

# ANALISI PERFORMANSI DETEKSI PELANGGARAN STOP MENGGUNAKAN FASTER R-CNN

## PERFORMANCE ANALYSIS STOP VIOLATION DETECTION USING FASTER R-CNN

Bayu Arif Budiman<sup>1</sup>, Iwan Iwut Tritoasmoro<sup>2</sup>, Rissa Rahmanias<sup>3</sup>

<sup>1,3</sup>Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom

<sup>1</sup>bayuarifbudiman@student.telkomuniversity.ac.id, <sup>2</sup>iwan.tritoasmoro@gmail.com,

<sup>3</sup>saniarahmani@telkomuniversity.ac.id

### Abstrak

Kemacetan adalah permasalahan yang sering terjadi di beberapa kota besar di Indonesia. Kemacetan itu sendiri terjadi terdiri dari beberapa faktor seperti banyaknya jumlah kendaraan yang melintas, dan banyaknya kendaraan yang melakukan stop liar dipinggir jalan. Untuk mengatasi kemacetan yang marak terjadi, diperlukan suatu sistem yang dapat mengidentifikasi kendaraan yang melanggar marka jalan khususnya marka dilarang stop. Pada Tugas Akhir ini menggunakan metode *Convolutional Neural Network* yang dimana *Convolutional Neural Network* adalah sebuah metode yang dilakukan untuk mendeteksi citra dan *Region of Interest* untuk mengurangi area deteksi. Performansi pada penelitian ini dianalisis melalui parameter-parameter, seperti akurasi, *Frame per Second*, dan waktu komputasi. Pada penelitian ini memiliki akurasi rata-rata sebesar 80% ketika diuji pada objek tampak depan, 100% pada objek tampak belakang, dan tampak samping. Sedangkan untuk waktu komputasi sistem memiliki waktu komputasi selama 30 – 33 detik pada *device* pertama dan 4 – 8 detik pada *device* kedua, dan memiliki nilai *Frame per Second* sebesar 1.5 pada *device* pertama dan 7.5 pada *device* kedua.

**Kata kunci :** *Convolutional Neural Network, Kendaraan, Region of Interest*

### Abstract

Congestion is a problem that often occurs in several big cities in Indonesia. The traffic jam itself consists of several factors such as the large number of vehicles that pass, and the number of vehicles that park illegally alongside a road. To overcome the congestion that is rife, we need a system that can identify vehicles that violate road markings especially those prohibited from parking. In this final project uses the Convolutional Neural Network method where Convolutional Neural Network is a method used to detect images and regions of interest to reduce the detection area. Performance in this study was analyzed through parameters, such as accuracy, frames per second, and computational time. In this study has an average accuracy of 80% when tested on front view objects, 100% on rear view objects, and side view. Whereas for computing time the system has a computing time of 30 – 33 seconds on the first device and 4 – 8 seconds on the second device, and has a Frame per Second value of 1.5 on the first device and 7.5 on the second device

**Keywords:** *Convolutional Neural Network, Vehicle, Region of Interest*

### 1. Pendahuluan

Kemacetan adalah masalah yang sangat sulit diatasi di beberapa kota besar yang ada di Indonesia. Kemacetan itu sendiri memiliki banyak faktor, seperti banyaknya jumlah kendaraan di jalan, dan banyaknya kendaraan yang melakukan stop liar dipinggir jalan. Banyak solusi yang digunakan oleh pihak terkait untuk menertibkan para pengguna jalan yang melanggar rambu lalu lintas, yaitu dengan menggunakan teknologi *Object Detection* yang bertujuan untuk mengidentifikasi hingga mengetahui apa yang dilanggar oleh pengendara tersebut.

Pada penelitian sebelumnya yang dilakukan oleh Saifa Kanthasak, Nattha Jindapetch, Pakpoom Hoyingchaeron, Kanadit Chetpattananondh, Masami Ikura, dan Surachate Chumpol [1]. Namun pada penelitian tersebut tidak adanya pembahasan bahwa kendaraan tersebut melakukan pelanggaran stop, yang hanya berfokus mendeteksi kendaraan yang dapat dideteksi didalam ROI (*Region Of Interest*) [1] yang dimana kendaraan tersebut tidak bisa terdeteksi ketika kendaraan tersebut berhenti, dan pada penelitian tersebut tidak bisa mendeteksi jenis kendaraan yang melakukan pelanggaran maka dari itu pada penelitian ini menggunakan metode CNN untuk mendeteksi kendaraan [2].

Tujuan dari dibuatnya penelitian dan penyusunan tugas akhir ini adalah untuk merancang dan membuat sistem yang berfungsi untuk mengidentifikasi kendaraan yang dapat melakukan deteksi kendaraan yang

melakukan pelanggaran stop, dan untuk menghasilkan performa sistem yang optimal dengan menganalisis performansi pada sistem melalui parameter Akurasi, *Frame per Second*, dan Waktu Komputasi

Metode penelitian yang digunakan pada penyusunan tugas akhir ini dimulai dengan melakukan studi literatur, melakukan Perancangan, dan Simulasi dari model yang akan dibuat, lalu melakukan Analisis berdasarkan data yang didapatkan terhadap parameter-parameter yang ditentukan, dan menarik kesimpulan terhadap hasil analisis.

## 2. Dasar Teori /Material dan Metodologi/perancangan

### 2.1 Citra Digital

Gambar di dalam Pengolahan Citra Digital memiliki dua dimensi yaitu  $f(x,y)$ , dimana citra tersebut terdiri dari sepasang koordinat spasial. Dan Amplitudo dari pasangan koordinat dari citra adalah intensity of Gray Level pada citra [3].

### 2.2 Convolutional Neural Network

Convolutional Neural Network (CNN) adalah salah satu algoritma yang dirancang untuk mengolah data dalam bentuk dua dimensi. CNN digunakan untuk mengklasifikasi, yang mana terdapat data yang dilatih dengan tujuan dari metode ini adalah mengelompokkan suatu data ke data yang sebelumnya.

Lapisan-lapisan CNN terdiri dari neuron 3 dimensi (lebar, tinggi, kedalaman). Lebar dan tinggi merupakan ukuran lapisan sedangkan kedalaman mengacu pada jumlah lapisan. CNN memiliki lapisan yang masing-masing belajar untuk mendeteksi berbagai gambar. Pengolahan citra memiliki output dari masing-masing gambar yang diolah dan akan digunakan sebagai input ke lapisan berikutnya. Secara umum klasifikasi Convolutional Neural Network (CNN) dibagi menjadi dua yaitu:

1. Tahap ekstraksi fitur (feature extraction layer) gambar, letaknya berada pada awal arsitektur tersusun atas beberapa lapisan dan setiap lapisan tersusun dari neuron yang terhubung. Lapisan jenis pertama dalam ekstraksi fitur adalah convolutional layer dan lapisan kedua adalah pooling layer. Setiap lapisan memiliki fungsi aktivasi dengan posisinya yang bergantian antara jenis pertama dengan jenis kedua. Tahap ini menerima input gambar secara langsung dan memprosesnya hingga menghasilkan output berupa vektor untuk diolah pada lapisan berikutnya. Pada tahap ini terdapat fungsi aktivasi Rectified Linear Unit (ReLU) yang akan menghasilkan nilai nol apabila  $x < 0$  dan linier dengan kemiringan satu ketika  $x > 0$ .

2. Tahap klasifikasi (classification layer), tersusun atas beberapa lapisan dan setiap lapisan tersusun atas neuron yang terkoneksi secara penuh (fully connected) dengan lapisan lainnya. Tahap ini menerima input dari hasil keluaran lapisan ekstraksi fitur yang berupa convolusi dan pooling layer, dan gambar berupa vektor kemudian ditransformasikan dengan tambahan beberapa hidden layer. Hasil keluaran berupa akurasi kelas untuk klasifikasi. Pada lapisan ini terdapat proses merubah matriks dua dimensi menjadi satu dimensi sebelum masuk ke lapisan \textit{fully connected layer}. Fungsi aktivasi yang digunakan di akhir dalam model CNN adalah fungsi aktivasi Softmax. Fungsi aktivasi Softmax digunakan untuk merubah hasil neural network menjadi probabilitas terhadap kelas yang di deteksi. Fungsi aktivasi Softmax memiliki rentang probabilitas output dari nol sampai sampai, dan jumlah semua probabilitasnya sama dengan satu dan dapat digunakan untuk multiple classification logistic regression model, dan merubah output dari fully connected layer menjadi probabilitas.

$$\begin{bmatrix} 2.0 \\ 0.8 \\ 0.3 \end{bmatrix} > \textit{Softmax} > \begin{bmatrix} 0.60 \\ 0.30 \\ 0.10 \end{bmatrix}$$

(2.1)

Dengan demikian CNN merupakan metode untuk mentransformasikan gambar dari nilai piksel pada gambar kedalam nilai terhadap kelas untuk klasifikasi. Dan setiap lapisan ada yang memiliki hyperparameter dan ada yang tidak memiliki parameter (bobot dan bias pada neuron).

### 2.3 Region of Interest

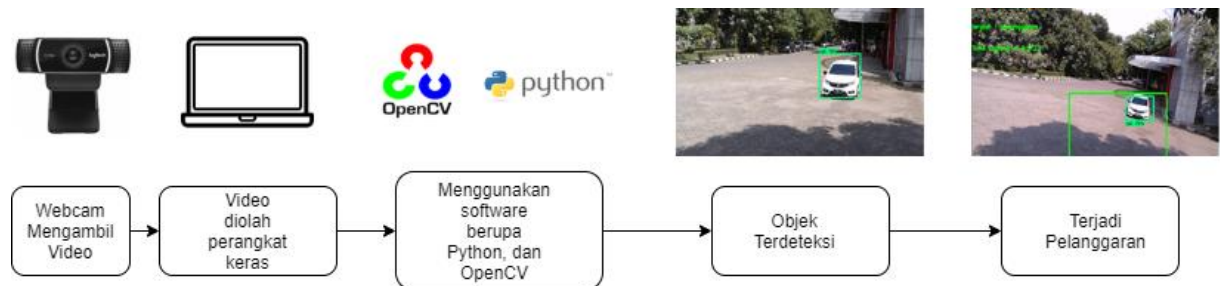
Region of Interest adalah salah satu solusi yang dibutuhkan pada pengolahan citra digital. Hasil yang didapatkan dengan menggunakan Region of Interest adalah dengan memperkecil area yang ditangkap, untuk mempermudah dalam pengambilan citra digital. Region of Interest pada penelitian ini bertujuan untuk mengurangi area deteksi pada video sehingga program dapat mengetahui objek yang akan dideteksi terkhusus hanya pada area yang ditentukan oleh Region of Interest, Seperti pada Gambar 2.5 adalah contoh penerapan Region of Interest pada citra yang digunakan untuk memperkecil area yang ingin digunakan [4].

## 3. Perancangan dan Simulasi

### 3.1. Desain Sistem

Desain Sistem yang akan diusulkan untuk mendeteksi kendaraan yang melakukan pelanggaran stop pada marka jalan dengan mengidentifikasi kendaraan tersebut melakukan pelanggaran stop atau tidak pada marka jalan tersebut. Pada Desain Sistem ini Webcam dihubungkan dengan Laptop yang berfungsi untuk melakukan

pengolahan citra digital menggunakan bahas pemrograman Python dan Library OpenCV. Pemodelan mengenai sistem yang akan diusulkan adalah:



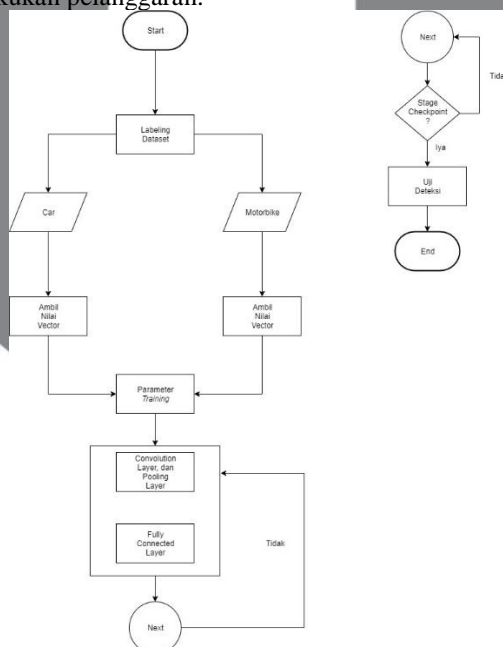
Gambar 3.1 Desain Sistem

### 3.2 Blok Diagram

Blok diagram yang dirancang untuk mendeteksi pelanggaran stop pada marka jalan yang dilakukan pada kendaraan membutuhkan training, suatu sistem dilatih dengan dataset yang sama dengan objek yang akan dideteksi yaitu dengan mengelompokkan dua jenis dataset yaitu mobil, dan motor.

Setelah mengelompokkan dataset akan dilakukan pada tahap training, tahap training sistem akan menggunakan model Faster R-CNN, Faster R-CNN adalah pengembangan dari model CNN (Convolutional Neural Network), yang dimana model ini dikembangkan untuk Object Detection yang diharapkan dapat mendeteksi kendaraan berupa mobil dan motor. Setelah tahap training sistem mengambil data citra yang akan dideteksi menggunakan webcam dengan format video tertentu, dan pada lokasi tertentu yang ditentukan.

Setelah mendapatkan video citra dari webcam sistem dapat melakukan deteksi objek tersebut, lalu dapat dianalisis parameter-parameter yang dibutuhkan seperti Akurasi, Waktu Komputasi, dan Frame Per Second (FPS). Setelah dapat mendeteksi objek tersebut sistem akan membedakan apakah kendaraan tersebut melanggar atau tidak dengan menggunakan timer pada area yang akan dideteksi, dan sistem diharapkan dapat mengambil gambar citra kendaraan yang melakukan pelanggaran.



Gambar 3.2 Blok Diagram


### 3.3 Diagram Alir

Diagram Alir pada sistem ini yaitu dimulai dengan mendapatkan citra yang didapatkan dari Webcam yang dimana data citra tersebut akan diolah menggunakan Laptop untuk mengolah citra tersebut. Ketika program

dijalankan maka webcam pada sistem sudah dapat melakukan fungsinya untuk mendeteksi kendaraan yang melakukan pelanggaran stop di marka jalan.

Ketika sistem tidak mendeteksi adanya pelanggaran yang terjadi sistem akan terus bekerja hingga mendapatkan adanya pelanggaran yang terjadi.

Ketika terjadi sebuah pelanggaran yang terdeteksi pada citra, sistem akan mendeteksi kendaraan yang melakukan pelanggaran pada lokasi tersebut sehingga dapat diketahui bahwa ada kendaraan yang melakukan pelanggaran di area tersebut.



Gambar 3.3 Diagram Alir

**4. Hasil Pengukuran dan Analisis**

**4.1 Pengujian Keakurasian**

Pengujian Keakurasian ini dilakukan untuk mengetahui seberapa akurasi sistem pada Tugas Akhir ini untuk mendeteksi objek yang ditujukan untuk kendaraan khususnya Mobil. Pada pengujian ini salah satu factor yang mempengaruhi sebuah sistem adalah jumlah Steps.

Steps adalah keadaan dimana terjadinya pembagian antara jumlah dataset dengan batch size untuk mendapatkan nilai stepsnya. Pada pengujian ini dengan mengganti nilai Steps pada program. Pengujian ini dilakukan dengan jumlah Steps sebesar 161, 254, 545, dan 2372. Dari nilai Steps tersebut dapat dilakukan pengujian terhadap jarak, dan posisi kendaraan.

**4.1.1 Pengujian Keakurasian Terhadap Objek Tampak Depan**

Pengujian Keakurasian pada Tampak Depan adalah pengujian yang dilakukan pada jarak 5 Meter, 10 Meter, 15 Meter, dan 20 Meter. Dengan jarak tersebut objek akan menghadap didepan objek dengan posisi Tampak Depan pada kamera dengan Steps seperti yang disebutkan. Berikut data akurasi rata-rata terhadap pengujian objek Tampak Depan.

**Tabel 4.1** Akurasi rata-rata pada pengujian Tampak Depan

Steps	Jumlah Deteksi	Jumlah Terdeteksi	Akurasi
161	5	1	20%
254	5	2	40%
545	5	2	40%
2372	5	4	80%

**4.1.2 Pengujian Keakurasian Terhadap Objek Tampak Belakang**

Pengujian Keakurasian pada Tampak Belakang adalah pengujian yang dilakukan pada jarak 5 Meter, 10 Meter, 15 Meter, dan 20 Meter. Dengan jarak tersebut objek akan menghadap didepan objek dengan posisi Tampak Belakang pada kamera dengan Steps seperti yang disebutkan. Berikut data akurasi rata-rata terhadap pengujian objek Tampak Belakang.

**Tabel 4.2** Akurasi rata-rata pada pengujian Tampak Belakang

Steps	Jumlah Deteksi	Jumlah Terdeteksi	Akurasi
161	4	3	80%
254	4	3	80%
545	4	3	80%
2372	4	4	100%

#### 4.1.3 Pengujian Keakurasian Terhadap Objek Tampak Samping

Pengujian Keakurasian pada Tampak Samping adalah pengujian yang dilakukan pada jarak 5 Meter, 10 Meter, 15 Meter, dan 20 Meter. Dengan jarak tersebut objek akan menghadap didepan objek dengan posisi Tampak Samping pada kamera dengan Steps seperti yang disebutkan. Berikut data akurasi rata-rata terhadap pengujian objek Tampak Samping.

**Tabel 4.3** Akurasi rata-rata pada pengujian Tampak Samping

Steps	Jumlah Deteksi	Jumlah Terdeteksi	Akurasi
161	4	3	80%
254	4	4	100%
545	4	4	100%
2372	4	4	100%

#### 4.2 Pengujian Waktu Komputasi Sistem

Pada pengujian dilakukan dengan membandingkan seberapa lama sistem dapat melakukan deteksi terhadap objek yang ingin dideteksi dengan jumlah Steps yang menjadi parameter.


**Tabel 4.4** Perbandingan Waktu Komputasi Sistem

Steps	Device	Waktu Komputasi
161	Lenovo 320S	29 Detik
254	Lenovo 320S	30 Detik
545	Lenovo 320S	31 Detik
2372	Lenovo 320S	33 Detik
161	Asus FX553	4 Detik
254	Asus FX553	5 Detik
545	Asus FX553	6 Detik
2371	Asus FX553	8 Detik

Dari Tabel dapat diketahui bahwa performa Hardware dan Jumlah Steps sangat mempengaruhi lamanya Waktu Komputasi yang dilakukan sistem untuk dapat mendeteksi sebuah Objek.

#### 4.3 Pengujian Kendaraan Yang Melakukan Pelanggaran Stop

Pengujian ini bertujuan untuk membedakan kendaraan yang melakukan pelanggaran stop atau tidak, dengan cara mengaktifkan timer pada area deteksi ketika kendaraan terdeteksi di area tersebut sehingga dapat membedakan kendaraan yang melakukan parkit atau tidak.



**Gambar 4.1** Tampilan Anaconda Prompt ketika tidak ada objek yang terdeteksi



**Gambar 4.2** Tampilan ketika ada objek yang terdeteksi

Pada **Gambar 4.2** dapat diketahui bahwa sistem mendeteksi adanya kendaraan yang melintas di area yang dibatasi sebagai area yang tidak boleh ditempati untuk stop, sistem akan mengetahui kendaraan tersebut melanggar ketika timer yang dilakukan oleh sistem sudah mencapai 30 detik, sehingga akan ada informasi pada tampilan pada Command Prompt adanya pelanggaran.

Pada **Gambar 4.3** dapat diketahui bahwa sistem mendeteksi adanya kendaraan yang melakukan pelanggaran stop dikarenakan berada di area tersebut selama lebih dari 30 detik, sehingga sistem ini berhasil mendeteksi adanya pelanggaran stop pada area yang dilarang stop. Tetapi pada sistem ini memiliki kekurangan yaitu sistem ini hanya bisa mendeteksi satu pelanggaran jika ada dua mobil yang berada di area tersebut sehingga hanya bisa mendeteksi satu kendaraan saja yang melakukan pelanggaran.



**Gambar 4.3** Tampilan ketika ada objek yang terdeteksi dan melakukan pelanggaran

Dari hasil uji diatas menunjukkan sistem bekerja dengan baik, selain itu pada sistem ini dilakukan perbandingan performa sistem terhadap kualitas Frame per Second pada dua perangkat keras yang berbeda, yang tertera pada **Tabel 4.5**

**Tabel 4.5** Perbandingan *Frame per Second*

<i>Hardware</i>	<i>Frame per Second</i>
Lenovo 320S	1.5 <i>Frame per Second</i>
Asus FX553	7.5 <i>Frame per Second</i>

Dari **Tabel 4.5** Dapat disimpulkan bahwa Spesifikasi perangkat keras (Hardware) berupa Perangkat Keras sangat mempengaruhi performa sistem, dan performa sistem optimal ketika menggunakan Perangkat Keras ASUS FX553.

## 5. Simpulan dan Saran

### 5.1 Simpulan

Setelah dilakukan perancangan, realisasi dan pengujian dalam mendeteksi objek, dapat disimpulkan bahwa:

1. Jarak terbaik adalah 5 Meter dengan rata-rata akurasi sebesar 100%.
2. Pada posisi kendaraan Tampak Depan memiliki Steps terbaik yaitu 2372 dengan akurasi rata-rata sebesar 80
3. Pada posisi kendaraan Tampak Belakang memiliki Steps terbaik yaitu 2372 dengan akurasi sebesar 100
4. Pada posisi kendaraan Tampak Samping memiliki Steps terbaik yaitu 245, 545, dan 2372 dengan akurasi sebesar 100
5. Pada pengujian sistem pelanggaran stop sistem dapat membedakan kendaraan yang melanggar stop, namun hanya bisa mendeteksi satu pelanggaran saja
6. Semakin tinggi Stepsnya maka akan semakin lama Waktu Komputasi yang dibutuhkan
7. Frame per Second diuji dengan membandingkan dengan dua Hardware dengan spesifikasi yang berbeda, dan semakin bagus Hardware yang digunakan semakin bagus juga nilai Frame per Second yang didapat

### 5.2 Saran

Berdasarkan penelitian Tugas Akhir ini, penulis menyarankan lebih banyak objek yang diujicoba untuk mengukur keakurasian pada sistem dengan jumlah lebih dari satu objek, diharapkan pada penelitian selanjutnya sistem dapat mendeteksi lebih dari satu pelanggaran, dan dalam pemilihan perangkat keras sangat diperhatikan karena mempengaruhi terhadap performa sistem yang dibuat.

### Daftar Pustaka:

- [1] S. Khantasak, "Parking Violation Detection System based on Video processing," *2018 IEEE 5th Int. Conf. Smart Instrumentation, Meas. Appl. ICSIMA 2018*, no. November, pp. 1–5, 2019.
- [2] S. Mane and S. Mangale, "Moving Object Detection and Tracking Using Convolutional Neural Networks," *Proc. 2nd Int. Conf. Intell. Comput. Control Syst. ICICCS 2018*, no. Icices, pp. 1809–1813, 2019.
- [3] R. C. Gonzalez, *Digital Image Processing*. 2002.
- [4] F. Yaghmaee and M. Ebadi, "ROI detection in images using annotation output," *Int. Image Process. Appl. Syst. Conf. IPAS 2014*, pp. 1–5, 2014.