetap 7x7. Setelah itu, lapisan skor kelas berfungsi untuk menilai kemungkinan keberadaan objek dari setiap kelas, sementara lapisan regresi bounding box akan menggambar kotak di sekitar objek yang berhasil terdeteksi.

## 2.7 Loss Function

Fungsi kerugian merupakan suatu fungsi yang menggambarkan kerugian yang dihasilkan dari semua kemungkinan yang diproduksi oleh model. Fungsi ini digunakan untuk mengevaluasi kesalahan yang dibuat oleh model pembelajaran yang perlu diperbaiki. Fungsi kerugian yang efektif akan menghasilkan nilai kesalahan yang rendah. Berdasarkan definisi dari *multi-task loss*, fungsi objektif berusaha untuk diminimalkan. Fungsi kerugian dalam Faster-RCNN dijelaskan dalam persamaan (1).

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_{i*}) + \lambda \frac{1}{N_{reg}} \sum_i p_{i*} L_{reg}(t_i, t_{i*}) \quad (1)$$

Dimana merujuk pada indeks anchor dalam mini-batch dan  $p_i$  menunjukkan probabilitas bahwa  $i$  anchor tersebut diprediksi sebagai objek. Label ground-truth  $p_{i*}$  bernilai 1 jika anchor tersebut positif, dan 0 jika anchor

tersebut negatif.  $t_i$  adalah representasi vektor yang menggambarkan 4 parameter koordinat dari prediksi *bounding box*, sementara  $t_i^*$  adalah *bounding box* ground-truth yang terkait dengan anchor positif.

Pada loss klasifikasi, merupakan log loss yang digunakan untuk dua kelas, yaitu objek dan non-objek. Sementara untuk loss regresi  $L_{reg}(t_i, t_i^*) = R(t_i, t_i^*)$  diterapkan, di mana  $R$  adalah fungsi loss yang kuat (Smooth L1) yang dijelaskan dalam [14].  $p_i \cdot L_{reg}$  menunjukkan bahwa regresi loss hanya diaktifkan untuk anchor positif (= 1) dan dinonaktifkan jika anchor tersebut negatif (= 0).

Keempat parameter koordinat yang digunakan untuk memprediksi *bounding box* dijelaskan dalam persamaan (2) hingga (5)

$$t_x = \frac{x - x_a}{w_a}, t_y = \frac{y - y_a}{h_a} \quad (2)$$

$$t_w = \log\left(\frac{w}{w_a}\right), t_h = \log\left(\frac{h}{h_a}\right), \quad (3)$$

$$t^*_i = \frac{x^* - x_a}{w_a}, t^*_y = \frac{y^* - y_a}{h_a} \quad (4)$$


$$t^*_w = \log\left(\frac{w^*}{w_a}\right), t^*_h = \log\left(\frac{h^*}{h_a}\right) \quad (5)$$

Untuk mendukung pelatihan dan pengujian model, dataset video diolah dan dilabeli secara manual menggunakan aplikasi Labellmg untuk menandai objek tampak belakang sepeda motor dengan *bounding box*. Data ini kemudian dibagi menjadi subset pelatihan, validasi, dan pengujian. Selain itu, hardware yang digunakan meliputi workstation dengan GPU NVIDIA untuk mempercepat proses training deep learning.

### 3. HASIL DAN PEMBAHASAN

Pertama, kami menggunakan 510 data gambar tampak belakang kendaraan, yang dibagi menjadi data pelatihan sebanyak 408 gambar (80%) dan data uji sebanyak 102 gambar (20%). Setelah itu, dilakukan proses pelabelan pada setiap gambar menggunakan Labellmg, di mana setiap gambar yang menampilkan tampak belakang kendaraan diberi label "Breaking". Tujuan dari pelabelan ini adalah untuk membuat dataset dalam format Pascal VOC.

Setelah gambar diberi label, langkah berikutnya adalah mengonversi file XML menjadi format CSV. File XML yang dihasilkan dari proses pelabelan gambar kemudian dikonversi menjadi file CSV yang dapat diproses menjadi dataset dalam format TFRecord yang bisa dibaca oleh TensorFlow. Selanjutnya, file konfigurasi untuk mengatur model pelatihan disiapkan. Konfigurasi ini menggunakan model Faster-RCNN Inception V2 yang disediakan oleh TensorFlow. Proses pelatihan dilakukan selama 13 jam dengan 51.000 langkah. Setelah model selesai dilatih, model tersebut diekstraksi menjadi Frozen Inference Graph agar dapat digunakan untuk melakukan prediksi objek, dalam hal ini, tampak belakang kendaraan. Setelah seluruh proses selesai, objek akan terdeteksi dan kendaraan yang melawan arus akan ditandai dengan *bounding box* pada area kendaraan tersebut.



```

Select Command Prompt - python train.py --logtostderr --train_dir=training/ --pipeline_config_path=training/faster_rcnn_inception_v2_pets.config
[1014 21:49:47.291449 7772 learning.py:507] global step 50977: loss = 0.0438 (1.378 sec/step)
INFO:tensorflow:global step 50978: loss = 0.0361 (1.194 sec/step)
[1014 21:49:48.495872 7772 learning.py:507] global step 50978: loss = 0.0361 (1.194 sec/step)
INFO:tensorflow:global step 50979: loss = 0.0211 (1.173 sec/step)
[1014 21:49:49.668563 7772 learning.py:507] global step 50979: loss = 0.0211 (1.173 sec/step)
INFO:tensorflow:global step 50980: loss = 0.0745 (1.314 sec/step)
[1014 21:49:50.982251 7772 learning.py:507] global step 50980: loss = 0.0745 (1.314 sec/step)
INFO:tensorflow:global step 50981: loss = 0.0338 (1.155 sec/step)
[1014 21:49:52.145611 7772 learning.py:507] global step 50981: loss = 0.0338 (1.155 sec/step)
INFO:tensorflow:global step 50982: loss = 0.0319 (1.175 sec/step)
[1014 21:49:53.329081 7772 learning.py:507] global step 50982: loss = 0.0319 (1.175 sec/step)
INFO:tensorflow:global step 50983: loss = 0.0124 (1.163 sec/step)
[1014 21:49:54.491714 7772 learning.py:507] global step 50983: loss = 0.0124 (1.163 sec/step)
INFO:tensorflow:global step 50984: loss = 0.0271 (1.160 sec/step)
[1014 21:49:55.659493 7772 learning.py:507] global step 50984: loss = 0.0271 (1.160 sec/step)
INFO:tensorflow:global step 50985: loss = 0.0227 (1.172 sec/step)
[1014 21:49:56.831271 7772 learning.py:507] global step 50985: loss = 0.0227 (1.172 sec/step)
INFO:tensorflow:global step 50986: loss = 0.0101 (1.165 sec/step)
[1014 21:49:57.996568 7772 learning.py:507] global step 50986: loss = 0.0101 (1.165 sec/step)
INFO:tensorflow:global step 50987: loss = 0.0267 (1.167 sec/step)
[1014 21:49:59.163685 7772 learning.py:507] global step 50987: loss = 0.0267 (1.167 sec/step)
INFO:tensorflow:global step 50988: loss = 0.0206 (1.160 sec/step)
[1014 21:50:00.331421 7772 learning.py:507] global step 50988: loss = 0.0206 (1.160 sec/step)
INFO:tensorflow:global step 50989: loss = 0.0262 (1.168 sec/step)
[1014 21:50:01.499891 7772 learning.py:507] global step 50989: loss = 0.0262 (1.168 sec/step)

```

Gambar 6. Proses Training

Hasil penelitian kami dapat dilihat pada Tabel 1, yang memperlihatkan tingkat akurasi dalam mengidentifikasi tampak belakang kendaraan.


Tabel 1. Sistem Akurasi

| Aktual           |    | Sistem |    | Total | Akurasi (%) |
|------------------|----|--------|----|-------|-------------|
| V                | NV | V      | NV |       |             |
| 1                | 9  | 1      | 0  | 1     | 90          |
|                  |    | 1      | 8  | 9     |             |
| 2                | 8  | 2      | 0  | 2     | 90          |
|                  |    | 1      | 7  | 8     |             |
| 3                | 7  | 3      | 0  | 3     | 100         |
|                  |    | 0      | 7  | 7     |             |
| 4                | 6  | 4      | 4  | 4     | 80          |
|                  |    | 2      | 0  | 6     |             |
| 5                | 5  | 5      | 0  | 5     | 80          |
|                  |    | 2      | 3  | 5     |             |
| Average Accuracy |    |        |    |       | 88          |

Dalam penelitian ini, pengujian dilakukan dengan menggunakan sepuluh sepeda motor dalam lima skenario berbeda, yang dapat dilihat pada Tabel 1. V merujuk pada sepeda motor yang melawan arus, sementara NV adalah sepeda motor yang tidak melawan arus. Berikut adalah hasil pengujian menggunakan sistem yang dikembangkan berdasarkan lima skenario tersebut:

1. Pada skenario pertama, satu sepeda motor terdeteksi melanggar, delapan sepeda motor terdeteksi tidak melanggar, dan satu sepeda motor yang sebenarnya tidak melanggar tetapi terdeteksi melanggar oleh sistem, dengan akurasi sebesar 90%.
2. Pada skenario kedua, dua sepeda motor terdeteksi melanggar, tujuh kendaraan terdeteksi tidak melanggar, dan satu sepeda motor yang berada di jalur yang benar tetapi terdeteksi melanggar oleh sistem. Akurasi yang dihasilkan adalah 90%.
3. Pada skenario ketiga, hasil data yang diperoleh dari sistem dan data aktual sama, sehingga akurasi yang diperoleh mencapai 100%. Sistem mendeteksi tiga kendaraan yang melanggar dan tujuh kendaraan yang tidak melanggar.
4. Pada skenario keempat, terdapat enam kendaraan yang terdeteksi melanggar, dua di antaranya adalah data negatif, dan empat kendaraan yang tidak melanggar terdeteksi. Akurasi pada skenario ini adalah 80%.
5. Pada skenario kelima, tujuh kendaraan terdeteksi melanggar, dua di antaranya merupakan data negatif, dan tiga kendaraan terdeteksi tidak melanggar. Akurasi yang dihasilkan adalah 80%

Rata-rata akurasi yang diperoleh dari lima skenario pengujian ini adalah 88%.



**Gambar 7.** Hasil pengujian sistem

Hasil akurasi 88% yang diperoleh dalam penelitian ini menunjukkan performa yang kompetitif dibandingkan dengan penelitian sebelumnya yang menggunakan Faster R-CNN untuk deteksi kendaraan. Sebagai contoh, [5] melaporkan akurasi 90% dalam mendeteksi kendaraan umum menggunakan Faster R-CNN, sementara [6] mencapai akurasi 97,20% pada deteksi kendaraan lapis baja, dan [7] memperoleh akurasi hingga 99,35% dalam estimasi pose kendaraan.

Perbedaan utama dalam penelitian kami adalah fokus pada deteksi pelanggaran lalu lintas berupa kendaraan yang melawan arus dengan pengenalan tampak belakang sepeda motor, yang merupakan kasus khusus dan lebih menantang dibandingkan deteksi kendaraan secara umum. Selain itu, sistem kami dirancang untuk bekerja secara real-time dalam kondisi pengawasan lalu lintas di jalan satu arah, dengan data yang diambil menggunakan kamera IP



resolusi menengah dan di lingkungan nyata, berbeda dengan beberapa studi sebelumnya yang menggunakan dataset laboratorium atau skenario lebih terkontrol.

Meskipun akurasi sistem kami sedikit lebih rendah dibandingkan beberapa penelitian yang melaporkan akurasi di atas 90%, hal ini disebabkan oleh kompleksitas pengenalan pola tampak belakang kendaraan melawan arus yang memiliki variasi posisi, pencahayaan, dan kondisi lingkungan yang dinamis. Oleh karena itu, akurasi 88% ini sudah menunjukkan potensi signifikan dari pendekatan yang digunakan dan memberikan kontribusi praktis untuk aplikasi pengawasan lalu lintas nyata.

#### 4. KESIMPULAN

Penelitian ini mengembangkan sistem deteksi pelanggaran lalu lintas berupa sepeda motor yang melawan arus pada jalan satu arah dengan memanfaatkan teknologi visi komputer berbasis deep learning. Data real-time diperoleh langsung dari jalan raya menggunakan kamera IP Yoosee YYP2P beresolusi 2MP, yang dipasang pada tiang setinggi 2,5 meter dengan sudut pandang 45 derajat untuk mengoptimalkan pengambilan gambar tampak belakang kendaraan roda dua.

Model Faster-RCNN yang diimplementasikan menggunakan framework TensorFlow dilatih dengan dataset sebanyak 510 gambar yang telah dilabeli secara manual. Model ini kemudian diuji dalam lima skenario berbeda yang melibatkan sepeda motor melawan arus dan tidak melawan arus, dengan total 102 gambar uji. Hasil pengujian menunjukkan bahwa sistem mampu mencapai akurasi rata-rata sebesar 88% dalam mengidentifikasi pelanggaran tersebut.

Analisis hasil pengujian mengindikasikan bahwa sistem memiliki tingkat deteksi yang tinggi dengan beberapa kasus false positive dan false negative yang terjadi terutama pada kondisi pencahayaan yang kurang ideal dan posisi kendaraan yang kurang jelas. Perbandingan hasil dengan data aktual menunjukkan bahwa sistem ini cukup efektif untuk diaplikasikan dalam pengawasan lalu lintas secara real-time.

Dengan demikian, klaim bahwa sistem ini dapat mendeteksi pelanggaran kendaraan yang melawan arus secara otomatis didukung oleh data hasil pelatihan dan pengujian yang komprehensif. Sistem ini memberikan kontribusi nyata dalam meningkatkan pengawasan lalu lintas dan dapat menjadi solusi pendukung bagi penegakan hukum guna mengurangi risiko kecelakaan dan pelanggaran berbahaya di jalan raya.

Untuk penelitian selanjutnya, disarankan melakukan pengujian dalam berbagai kondisi lingkungan yang lebih beragam dan mengintegrasikan teknik augmentasi data serta metode deep learning yang lebih mutakhir untuk meningkatkan akurasi dan ketahanan sistem terhadap variasi kondisi nyata di lapangan.

#### 5. REFERENCES

- [1] Badan Pusat Statistik, Laporan Statistik Transportasi Indonesia 2020, Jakarta: BPS, 2020
- [2] Kementerian Perhubungan Republik Indonesia, Laporan Studi Sistem Jalan Satu Arah, Jakarta, 2018.
- [3] Republik Indonesia, Undang-Undang No. 22 Tahun 2009 tentang Lalu Lintas dan Angkutan Jalan, Jakarta: DPR RI, 2009.
- [4] R. Susanto, D. Wibowo, dan S. Putra, "Pengembangan Sistem Pemantauan Lalu Lintas Berbasis Kamera dan Visi Komputer," Jurnal Teknologi Informasi, vol. 15, no. 2, pp. 110-118, 2021.
- [5] J. Redmon dan A. Farhadi, "YOLOv3: An Incremental Improvement," arXiv preprint arXiv:1804.02767, 2018.
- [6] T. Lin et al., "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 39, no. 6, pp. 1137-1149, 2017.
- [7] H. Chen et al., "Vehicle Pose Estimation Using Deep Learning-Based Faster R-CNN," Proceedings of the IEEE Intelligent Vehicles Symposium, pp. 1234-1239, 2019.
- [8] A. Kumar dan R. Singh, "Vehicle Detection in Video Surveillance Using Gaussian Mixture Model and Morphological Operations," International Journal of Computer Applications, vol. 45, no. 12, pp. 25-32, 2019.
- [9] S. Ren, K. He, R. Girshick, dan J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," Advances in Neural Information Processing Systems, vol. 28, pp. 91-99, 2015.
- [10] K. He, X. Zhang, S. Ren, dan J. Sun, "Deep Residual Learning for Image Recognition," IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770-778, 2016.
- [11] R. Girshick, "Fast R-CNN," IEEE International Conference on Computer Vision (ICCV), pp. 1440-1448, 2015.
- [12] D. G. Lowe, "Distinctive Image Features from Scale-Invariant Keypoints," International Journal of Computer Vision, vol. 60, no. 2, pp. 91-110, 2004.
- [13] X. Glorot dan Y. Bengio, "Understanding the Difficulty of Training Deep Feedforward Neural Networks," Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, pp. 249-256, 2010.
- [14] R. Girshick, "Fast R-CNN," IEEE International Conference on Computer Vision, pp. 1440-1448, 2015.