

Sistem Deteksi Lampu Lalu Lintas Sebagai Asisten Pengemudi Menggunakan *Convolutional Neural Network*

Akhmad Hendriawan¹, Muhammad Iqbal Millyniawan Pradana², Ronny Susetyoko*³
^{1,2,3} Politeknik Elektronika Negeri Surabaya, Jalan Raya ITS Sukolilo, Surabaya, Indonesia
Email: hendri@pens.ac.id¹, iqbalpradanaaa@gmail.com², ronny@pens.ac.id³

Abstrack - Accident cases in Indonesia are increasing along with the increase in the number of motorized vehicles. From 2016 to 2017, speed limit violations increased by 96.20% and violations of road markings or signs also increased by 5.54%. Intelligent transportation system is one solution to reduce the number of accidents. Currently Driver Assistance Systems (DAS) are being developed in the automotive world. The purpose of this research is to design a watershed based on three input parameters for determining recommended actions, namely: 1) distance to the vehicle behind; 2) vehicle speed; and 3) traffic light status with recommendation action using fuzzy rule base. Lidar sensor for distance detection and GPS for monitoring vehicle speed. The YOLOv4 Algorithm method is used to detect traffic lights. The results of this study, the accuracy of sign color recognition is 92.831% with a detection speed of up to 8.94 FPS. The most stable reading distance is between 1 – 8-meters with a light intensity of 10 – 3200 lux and a tilt angle of up to 90 degrees. There is a drop in processing speed of up to 1.5 FPS during system integration. This DAS is effective enough to be applied to two-wheeled and four-wheeled motorized vehicles.

Keywords - Driver Asistant System, YOLOv4, GPS, Lidar, HSV color.

Intisari – Kasus kecelakaan di Indonesia meningkat seiring dengan kenaikan jumlah kendaraan bermotor. Dari tahun 2016 ke tahun 2017, pelanggaran batas kecepatan naik 96,20% dan pelanggaran marka jalan atau rambu-rambu juga naik 5,54%. *Intelligent transportation system* merupakan salah satu solusi untuk menekan angka kecelakaan. Saat ini *Driver Assistance Systems* (DAS) sedang dikembangkan di dunia otomotif. Tujuan penelitian ini adalah merancang DAS berdasarkan tiga parameter input untuk penentuan aksi rekomendasi yaitu: 1) jarak dengan kendaraan di belakang; 2) kecepatan kendaraan; dan 3) status lampu lalu lintas dengan aksi rekomendasi menggunakan *fuzzy rule base*. Sensor Lidar untuk pendeteksian jarak dan GPS untuk memantau kecepatan kendaraan. Metode Algoritma YOLOv4 digunakan untuk mendeteksi lampu lalu lintas. Hasil penelitian ini, akurasi pengenalan warna rambu sebesar 92,831% dengan kecepatan deteksi hingga 8,94 FPS. Jarak pembacaan yang paling stabil antara 1 – 8-meter dengan intensitas cahaya 10 – 3200 lux dan sudut kemiringan hingga 90 derajat. Ada penurunan kecepatan proses hingga 1,5 FPS saat integrasi sistem. DAS ini cukup efektif untuk diterapkan pada kendaraan bermotor roda dua maupun roda empat.

Kata Kunci - Driver Asistant System, YOLOv4, GPS, Lidar, warna HSV

I. PENDAHULUAN

Menurut data dari Badan Pusat Statistik (BPS), pertumbuhan jumlah kendaraan bermotor setiap tahunnya sebesar 10-15 %. Pertumbuhan jumlah kendaraan bermotor yang tinggi setiap tahunnya akan berdampak pada berbagai sektor. Dampak yang akan timbul seperti kemacetan, polusi udara, kecelakaan lalu lintas, dan pelanggaran lalu lintas [1]. Salah satu faktor penyebab kecelakaan lalu lintas dan pelanggaran lalu lintas adalah faktor manusia, dimana jenis pelanggaran yang mengalami kenaikan dari tahun 2016 ke tahun 2017 adalah pelanggaran batas

kecepatan dengan kenaikan 96,20% dan pelanggaran marka jalan/rambu-rambu dengan kenaikan 5,54% [2].

Untuk mengatasi masalah tersebut diperlukan suatu sistem yang dinamakan *intelligent transportation system*, yaitu sebuah sistem yang memadukan antara faktor manusia, jalan, dan kendaraan dengan memanfaatkan *state of the the art* teknologi informasi. Salah satu teknologi yang saat ini diterapkan dan sedang dikembangkan di dalam dunia otomotif yakni *Advanced Driver Assistance System (ADAS)* [3]. Perangkat ADAS adalah sistem canggih yang memahami lingkungan dan memberikan bantuan kepada pengemudi untuk kenyamanan atau keselamatannya. Pengembangan prototipe sistem pembacaan *variable message sign (VMS)* menggunakan *machine learning*. Asisten terdiri dari dua bagian, yaitu mengenali sinyal di jalan serta mengekstrak teks dan mengubahnya menjadi ucapan [4].

Perubahan besar telah terjadi dalam teknologi otomatisasi dan *machine vision technology* dalam beberapa tahun terakhir. Sementara itu, tuntutan keselamatan berkendara, efisiensi, dan kecerdasan juga meningkat secara signifikan. Semakin banyak perhatian diberikan pada penelitian tentang sistem bantuan pengemudi canggih (ADAS) sebagai salah satu fungsi terpenting dalam transportasi cerdas. Dibandingkan dengan transportasi tradisional, ADAS lebih unggul dalam memastikan keselamatan penumpang, mengoptimalkan perencanaan jalur, dan meningkatkan kontrol berkendara, terutama dalam mode *autopilot* [5].

Sistem tersebut dapat digunakan untuk mengenali rambu lampu lalu lintas di jalan raya, kemudian memberitahukan kepada pengemudi sebagai pengingat mengenai status keberadaan rambu lampu lalu lintas untuk mengurangi atau menambah batas kecepatan dari mobil, memberitahu pengemudi adanya peringatan adanya bahaya dibelakang kendaraan, dan lain sebagainya. Teknologi ini mempunyai kemampuan untuk meningkatkan sistem keamanan bagi pengemudi dan lingkungan disekitar kendaraan. Kendala utama pada sistem ini adalah sistem harus dapat mengenali kondisi kendaraan saat kendaraan sedang melaju dengan cepat, selain itu sistem harus tanggap dengan segala perubahan cuaca lingkungan sekitar dengan cepat dan tetap bekerja secara akurat terus menerus. Beberapa metode terkait pengenalan objek secara real time yang telah dikembangkan antara lain metode *Fast R-CNN*, *Faster R-CNN*, *Single Shot Detector*, *You Only Look Once (YOLO)*.

Tujuan penelitian ini adalah membuat piranti yang dapat bertindak sebagai asisten pengemudi dalam mengenali rambu lampu lalu lintas dan dapat membuat rekomendasi aksi yang harus dilakukan kepada pengemudi berdasarkan status lampu lalu lintas, kecepatan dan jarak kendaraan dengan objek yang berada dibelakang pada saat berlalu lintas. Untuk mendeteksi lampu lalu lintas menggunakan kamera, dimana output dari pengenalan tersebut dalam bentuk notifikasi suara. Metode pengenalan lampu lalu lintas yang digunakan yaitu YOLOv4, yang merupakan bagian dari metode Convolutional neural networks (CNN) yang banyak diaplikasikan pada data citra. Metode ini akan membagi gambar menjadi wilayah-wilayah kemudian memprediksi kotak pembatas dan probabilitas. Untuk setiap kotak wilayah pembatas ditimbang probabilitasnya untuk mengklasifikasikan sebagai objek atau bukan. Sedangkan deteksi lampu lalu lintas menggunakan segmentasi warna HSV. Sistem dilengkapi dengan kemampuan untuk mendeteksi jarak untuk mendeteksi adanya objek dibelakang kendaraan menggunakan sensor Lidar dan mendeteksi kecepatan kendaraan menggunakan GPS.

II. SIGNIFIKANSI STUDI

A. Studi Literatur

1. Driver Assistance System (DAS)

Pengenalan Rambu Lalu Lintas diperlukan untuk penelitian mengemudi mandiri (*independent driving*) dan mengemudi yang dibantu (*assisted driving*). Studi ini sangat penting untuk meningkatkan keselamatan lalu lintas jalan. Dalam beberapa tahun terakhir,

Convolutional Neural Networks (CNN) memiliki kinerja yang cukup baik dalam pemrosesan gambar, dengan akurasi yang lebih tinggi daripada pendekatan tradisional [6].

Sistem deteksi pengenalan rambu lalu lintas yang diterapkan dalam DAS dengan output berupa notifikasi suara jenis rambu bagi pengemudi. Sistem pendeteksian objek pada penelitian ini menggunakan Raspberry pi dengan metode *shape detection*. Pengujian dilakukan dengan mendeteksi warna, deteksi bentuk, kemudian deteksi jenis. Hasil yang didapatkan pada pendeteksian ini yaitu persentase pendeteksian rambu lalu lintas, sebesar 80.7% dan pengolahan gambar membutuhkan waktu selama 0.5 detik per gambar [7]. Penelitian [8] melakukan deteksi dan klasifikasi sinyal lalu lintas ditampilkan dalam tampilan jalan, yang menyajikan kerangka kerja baru menggunakan *visual attention model* untuk membuat deteksi lebih efisien, tanpa kehilangan akurasi.

Dalam penelitian [9] untuk pengukuran jarak antar kendaraan menggunakan sensor ultrasonik HCSR04 dan komunikasi bluetooth. Hasil yang didapatkan sistem dapat beroperasi hingga jarak 350 cm dengan error rata-rata 1.82 cm. Sedangkan dalam penelitian [10] untuk mengukur kecepatan aplikasi mobile GPS menggunakan metode Euclidian Distance. Hasil yang didapat yaitu pada sistem ini memerlukan perjalanan 50–80-meter dengan waktu 10 detik atau 5 – 8 m/detik dengan tingkat error 35%.

2. *You Only Look Once* (YOLO)

Deteksi dan pengenalan citra sinyal lalu lintas merupakan konten penting dalam sistem transportasi cerdas. Hal ini dapat diterapkan pada sistem bantuan pengemudi untuk secara efektif mengenali rambu-rambu lalu lintas di jalan, sehingga dapat mengurangi terjadinya kecelakaan lalu lintas. Pada saat yang sama juga memberikan dukungan teknis yang kuat untuk sistem mengemudi tanpa awak di masa depan. Penelitian menggunakan metode *deep learning*, dengan algoritma YOLOv3 dan YOLOv4 untuk mendeteksi dan mengenali citra sinyal lalu lintas di jalan. Hasil eksperimen menunjukkan bahwa hasil pengenalan jaringan YOLOv4 lebih baik daripada jaringan YOLOv3 [11]. Penelitian [12] melakukan kombinasi fitur-fitur pada kumpulan data yang besar untuk meningkatkan akurasi Convolutional Neural Network (CNN).

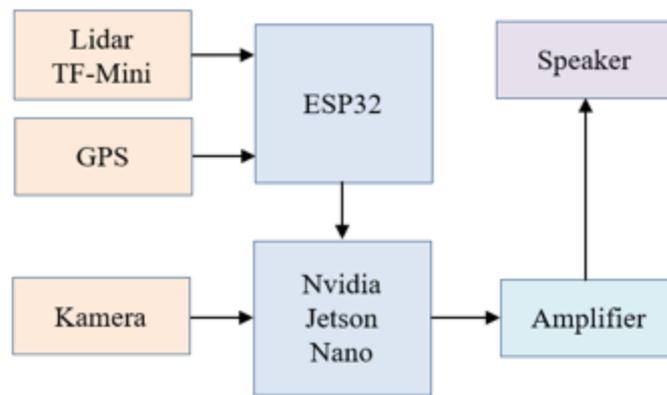
Untuk menghadapi masalah ketidakpekaan algoritma YOLOv4 terhadap objek kecil dan presisi deteksi yang rendah dalam deteksi dan pengenalan lampu lalu lintas, dilakukan optimalisasi fitur. Improvisasi algoritma YOLOv4 terbukti memiliki efektivitas tinggi dalam meningkatkan presisi deteksi dan pengenalan lampu lalu lintas. Dalam eksperimen pendeteksian, area di bawah nilai kurva *Precision-Recall* algoritma YOLOv4 yang telah diimprovisasi sebesar 97,58% dengan presisi rata-rata 82,15% [13].

3. *Segmentasi Warna HSV*

Metode segmentasi warna dengan warna HSV menghasilkan objek segmen citra berupa blob sehingga dapat dideteksi oleh komputer. Berdasarkan hasil pengujian, sampel warna akan menghasilkan nilai yang akan menjadi acuan rentang filter dalam proses segmentasi. Dalam prosesnya akan diketahui berapa banyak objek yang terdeteksi sesuai dengan warna yang ditentukan [14].

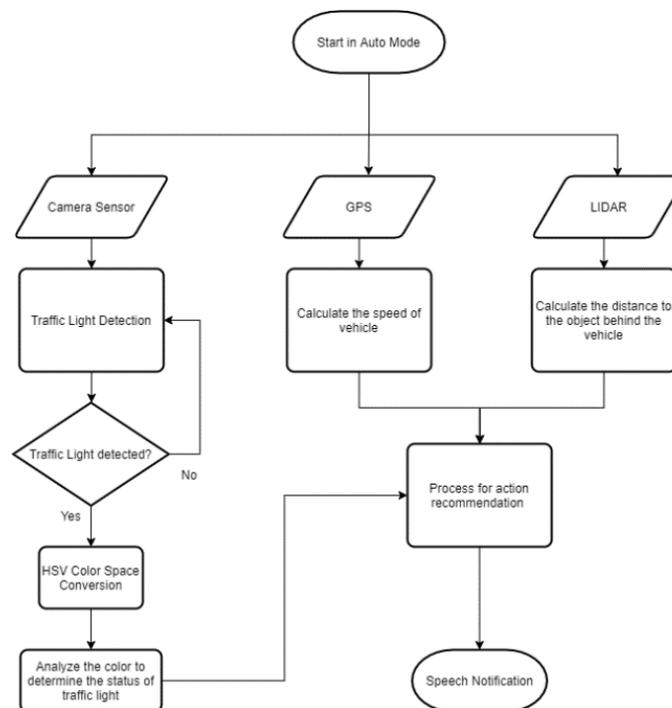
B. *Data Penelitian*

Data penelitian yang digunakan untuk mengembangkan sistem deteksi lampu lalu lintas ini adalah data jarak, kecepatan, dan identifikasi warna. Desain sistem berupa sensor dan komponen utama yang digunakan untuk mendapatkan data secara realtime dapat dilihat pada Gambar 1. Nvidia Jetson Nano berfungsi sebagai prosesor untuk mengolah data input dari sensor Lidar, GPS, dan kamera. Output dari sistem ini dalam bentuk notifikasi suara.



Gambar 1 Desain Sistem

Alur kerja dari sistem ini dapat dilihat pada Gambar 2. Pada saat sistem dinyalakan, sensor yang digunakan sebagai input yakni kamera untuk menangkap gambar, kemudian sensor Lidar untuk membaca jarak antar objek dan sensor GPS membaca data kecepatan laju dari kendaraan. Berikutnya, Nvidia Jetson Nano yang berfungsi sebagai prosesor akan mengolah data sehingga menghasilkan klasifikasi dan keputusan. Hasil pengolahan ketiga sensor tersebut akan dikeluarkan menjadi output dalam bentuk notifikasi suara.



Gambar 2 Flowchart Sistem

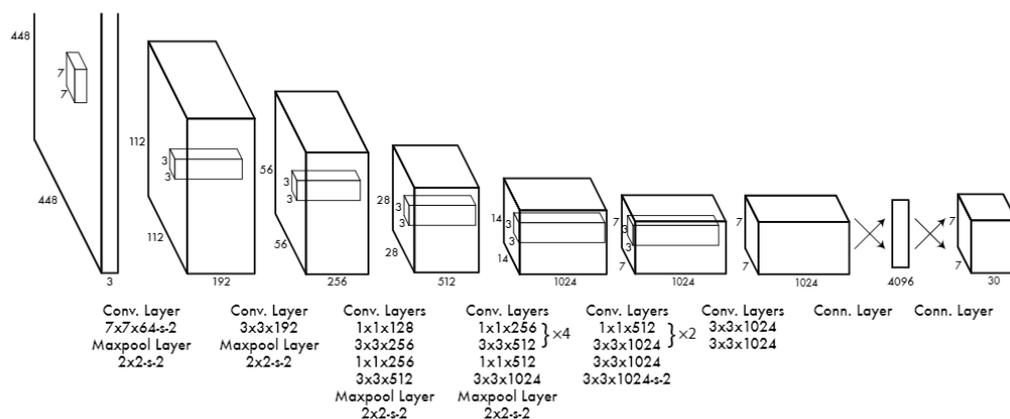
C. Lokasi Penelitian

Pengambilan dataset lampu lalu lintas dilaksanakan di Perumahan Gresik Kota Baru (GKB) Manyar, Gresik. Demikian juga pada tahap pengujian juga dilakukan di GKB Manyar Gresik, utamanya di perempatan Jalan Kalimantan.

D. Metode Penelitian

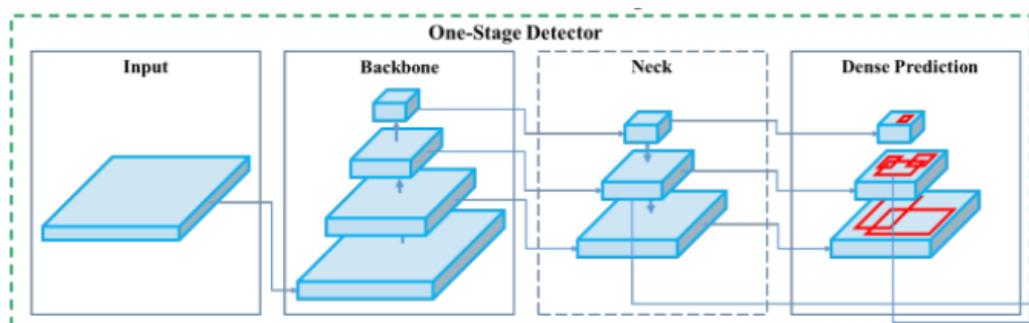
Penelitian ini menggunakan algoritma *Convolutional Neural Network (CNN) You Only Look Once v4 (YOLOv4)*, yang merupakan sistem deteksi yang berbasis *Convolutional Neural Network*. Gambar 3 adalah arsitektur YOLO terdiri dari 24 *convolutional layer* yang berfungsi sebagai mendapatkan fitur dari citra. Kemudian diikuti 2 *connected layer* yang berfungsi sebagai memprediksi probabilitas dan koordinat [7]. Terdapat tiga tahap dalam deteksi objek menggunakan YOLO seperti berikut:

- a) mengubah ukuran dimensi masukan citra menjadi 448 x 448.
- b) menjalankan *single convolutional network* pada citra; dan
- c) melakukan threshold pada hasil deteksi berdasarkan nilai *confidence* yang didapatkan oleh model.



Gambar 3 Arsitektur YOLO [12]

YOLOv4 merupakan model deteksi obyek *one stage*. Secara umum pada arsitektur deteksi obyek memiliki beberapa bagian yaitu *backbone*, *neck*, dan *head* seperti yang terlihat pada Gambar 4.



Gambar 4 Arsitektur YOLOv4

Backbone merupakan *convolution* layer utama. Pada YOLOv4 arsitektur backbone terdapat metode atau plugin tambahan untuk meningkatkan akurasi yaitu, BoF (Bag of Freebies), BoS (Bag of Specials). Algoritma YOLO merupakan algoritma *deep learning* untuk deteksi objek yang menggunakan pendekatan berbeda dari algoritma lain, yaitu menerapkan sebuah jaringan syaraf tunggal pada keseluruhan citra.

Beberapa proses dalam sistem deteksi lampu lalu lintas ini adalah sebagai berikut.

1. *Anotasi Objek*

Anotasi objek proses pelabelan pada data gambar yang hendak dilatih sehingga menghasilkan sebuah sistem yang dapat digunakan untuk mengenali suatu objek. Proses anotasi dilakukan dengan mengumpulkan data gambar yang diperlukan seperti pada Gambar 5. Pada penelitian ini digunakan data sebanyak 1000 gambar yang diambil menggunakan kamera ponsel 12MP.



Gambar 5 Dataset Lampu Lalu Lintas

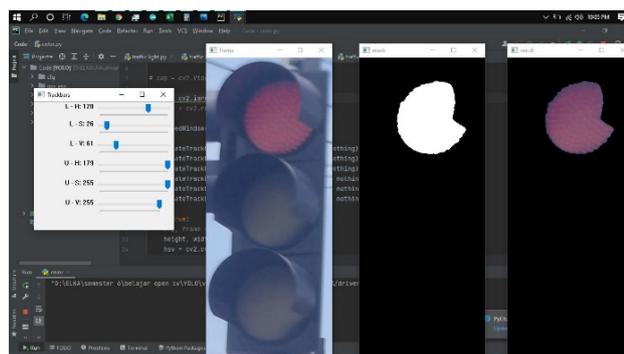
Kemudian kumpulan gambar tersebut diberi label sebelum proses training menggunakan software labellmg.exe. Setelah proses pemberian label selesai maka akan didapatkan data berkeestensi .txt yang berisikan kode koordinat dari gambar berlabel.

2. *Proses Pelatihan Dataset*

Pelatihan atau biasa disebut *training* dilakukan untuk melatih model berdasarkan data yang telah diberi label. Dalam melakukan *training*, dilakukan pengunggahan gambar pada situs aplikasi roboflow yang bertujuan untuk menambahkan variasi augmentasi dalam gambar yang telah diberi label. Data *training* dibagi menjadi 3 bagian yakni, *train* sebesar 70%, *validation* sebesar 20% dan *test* sebesar 10% Tujuannya adalah untuk menghindari overfitting pada model. Berikutnya, proses training dilakukan pada Google Colab dengan batch sebesar 5000, *learning rate* sebesar 0,00261.

3. *Seleksi Warna HSV*

Seleksi warna digunakan untuk mengidentifikasi warna lampu lalu lintas. Seleksi dilakukan dengan mengumpulkan gambar lampu lalu lintas, kemudian melakukan *threshold* warna seperti pada Gambar 6. Proses ini dilakukan untuk setiap status warna sehingga didapatkan nilai rata-rata dari warna HSV.



Gambar 6 Seleksi Warna HSV

4. *Konversi Kecepatan dan Jarak*

Konversi laju kecepatan dilakukan pada mikrokontroler ESP32 yang mendapat input data melalui komunikasi UART dengan GPS BN280. Konversi dilakukan dengan menggunakan library TinyGPS++ yang dikembangkan oleh Mikal Hart sehingga didapatkan data kecepatan laju dari suatu objek yang bergerak berdasarkan lokasi koordinat yang terbaca oleh GPS. Konversi pembacaan sensor LIDAR Tf-Mini dilakukan pada mikrokontroler ESP32. Pembacaan data sensor dapat dilakukan melalui komunikasi UART, sehingga diperlukan program untuk membaca data pada masing masing byte data yang dikirimkan oleh sensor dalam bentuk hexadecimal sehingga perlu dikonversi kedalam bilangan desimal.

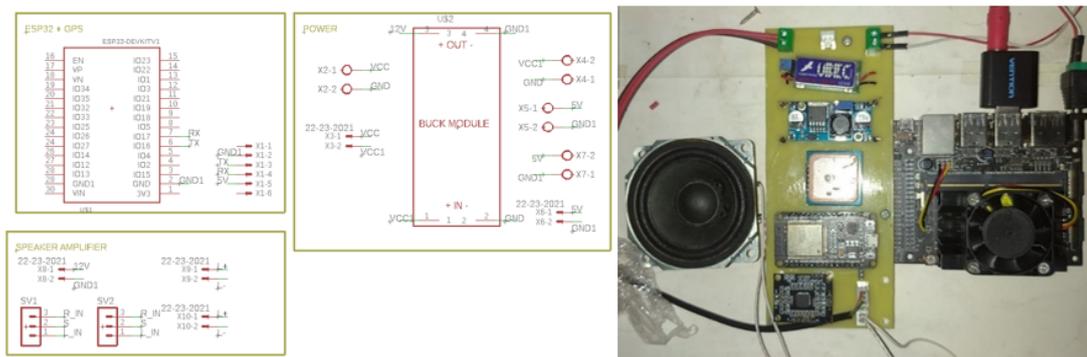
5. *Perancangan dan Pembuatan Perangkat Keras*

a. *Konfigurasi Kamera*

Perangkat kamera digunakan untuk menangkap gambar secara visual. Data yang dihasilkan dari kamera berupa citra RGB yang kemudian dikirimkan ke prosesor. Pada penelitian ini digunakan action cam BPro 5 Mark3s yang memiliki sensor sebesar 12MP, resolusi video 720p dengan frame rate sebesar 30 FPS. Pada penelitian ini digunakan media kendaraan roda dua, sehingga kamera diletakkan pada bagian depan dengan diberi gimbal elektrik.

b. *Rancangan Rangkaian Utama*

Dalam penelitian ini dibutuhkan rangkaian elektrik yang dibagi menjadi 2 papan pcb, untuk rangkaian utama berisikan blok power supply yang berfungsi untuk menurunkan tegangan menjadi 5V DC menggunakan regulator tegangan dengan jenis UBEC dengan kemampuan arus hingga 5A untuk mensuplai Nvidia Jetson Nano, ESP32 dan GPS BN280, kemudian terdapat regulator tegangan 12VDC untuk mensuplai tegangan amplifier untuk output audio. Dalam pembuatan rangkaian utama digunakan software Eagle untuk mendesain PCB seperti pada Gambar 7.



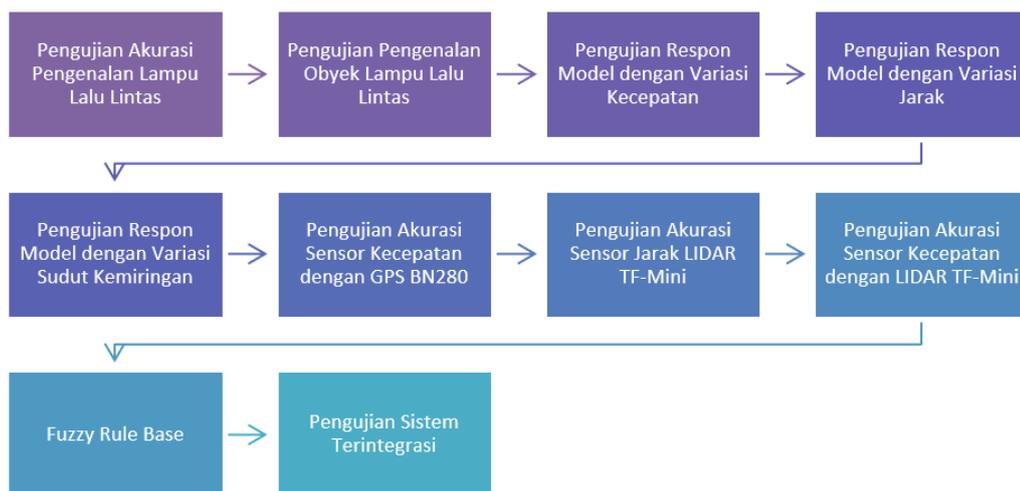
Gambar 7 Skematik dan PCB Rangkaian Utama

c. *Rancangan Rangkaian Sekunder*

Rangkaian sekunder merupakan rangkaian sensor LIDAR yang terpisah karena peletakkannya yang berbeda dengan rangkaian utama sehingga pada rangkaian ini memiliki sumber catu daya sendiri yaitu menggunakan baterai dengan tegangan 3, VDC. Rangkaian ini terdiri atas switch, ESP32 dan sensor LIDAR Tf-Mini.

E. *Evaluasi*

Untuk mengevaluasi kinerja dari sistem ini dilakukan beberapa pengujian sebagaimana ditunjukkan pada Gambar 8.



Gambar 8 Pengujian Sistem

III. HASIL DAN PEMBAHASAN

Pada bagian ini dilakukan pengujian dan analisa terhadap perangkat keras dan program yang telah dibuat. Adapun beberapa pengujian yang telah dilakukan adalah sebagai berikut.

A. Pengujian Akurasi Warna Lampu Lalu Lintas

Pengujian ini untuk mengetahui kemampuan dari metode yang telah dilatih dalam mengenali status warna lampu lalu lintas dengan membandingkan metode YOLOv4 dengan membagi 3 kelas objek warna pada model (YOLOv4 – 3 kelas) dan metode YOLOv4 dengan menambahkan konversi warna HSV (YOLOv4 – konversi HSV). Pengujian dengan membandingkan tingkat akurasi pada 3 variasi intensitas cahaya, yaitu dengan kecerahan 15, 60 dan 150 lux. Ringkasan nilai akurasi ditunjukkan pada Tabel 1. Rata-rata akurasi YOLOv4 – 3 kelas sebesar 92.831%, lebih besar dibandingkan dengan YOLOv4 – konversi HSV dengan rata-rata akurasi sebesar 85.819%. Akurasi pada metode YOLOv4 – 3 kelas dengan kecerahan 150 lux cenderung lebih besar dibandingkan dengan kecerahan 15 lux maupun 60 lux, yaitu antara 94.915% – 98.246%.

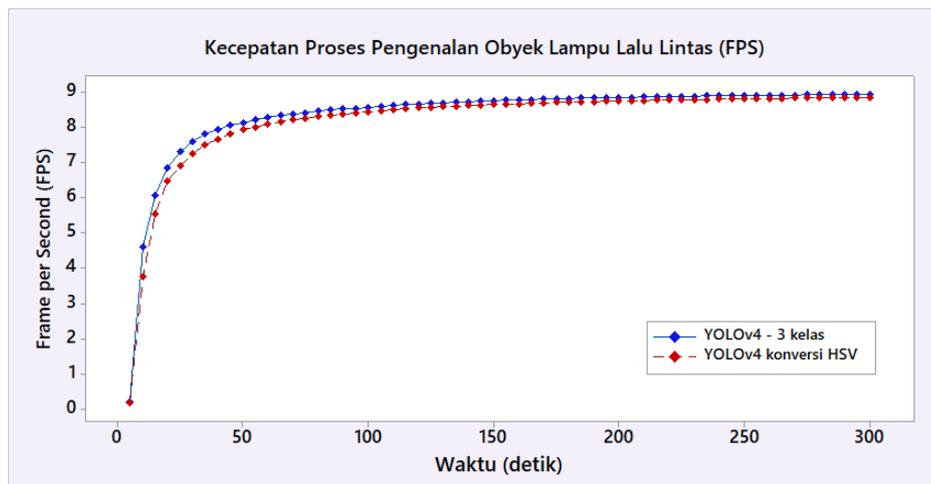
TABEL I
RINGKASAN AKURASI PENGENALAN WARNA LAMPU LALU LINTAS

Status	Akurasi (%)					
	YOLOv4 – 3 kelas			YOLOv4 – konversi HSV		
	15 lux	60 lux	150 lux	15 lux	60 lux	150 lux
Merah	86.792	94.545	94.915	89.474	100.000	70.000
Kuning	89.462	91.228	96.552	87.179	100.000	70.000
Hijau	90.196	93.440	98.246	60.734	95.000	100.000
Rata-rata	92.831			85.819		

B. Kecepatan Pengenalan Obyek Lampu Lalu Lintas

Untuk mengetahui lama waktu proses sistem dalam mengenali objek lampu lalu lintas dibandingkan dua metode yaitu YOLOv4 – 3 kelas dan YOLOv4 – konversi HSV, masing-masing dengan mini-PC Nvidia Jetson Nano 4GB. Grafik hubungan antara waktu dan kecepatan proses pengenalan obyek lampu lalu lintas ditunjukkan pada Gambar 9. Dari waktu

ke waktu, kecepatan proses pengenalan pada YOLOv4 – 3 kelas mempunyai kinerja lebih baik, dapat melakukan kecepatan proses hingga 8.94 FPS.



Gambar 9 Kecepatan Proses Pengenalan Obyek Lampu Lalu Lintas (FPS)

C. *Pengujian Respon Model dengan Variasi Kecepatan*

Pengujian ini bertujuan untuk mengetahui kecepatan proses dari sistem dalam mengenali objek lampu lalu lintas hingga pengeluaran notifikasi suara pada berbagai macam variasi kecepatan. Pegujian dilakukan dengan melakukan pendeteksian pada kecepatan perpindahan objek dengan kecepatan 5, 10, 15, 20, 25, 30 km per jam diluar ruangan menggunakan kendaraan dengan hasil yang ditunjukkan pada Tabel 2.

TABEL II
RINGKASAN AKURASI PENGENALAN WARNA LAMPU LALU LINTAS

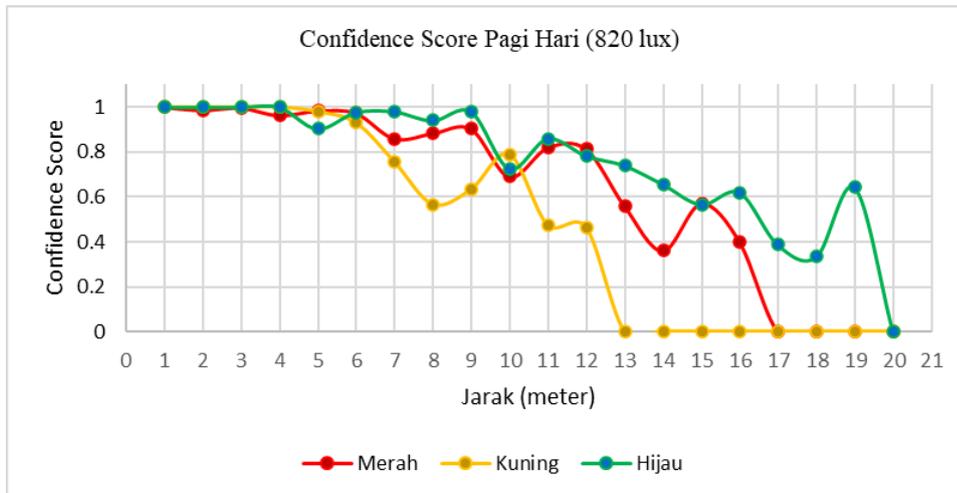
Kecepatan (km/jam)	Replikasi (kali)	Keberhasilan
5	5	100
10	5	100
15	5	100
20	5	60
25	5	20
30	5	20

Berdasarkan pengujian pada Tabel 2 didapatkan bahwa sistem dapat mengenali objek dengan tingkat keberhasilan yang tinggi pada kecepatan 5 – 15 km/jam. Pada kecepatan 20 km/jam atau lebih, tingkat keberhasilan turun dan ada delay karena keterbatasan kemampuan pengolahan gambar dan gambar buram sehingga terjadi keterlambatan notifikasi serta ketidakstabilan dari hasil pendeteksian.

D. *Pengujian Respon Sistem dengan Variasi Jarak*

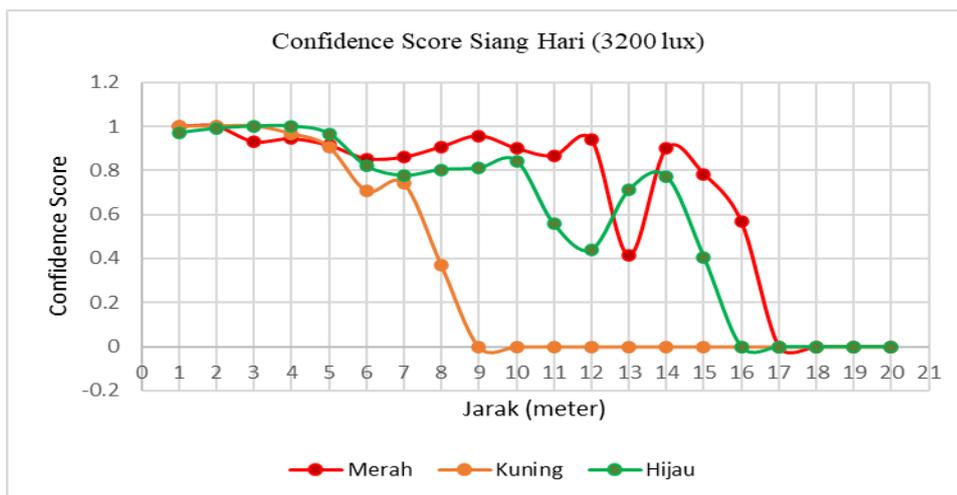
Berdasarkan hasil uji coba pada pagi, siang dan malam dengan variasi jarak 1 – 10-meter dengan masing-masing 3 replikasi diperoleh confidence score seperti yang ditunjukkan pada Gambar 10, Gambar 11, dan Gambar 12. Berdasarkan Gambar 10, pada pagi hari, confidence score pengenalan warna rambu hijau cenderung lebih tinggi dibandingkan dengan confidence

score warna rambu merah dan kuning pada jarak 6-meter sampai dengan 19 meter. Warna rambu kuning tidak dapat dikenali mulai jarak 13 meter. Sedangkan rambu warna merah tidak dapat dikenali mulai jarak 17 meter.



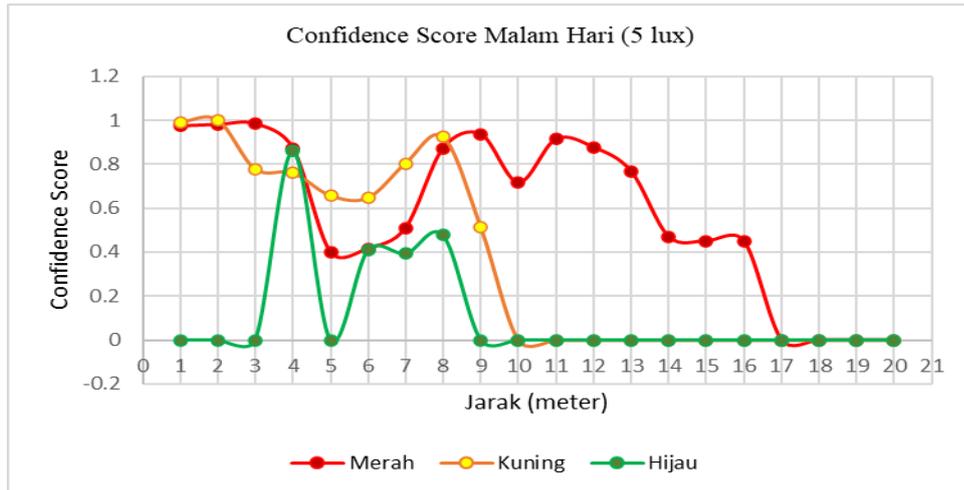
Gambar 10 Confidence Score Warna Rambu Berdasarkan Variasi Jarak (Pagi Hari)

Berdasarkan Gambar 11, hasil pada siang hari berbeda dengan pagi hari, confidence score pengenalan warna rambu merah cenderung lebih tinggi dibandingkan dengan confidence score warna rambu hijau dan kuning pada jarak 6-meter sampai dengan 16 meter, kecuali pada jarak 13 meter. Warna rambu kuning tidak dapat dikenali mulai jarak 9 meter. Sedangkan rambu warna hijau tidak dapat dikenali mulai jarak 16 meter.



Gambar 11 Confidence Score Warna Rambu Berdasarkan Variasi Jarak (Siang Hari)

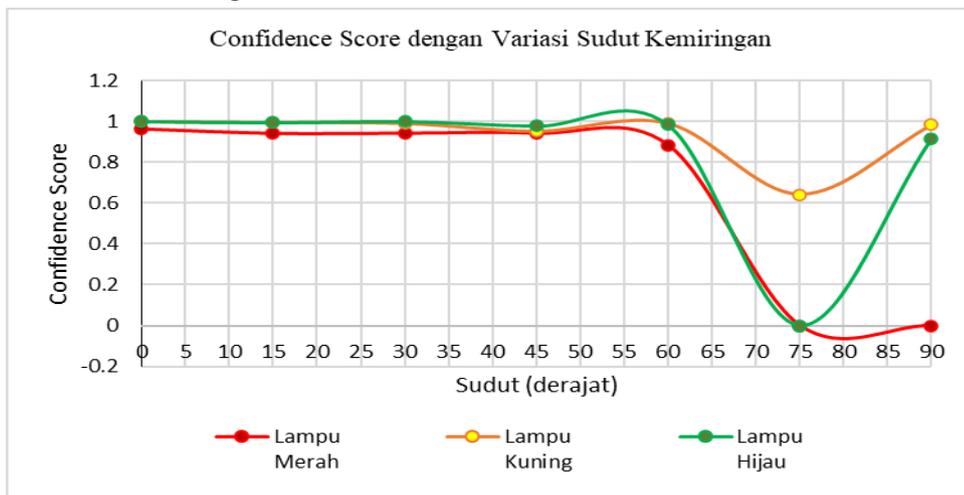
Demikian juga pada Gambar 12, hasil pada malam hari, confidence score pengenalan warna rambu merah juga cenderung lebih tinggi dibandingkan dengan confidence score warna rambu hijau dan kuning pada jarak 9-meter sampai dengan 16 meter. Warna rambu kuning tidak dapat dikenali mulai jarak 10 meter. Sedangkan rambu warna hijau tidak dapat dikenali pada jarak 5-meter dan mulai jarak 9 meter.



Gambar 12 Confidence Score Warna Rambu Berdasarkan Variasi Jarak (Malam Hari)

E. Pengujian Respon Model dengan Variasi Sudut Kemiringan

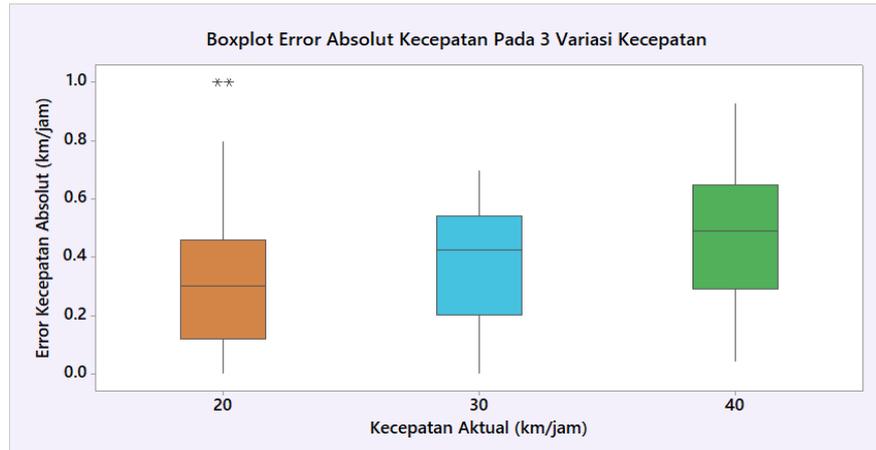
Pada Gambar 13 ditunjukkan kurva rata-rata confidence score dengan variasi sudut kemiringan mulai 0 derajat hingga 90 derajat. Kemampuan sistem untuk mengenali objek lampu lalu lintas dengan baik pada sudut kemiringan mulai dari 0 derajat hingga 60 derajat. Meskipun demikian, sistem juga dapat mengenali objek lampu lalu lintas hingga 90 derajat pada saat lampu berwarna kuning.



Gambar 13 Confidence Score Warna Rambu Berdasarkan Sudut Kemiringan

F. Pengujian Akurasi Sensor Kecepatan dengan GPS BN280

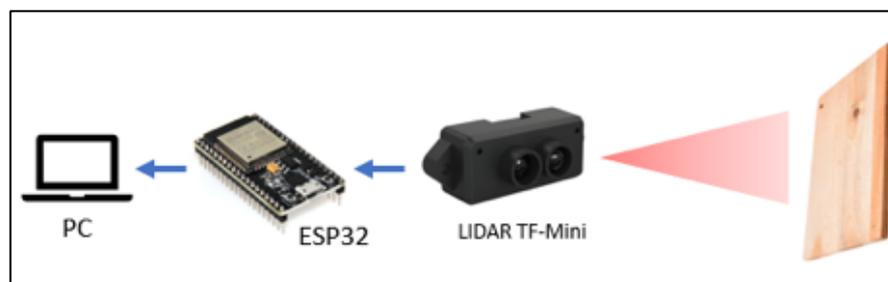
Gambar 14 adalah boxplot yang menunjukkan distribusi error kecepatan absolut menggunakan GPS BN280 dengan kecepatan aktual. Secara umum, tidak ada perbedaan distribusi error pada kecepatan 20 km/jam, 30 km/jam, dan 40 km/jam. Rata-rata error kecepatan absolut pada kecepatan 20 km/jam adalah 0.336 km/jam dengan kisaran antara 0 – 1 km /jam. Pada kecepatan 30 km/jam, rata-rata error kecepatan absolut sebesar 0.385 km/jam dengan kisaran 0 – 0.7 km/jam. Sedangkan pada kecepatan 40 km/jam, rata-rata error kecepatan absolut sebesar 0.454 km/jam dengan kisaran 0.4 – 0.93 km/jam.



Gambar 14 Boxplot Error Absolut Kecepatan Pada 3 Variasi Kecepatan

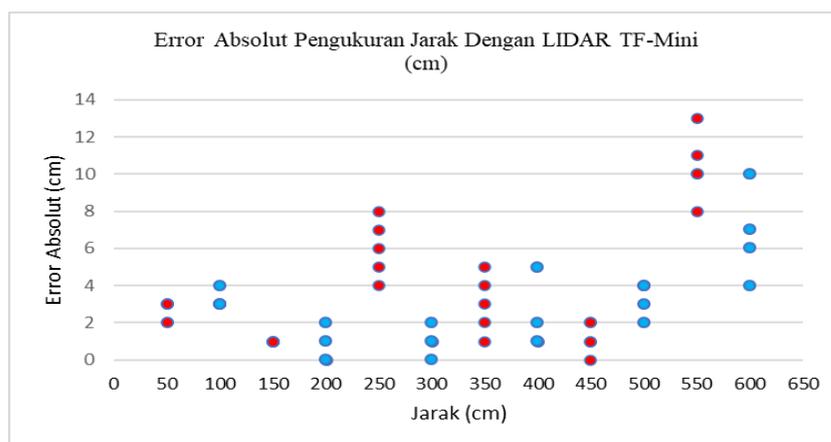
G. Pengujian Akurasi Sensor Jarak dengan LIDAR TF-Mini

Pengujian akurasi sensor jarak dengan menggunakan ESP32 yang telah terprogram untuk membaca data input dari sensor. Kemudian sensor diarahkan ke bagian papan penghalang yang akan berpindah posisi sehingga didapatkan perubahan jarak seperti ilustrasi Gambar 15.



Gambar 15 Konfigurasi Pengujian Sensor LIDAR

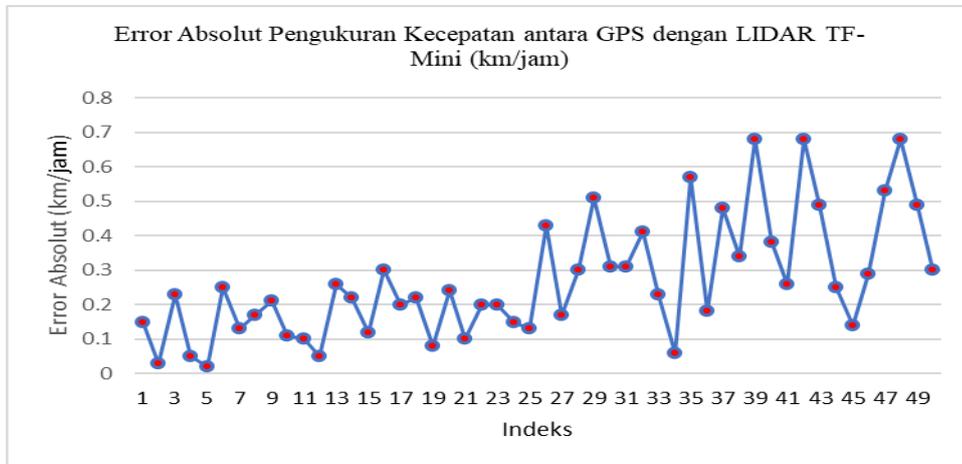
Gambar 16 adalah error absolut pengujian jarak dengan sensor LIDAR TF-Mini. Secara umum error absolut pembacaan sensor dengan jarak sebenarnya antara 0 – 13 cm. Error absolut maksimum pada saat jarak 550 cm atau 5,5-meter dengan persentase error 2,36%. Angka ini masih relatif kecil.



Gambar 16 Error Absolut Pengukuran Jarak Menggunakan LIDAR

H. Pengujian Akurasi Sensor Kecepatan dengan LIDAR TF-Mini

Gambar 17 adalah error absolut pengukuran kecepatan dengan sensor LIDAR TF-Mini dibandingkan dengan kecepatan di GPS. Secara umum rata-rata error absolut sebesar 0,268 km/jam dengan nilai berkisar 0,02 – 0,68 km/jam.



Gambar 17 Error Absolut Pengukuran Kecepatan Menggunakan LIDAR

I. Fuzzy Rule Base

Dengan menggunakan software MATLAB didapatkan hasil sebuah logika fuzzy yang sebagai algoritma penentu rekomendasi aksi bagi pengendara. Penentuan rekomendasi aksi yang diberikan didasarkan pada 3 input parameter yaitu status warna lampu lalu lintas, kecepatan kendaraan yang digunakan, dan kecepatan kendaraan yang berada dibelakang. Aturan fungsi implikasi atau *fuzzy rule base* dari sistem ditunjukkan pada Gambar 18.

- [R1] IF (LAMPU is kuning) and (KEC1 is pelan) and (KEC2 is pelan) THEN (BUZZ is berhenti)
- [R2] IF (LAMPU is kuning) and (KEC1 is pelan) and (KEC2 is sedang) THEN (BUZZ is berhenti)
- [R3] IF (LAMPU is kuning) and (KEC1 is pelan) and (KEC2 is cepat) THEN (BUZZ is jalan)
- [R4] IF (LAMPU is kuning) and (KEC1 is sedang) and (KEC2 is pelan) THEN (BUZZ is berhenti)
- [R5] IF (LAMPU is kuning) and (KEC1 is sedang) and (KEC2 is sedang) THEN (BUZZ is berhenti)
- [R6] IF (LAMPU is kuning) and (KEC1 is sedang) and (KEC2 is cepat) THEN (BUZZ is jalan)
- [R7] IF (LAMPU is kuning) and (KEC1 is cepat) and (KEC2 is pelan) THEN (BUZZ is jalan)
- [R8] IF (LAMPU is kuning) and (KEC1 is cepat) and (KEC2 is sedang) THEN (BUZZ is jalan)
- [R9] IF (LAMPU is kuning) and (KEC1 is cepat) and (KEC2 is cepat) THEN (BUZZ is jalan)
- [R10] IF (LAMPU is merah) THEN (BUZZ is berhenti)
- [R11] IF (LAMPU is hijau) THEN (BUZZ is jalan)

Gambar 18 *Fuzzy Rule Base* dari DAS Yang Dikembangkan

J. Pengujian Keseluruhan

Pada tahap ini dilakukan pengujian terhadap sistem secara terintegrasi untuk mengetahui apakah alat sudah berfungsi sesuai dengan perencanaan dan dapat bekerja dengan baik. Tabel 3 adalah pengujian sebanyak 10 kali didapatkan data bahwa sistem dapat mengenali objek

lampu lalu lintas dan kecepatan kendaraan yang digunakan serta kecepatan kendaraan lain. Namun, setelah sistem diintegrasikan terdapat penurunan kecepatan proses sebesar 1 hingga 1,5 FPS dikarenakan terdapat algoritma untuk menentukan output rekomendasi aksi yang dikeluarkan melalui buzzer dengan menggunakan algoritma fuzzy.

TABEL III
RINGKASAN AKURASI PENGENALAN WARNA LAMPU LALU LINTAS

No.	Hasil Pengenalan Rambu	Proses (FPS)	Kendaraan Pribadi (km/jam)	Kendaraan Lain (km/jam)	Output Fuzzy	Aksi
1	Hijau	7.82	10.1	13.01	2	Jalan
2	Merah	7.83	7.91	5.91	1	Berhenti
3	Merah	7.90	6.60	5.60	1	Berhenti
4	Merah	7.91	6.64	6.64	1	Berhenti
5	Kuning	7.91	11.35	12.35	1	Berhenti
6	Hijau	7.93	9.37	10.37	2	Jalan
7	Hijau	7.93	11.49	9.49	2	Jalan
8	Merah	7.97	7.85	7.85	1	Berhenti
9	Kuning	7.98	1.44	1.44	1	Berhenti
10	Kuning	8.02	1.60	2.60	1	Berhenti

IV. KESIMPULAN

Berdasarkan hasil pengujian dan analisis yang telah dilakukan, dapat disimpulkan sebagai berikut:

1. Akurasi rata-rata algoritma YOLOv4 – 3 kelas sebesar 92.831%. Kinerja ini lebih baik dibandingkan dengan metode YOLOv4 dengan seleksi warna HSV dengan akurasi rata-rata sebesar 85.819%.
2. Kecepatan deteksi sistem YOLOv4 – 3 kelas hingga 8.94 FPS, lebih cepat dibandingkan dengan metode YOLOv4 dengan seleksi warna HSV dengan kecepatan 8.84 FPS pada Nvidia Jetson Nano 4GB.
3. Jarak pembacaan paling stabil pada rentang antara 1 sampai dengan 8-meter dengan intensitas 10-3200 lux.
4. Sudut kemiringan objek lampu lalu lintas didapatkan hasil deteksi yang cukup baik untuk 3 jenis warna yakni warna kuning dan hijau dapat terdeteksi hingga sudut kemiringan 90°.
5. Sensor Lidar Tf-Mini cukup baik digunakan untuk mengukur jarak dengan error relatif rata-rata sebesar 5.56%.
6. Data GPS dapat dimanfaatkan untuk mengukur kecepatan dari laju objek yang bergerak dengan error relatif rata-rata sebesar 1,37%.

REFERENSI

- [1] F. Pangestu, A. W. Widodo, and B. Rahayudi, "Prediksi Jumlah Kendaraan Bermotor di Indonesia Menggunakan Metode Average-Based Fuzzy Time Series Models," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 9, pp. 2923–2929, 2018.
- [2] U. Enggarsasi and N. K. Sa'diyah, "Kajian Terhadap Faktor-Faktor Penyebab Kecelakaan Lalu Lintas Dalam Upaya Perbaikan Pencegahan Kecelakaan Lalu Lintas," *Perspektif*, vol. 22, no. 3, p. 228, 2017, doi: 10.30742/perspektif.v22i3.632.
- [3] M. F. T. Hakim, "Rancang Bangun Sistem Deteksi Rambu – Rambu Lalu Lintas Menggunakan Jaringan Syaraf," 2018.

- [4] G. De-Las-Heras, J. Sánchez-Soriano, and E. Puertas, “Advanced driver assistance systems (ADAS) based on machine learning techniques for the detection and transcription of variable message signs on roads,” *Sensors*, vol. 21, no. 17, pp. 1–18, 2021, doi: 10.3390/s21175866.
- [5] L. Wang *et al.*, “Advanced Driver-Assistance System (ADAS) for Intelligent Transportation Based on the Recognition of Traffic Cones,” *Adv. Civ. Eng.*, vol. 2020, 2020, doi: 10.1155/2020/8883639.
- [6] M. Kumar, D. Dhake, G. Palde, and U. Mandawkar, “DETECTION OF TRAFFIC SIGNS BY CONVOLUTIONAL NEURAL NETWORK USING SEQUENTIAL API,” vol. 9, no. 6, pp. 177–181, 2021.
- [7] O. R. Sitanggang, H. Fitriyah, and F. Utamingrum, “Sistem Deteksi dan Pengenalan Jenis Rambu Lalu Lintas Menggunakan Metode Shape Detection Pada Raspberry Pi,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput. Univ. Brawijaya*, vol. 2, no. 12, 2018.
- [8] M. Harahap *et al.*, “Sistem Cerdas Pemantauan Arus Lalu Lintas Dengan YOLO (You Only Look Once v3),” *Semin. Nas. APTIKOM*, p. 2019, 2019.
- [9] D. Okky Deltania and E. Apriaskar, “Pengaturan Lampu Lalu Lintas (Traffic Light) Dengan Sensor Ultrasonik,” *J. Ilm. Tek. Elektro*, vol. 19, no. 1, pp. 77–95, 2021, [Online]. Available: <http://dx.doi.org/10.25105/jetri.v19i1.8660>.
- [10] W. Sugeng, T. D. Putri, and H. Al Kamal, “Development of GPS-Based Mobile Application for Motorized Vehicle Speed Survey,” *J. Pekommas*, vol. 4, no. 2, p. 147, 2019, doi: 10.30818/jpkm.2019.2040205.
- [11] H. Gao, W. Wang, C. Yang, W. Jiao, Z. Chen, and T. Zhang, “Traffic signal image detection technology based on YOLO,” *J. Phys. Conf. Ser.*, vol. 1961, no. 1, 2021, doi: 10.1088/1742-6596/1961/1/012012.
- [12] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, “YOLOv4: Optimal Speed and Accuracy of Object Detection,” 2020, [Online]. Available: <http://arxiv.org/abs/2004.10934>.
- [13] Q. Wang, Q. Zhang, X. Liang, Y. Wang, C. Zhou, and V. I. Mikulovich, “Improved YOLOv4 Algorithm,” pp. 1–20, 2022.
- [14] A. K. Panggabean, A. Syahfaridzah, and N. A. Ardiningih, “Warna Hsv Menggunakan Aplikasi Matlab,” vol. 4, no. 2, pp. 94–97, 2020.