

Pengoptimasian Pengukuran Kepadatan Jalan Raya Dengan Cctv Menggunakan Metode Yolov8

Hilal Gibran¹, Bedy Purnama², Gamma Kosala³
^{1,2,3}Fakultas Informatika, Universitas Telkom Bandung, Indonesia

E-mail: hilalgibran847@gmail.com¹, bedypurnama@telkomuniversity.ac.id²,
gammakosala@telkomuniversity.ac.id³



Notifikasi Penulis
28 Desember 2023
Akhir Revisi
05 Februari 2023
Terbit
01 Juni 2023

Gibran, H., Purnama, B., & Kosala, G. Pengoptimasian Pengukuran Kepadatan Jalan Raya Dengan Cctv Menggunakan Metode Yolov8 : Optimizing Highway Density Measurement with CCTV Using the Yolov8 Method . *Technomedia Journal*, 9(1).

<https://doi.org/10.33050/tmj.v9i1.2216>

ABSTRACT

The development and growth of society according to research on the website dataindonesia.id as of December 31, 2022, the number was 126.99 million units by the end of last year. Increasing transportation density has become a serious problem in Indonesia. The relationship between speed and traffic flow (volume) can be used as a guide in determining the mathematical value of road capacity under ideal conditions. The proposed system requires CCTV to run properly. In each input frame, the system will perform data preprocessing to determine the vehicle object that will be segmented in the image. When the frame enters and preprocessing is done, the data will be rezoned to adjust to the system's compatibility. Then the data will go through the image processing stage. Image processing uses RGB color and is converted to grayscale in order to distinguish blobs in the frame. When the blob is detected, the number of objects will be counted and calculated to output the number of vehicles. The results of the number of vehicles will be used for datasets in vehicle density optimization. Motion detection that can be applied to measure highway density with CCTV using YOLO.

Keywords: Vehicle density, YOLO Method, Image Processing

ABSTRAK

Perkembangan dan pertumbuhan masyarakat menurut riset pada website dataindonesia.id per 31 desember 2022 jumlah tersebut sebanyak 126,99 juta unit hingga akhir tahun lalu. Meningkatnya kepadatan transportasi telah menjadi masalah yang serius di indonesia. Hubungan antara kecepatan dan arus lalu lintas (volume) dapat dijadikan pedoman dalam menentukan nilai matematis kapasitas jalan pada kondisi ideal. Sistem yang diusulkan memerlukan CCTV untuk dapat berjalan dengan baik. Disetiap frame input, sistem akan melakukan prapemrosesan data untuk menentukan objek kendaraan yang akan disegmentasi



citra. Saat frame masuk dan dilakukan preprocessing, data akan direzise untuk untuk menyesuaikan dengan komabilitas sistem. Lalu data tersebut akan melalui tahap image processing. Image processing menggunakan warna RGB dan diubah menjadi grayscale agar dapat membedakan blob yang ada pada frame. Saat blob terdeteksi maka jumlah objek akan dihitung dan dikalkulasikan menjadi output jumlah kendaraan. Hasil dari jumlah kendaraan tersebut yang akan digunakan untuk dataset dalam optimasi kepadatan kendaraan. Motion detection yang dapat diterapkan untuk mengukur kepadatan jalan raya dengan CCTV menggunakan YOLO.

Kata Kunci : *Kepadatan kendaraan, Metode YOLO, Image Processing*

PENDAHULUAN

Perkembangan dan pertumbuhan masyarakat beserta lingkungan yang terjadi tentunya akan memerlukan berbagai kegiatan yang ditimbulkannya [1]. Jumlah kepadatan penduduk Indonesia tercatat mengalami peningkatan menjadi 275,77 juta jiwa hingga pertengahan 2022 semakin banyak penduduk maka semakin meningkat kondisi kepadatan jalan raya [2]. Jumlah kendaraan bermotor di Indonesia mencapai 152,52 juta unit pada tahun 2022, menurut riset pada website dataindonesia.id per 31 desember 2022 jumlah tersebut sebanyak 126,99 juta unit atau 83,27% di antaranya berupa sepeda motor, sebanyak 19,31 juta unit mobil penumpang dan 5,76 juta unit kendaraan berjenis mobil beban Indonesia hingga akhir tahun lalu [3]. Meningkatnya kepadatan transportasi telah menjadi masalah yang serius di Indonesia [4].

Peningkatan lalu lintas mengubah perilaku lalu lintas [5]. Dalam Peraturan Menteri Perhubungan Nomor PM 96 Tahun 2015 secara teori, ada hubungan mendasar antara volume dan kecepatan dan kerapatan [6]. Hubungan antara kecepatan dan arus lalu lintas (volume) dapat dijadikan pedoman dalam menentukan nilai matematis kapasitas jalan pada kondisi ideal [7]. Hubungan mendasar antara kecepatan dan volume lalu lintas dapat dinyatakan, jika arus lalu lintas pada ruas jalan meningkat, maka kecepatan pada ruas jalan tersebut akan berkurang [8]. Jalan raya merupakan jalan utama yang menghubungkan satu kawasan dengan kawasan yang lain [9]. Jalan sebagai sarana penghubung utama baik antar desa, kota maupun antarnegara mempunyai peran dalam mewujudkan pembangunan daerah itu sendiri [10].

Kemacetan dalam berlalu lintas merupakan hal yang tidak asing lagi jika dilihat di kota-kota besar khususnya kota Bandung yang sedang berkembang [11]. Kemacetan merupakan akibat dari kondisi kepadatan jalan raya yang dapat dilihat pada ruas jalan, dimana kondisi pada jalan tersebut padat dan tidak teratur terutama pada saat jam sibuk dan tidak jarang pula pada jalur ini terjadi kemacetan yang dapat mempengaruhi keselamatan dan keterlambatan pengguna jalan [12].


Menurut Wilson dan teman-temannya dalam perkembangan teknologi informasi dan komunikasi saat ini, ada suatu basis system yang dapat digunakan sebagai basis kontrol dari suatu objek yaitu menggunakan Motion detection yang dapat diterapkan untuk mengukur kepadatan jalan raya dengan CCTV menggunakan YOLO [13]. Metode YOLO akan mendeteksi object yang ada [14]. Penelitian ini bertujuan merancang Pengukuran Kepadatan Jalan Raya Dengan CCTV Menggunakan Metode Yolo [15].

METODOLOGI PENELITIAN

Metode penelitian yang digunakan peneliti yaitu metode YOLO v8 dalam proses pembuatan sistem karena memiliki kemampuan untuk melihat seluruh gambar sekali kemudian melewati jaringan saraf sekali langsung mendeteksi object yang ada [16]. Sehingga dapat meningkatkan efisiensi dalam optimasi jumlah kepadatan kendaraan tertentu pada gambar dengan mengidentifikasi pola warna RGB yang telah disegmentasi oleh citra [17]. YOLO v8 merupakan hasil dari generasi baru dari YOLO v7 [18]. YOLO v8 digunakan karena memiliki kelebihan dalam mendeteksi object lebih baik, tracking sistem yang akurat, security sistem yang kuat dan masih banyak yang lain [19]. Dengan komponen module dalam YOLO v8 [20]. Menggunakan library YOLO v8 pada pemrosesan data object detection kendaraan akan dapat di indentifikasi dengan akurat dan cepat [21].


Arsitektur Sistem

YOLO menyatukan komponen yang terpisah dari pendeteksian objek menjadi satu jaringan syaraf [22]. YOLO memanfaatkan fitur dari keseluruhan gambar untuk memprediksi setiap kotak pembatas [23]. YOLO memprediksi semua kotak pembatas pada semua kelas objek untuk sebuah gambar secara bersamaan [24]. Ini berarti YOLO mempertimbangkan seluruh bagian citra secara global dan semua objek pada citra [25]. Arsitektur sistem yang akan dibuat pada penelitian *Deteksi Object Kendaraan* menggunakan YOLO v8 digambarkan pada gambar 1 Arsitektur Sistem berikut :



Gambar 1. Arsitektur Sistem

Di setiap Perilisan produk YOLO terbaru sering kita cari bagai mana tolak ukur dengan versi sebelumnya adapun data tolak ukur antar fersi YOLO dapat di lihat pada gambar 2 performa YOLO dengan versi sebelumnya di bawah ini



Gambar 2. Performa YOLO Dengan versi sebelumnya

HASIL DAN PEMBAHASAN

Perancangan Sistem

Perancangan sistem pada deteksi jumlah kendaraan pada *traffic light* merupakan tahapan utama dalam penelitian ini [26]. Diawali dari rancangan sistem yang diolah melalui perangkat lunak pengolah data Visual Code Studio dengan menambahkan baris kode dan beberapa library pada metode Yolo yang digunakan [27]. Pembuatan kode pada visual studio code berupa sistem yang digunakan untuk meresize ukuran video, bounding object dan juga klasifikasi kendaraan [28]. Untuk menjalankan code yang dibuat, diperlukan beberapa library agar dalam proses pembuatan sistem dapat lebih mudah [29]. Library yang digunakan pada perancangan sistem ini diantaranya :

- Ultralytics digunakan untuk realtime multi-tasking object.
- OpenCV yang digunakan untuk melakukan image processing.
- cv2 berfungsi untuk melakukan computer vision task.
- Numpy untuk pengolahan data numerical.
- Pandas untuk mengatur data mentah.
- Matplotlib digunakan untuk visualisasi data.
- Glob digunakan untuk membuat daftar urutan file.
- Shutil digunakan untuk operasi file dan direktori tingkat tinggi.

Pengumpulan Data

Pengumpulan data dilakukan dengan mengunduh file berformat JPG, MP4, MJPG dengan resolusi 640 x 480 p atau lebih tinggi yang didapat dengan mengunduh melalui website Kaggle dan hasil rekaman video dari kumpulan domba yang berada di salah satu kandang peternakan Sultan Farm Jember [30]. Sebanyak 3 video berisikan objek sekumpulan domba dengan durasi antara 7 detik hingga 2 menit. Pengumpulan data juga didapat melalui rekaman video CCTV yang diletakkan di beberapa sisi kandang alih - alih sebagai kamera CCTV yang terpasang dalam kandang dengan durasi minimal 30 detik sebanyak 3 video.

Pengambilan data juga dilakukan di *traffic light* dengan tujuan untuk menambah data yang akan di label. Terdapat 2 video yang menunjukkan kondisi traffic light di siang hari dan

malam hari. Dari data yang didapat, video akan di *resize* dengan ukuran 640x480. Video yang di *resize* akan diolah dengan mem *bounding box* satu per satu pada setiap object seperti motor, mobil dan truck. Dari data yang didapat, nantinya data latih sebanyak 90%, data testing sebesar 10%.



Gambar 3. Data Video Siang Hari



Gambar 4. Data Video Malam Hari

Pembangunan Model Yolo

Dalam pembangunan konfigurasi YOLO, diperlukan data uji dan data coba dengan porsi yang sudah dibagi. Untuk membuat data YOLO yang akurat, dibutuhkan data image awal, lalu dilabeling dan kemudia dilakukan testing. Pengembangan data model yang ditentukan dapat dilihat pada tabel dibawah :

Tabel 1. Pembagian Data

Training Data	Validation Data	Testing Data
90	3	7

Pada tabel tersebut dalam diketahui bahwa data yang dilatih sebanyak 90 %, validasi data sebanyak 3 %, dan data testing sebanyak 9 %. Dengan ini saat data yang diinputkan pada sistem, maka otomatis akan di potong dengan mengimport package *sklearn.model_selection* dan *train_test_split*. Data akan terbagi menjadi 3 bagian dengan rasio yang sudah ditentukan. Dari data ini dapat dilakukan pelatihan dan testing untuk menentukan konfigurasi perhitungan yang tepat. Selain itu data pada video yang dimport harus diolah terlebih dahulu dengan menyesuaikan ratio ukuran video agar di setiap video yang di render memiliki resolusi yang sama.

Tabel 2. Parameter Video



Parameter	Nilai
Width	640
Height	480
Xmin	140
Xmax	550
Ymin	150
Ymax	480

Video yang terinput akan di *resize* agar ukuran pada setiap video sama dan video yang diambil tampak pada bagian sisi video yang akan diuji. Nilai dari *width* dan *height* menjadi ukuran yang paten dalam setiap pengujian system. Lalu untuk xmin : xmax memiliki nilai 140 : 550 dan ymin : ymax memiliki nilai 150 : 480. Nilai ini ditentukan untuk mengambil potongan video yang presisi dan letak video pada sudut bagian bawah.

Hasil Pengujian


Data pada pemodelan yolo akan dilakukan pengujian untuk mendeteksi object pada data video yang di import. Untuk mengetahui tingkat akurasi pengklasifikasi data object dengan tepat, diperlukan perhitungan dengan menggunakan package *matplotlib*, *numpy*, *sklearn* dan *torch*. Dengan package ini, data pada hasil latih akan ditampilkan pada diagram dan gambar sehingga dapat lebih mudah dalam menganalisa data.

Pengujian data dilakukan 2 kali dengan konfigurasi yang sama namun berbeda data input nya. Dimana video yang akan dilatih yaki video kondisi *traffic lights* pada malam hari dan siang hari. Dari data yang dihasilkan, perhitungan perhitungan dari 2 jenis video input memiliki nilai data yang berbeda.


**Gambar 5. Precision & Recall Data Siang Hari****Gambar 6. F1 & Precision-Recall Data Siang Hari**

Pada gambar diatas menampilkan grafik *precision*, *recall*, *F1* dan *precision-recall*. Dalam membaca data grafik dilakukan dengan melihat pada sumbu sudut (0,0) pada bagian kiri, lalu dilihat garis lengkung kearah kanan. Pada *precision*, garis lengkung meningkung tajam pada titik 0,8. Hal ini menandakan bahwa sistem baru mempelajari data untuk mengklasifikasi objek mobil dan motor pada titik 0,8. Lalu pada *recall*, data lengkung tidak dimulai dari sudut (0,0) tapi mulai dari atas pada sudut (0.2, 1). Hal ini menandakan bahwa data klasifikasi object sudah berhasil dan akan mengambil data ulang untuk mengklasifikasian objek yang lebih sempurna. Garis lengkungnya menunjukan grafik dari atas melengkung ke bawah.

Pada gambar F1 menampilkan grafik melengkung yang menyerupai huruf n. F1 score digunakan untuk menghitung hasil median dari nilai *precision* dan *recall*. Hasil grafik f1 score dinilai baik karena garis lengkung keatas hingga ke bawah menunjukan bahwa nilai dari klasifikasi object memiliki presentase yang tinggi. Dan untuk *precision-recall* menampilkan grafik presentase yang tinggi dari perhitungan nilai *precision* dan *recall*. Dengan 4 tampilan grafik diatas, dapat disimpulkan bahwa pada kondisi siang hari sistem dapat membedakan objek dengan sangat baik dan menghasilkan hasil yang bagus.



Gambar 7. Precision & Recall Data Malam Hari




Gambar 8. F1 & Precision-Recall Data Malam Hari

Pada gambar diatas menampilkan grafik *precision*, *recall*, *F1* dan *precision-recall*. Dalam membaca data grafik dilakukan dengan melihat pada sumbu sudut (0,0) pada bagian kiri, lalu dilihat garis lengkung kearah kanan. Sama dengan data pada siang hari, lengkung garis menentukan seberapa presisi sistem dalam mengenali object. Namun perbedaannya terdapat pada grafik yang fluktuatif. Hal ini menandakan bahwa sistem perlu proses lebih dalam mengenali object kendaraan. Pada titik y 0,8 sistem mulai mengenal object, namun mengalami penurunan pada titik x 0,8. Recall menampilkan grafik menurun dari titik y 1,0 ke sudut titik x 1,0. Data ini menampilkan bahwa sistem dapat mengirim data balik dengan baik.

Untuk F1 score menampilkan gambaran nilai median dari data *precision* dan *recall* yang membentuk huruf n. Namun berbeda dengan data pada siang hari, tampilan gradik mediannya tidak menyentuh sudut y 1,0 namun hanya menyentuh hingga y 0,8. Dan untuk *precision-recall* menampilkan grafik presentase dari data *precision* dan *recall*. Dari data grafik diatas, dapat


disimpulkan bahwa sistem dapat dengan baik mengklasifikasi objek kendaraan pada video malam hari. Namun perbedaannya ada pada keakuratan sistem dalam mendeteksi objek. Hal ini dikarenakan data pada malam hari lebih susah dalam menentukan center dari object yang dideteksi. Data ini dapat disimpulkan dari hasil metrics yang dapat dilihat dibawah berikut.

Hasil metrics pada siang hari dan malam hari dinilai memiliki hasil yang bagus dimana nilai dari metrics cukup tinggi dan penyebaran clusteringnya yang merata.




Gambar 9. Confusion Metrics Data Siang Hari

Pada gambar diatas menampilkan data metrics pada siang hari. Metrics yang ditampilkan merupakan metrics 4x4. Dan data yang berupa data latih, val dan test akan di convert pada visualisasi metrics. Hal ini digunakan untuk melihat keakuratan yolo dalam mendeteksi object. Dapat dilihat pada gambar diatas bagian kiri, warna tergelap yakni deep blue terletak pada bagian kiri atas metrics, yang artinya object kendaraan sering terdeteksi pada bagian pojok kiri object yang telah ter-*bounding box*. Lalu pada gambar bagian kanan, menampilkan keakuratan yolo dalam menentukan object yang diklasifikasi. Semakin tinggi chart nya maka semakin akurat sistem dalam mengklasifikasi object menggunakan *bounding box*. Penyebaran data juga sangat baik dengan menyentuh sudut 1,0 pada sumbu y.




Gambar 10. Confusion Metrics Data Malam Hari

Hasil metrics pada data malam hari menampilkan hasil yang serupa dengan hasil data pada siang hari. Mulai dari tampilan metrics 4x4 dan tampilan grafik penyebaran clustering memiliki hasil yang sama. Perbedaan satu-satunya warna metrics pada bagian bawah kiri serta penyebaran data yang lebih padat dibanding data pada siang hari.



Gambar 11. Grafik Hasil Model Train, Val dan Metrics Data Siang Hari

Pada tampilan diatas menampilkan grafik dari train, val dan metrics. Pada grafik train menampilkan data *box_loss*, *cls_loss* dan *dfl_loss*. Setiap grafik mengalami penurunan pada setiap *epochs* nya. Grafik turun ini memberitahukan seberapa baik grafik dalam memproses video yang diinput. Seperti *box_loss* memberitahukan seberapa baik data yang dicocokkan dengan data *bounding box*. *Cls_loss* memberitahukan seberapa baik dalam mendeteksi objek. Dan *dfl_loss* memberitahukan seberapa baik data dari klasifikasi yang dideteksi. Dari data train *box_loss* dan *dfl_loss*, menampilkan bahwa semua grafik dimulai dari titik 2,3. Hal ini menandakan bahwa sistem dapat dengan baik mempelajari task yang diberikan dengan menggeneralisasi data dengan baik. Pada grafik val menampilkan data grafik yang sama yakni *box_loss*, *cls_loss* dan *dfl_loss*. Dari ketiga data ini, memiliki pembacaan data yang sama dengan data grafik train. Dimana semakin turun grafik pada setiap *epochs* maka akan menunjukkan seberapa baik sistem dalam menjalankan task nya. Perbedaan data train dan val terletak pada seberapa fluktuatif grafik *box_loss* dan *dfl_loss*. Tampilan grafik pada val terlihat sangat fluktuatif yakni naik turun grafik yang sangat drastic. Hal ini didasari dari perbedaan jumlah data train dan val. Pada grafik *box_loss* dan *dfl_loss*, data grafik di mulai dari titik y dibawah 1,8 sedangkan untuk *cls_loss* dimulai dari titik y dibawah 3,5. Lalu pada tampilan metrics terdiri dari 4 grafik yakni *precision(b)*, *recall(b)*, *mAP50(b)*, dan *mAP50-95(b)*. Data grafik menampilkan kenaikan pada setiap *epochs* nya. Hal in menunjukan seberapa besar akurasi metrics yang dihasilkan. Nilai dari metrics akan menunjukan *Mean Average Error* yang baik atau buruk. Sehingga untuk menentukan akurasi dan klasifikasi yang akurat dapat dinilai dari data metrics. Data pada mAP 50 dapat menyentuh titik y hingga 1,0 yang menandakan bahwa nilai akurasi sangat tinggi dan sistem dapat mengklasifikasi objek dengan baik. Begitu juga pada mAP 50-95 dapat menyentuh titik y 0,5 yang mengartikan data error tidak terlalu besar dan tergolong data pengklasifikasi yang baik.



Gambar 12. Grafik Hasil Model Train, Val dan Metrics Data Malam Hari


Sama dengan data grafik model train, val dan metrics pada data malam hari. Dimana data pada model train baik *box_loss*, *cls_loss* dan *dfl_loss* mengalami penurunan yang artinya sistem bekerja dengan baik dalam menjalankan task nya. Dan pada model val juga mengalami penurunan grafik pada *box_loss*, *cls_loss* dan *dfl_loss* yang memberitahukan seberapa baik sistem dalam mengklasifikasi data. Begitu juga dengan metrics juga mengalami kenaikan yang mengartikan seberapa besar presentase akurasi yang didapat. Perbedaan data terletak dari grafik fluktuatif yang naik turun pada data siang hari dan malam hari. Pada data malam hari, grafiknya lebih cenderung naik turun dibanding dengan data pada siang hari.

Selain itu data pada model train *box_loss* dan *dfl_loss*, nilai grafik dimulai dari sudut y dibawah 2,5 berbeda dengan grafik pada siang hari yakni dibawah 2,3. Sedangkan pada val *box_loss* dan *dfl_loss* data grafik dimulai dari sudut y dibawah 2,3 berbeda dengan data pada siang hari yang dimulai dari sudut y dibawah 1,8.



Gambar 13. Hasil Deteksi Kendaraan Siang Hari

Dari perhitungan yang sudah dilakukan maka hasil dari klasifikasi sistem dapat dilihat pada gambar diatas. Dimana data akan diklasifikasi dengan *bounding box* yang membedakan objek motor, mobil dan truck. Dari data diatas menampilkan hasil *bounding box* pada siang hari yang menampilkan data klasifikasi mobil dan motor. Nilai dari objek bounding menunjukan seberapa besar akurasi sistem dalam mendeteksi objek. Jika mobil dan motor terlihat berdempetan maka nilai dari *bounding box* akan rendah. Dan jika objek dalam tidak dalam kondisi berdempetan, maka nilai *bounding box* akan tinggi.




Gambar 14. Hasil Deteksi Kendaraan Malam Hari

Pada gambar diatas menampilkan hasil dari deteksi objek pada video yang di input. Pada video malam, nilai dari *bounding box* lebih banyak nilai yang turun yang menandakan bahwa sistem kesusahan dalam mendeteksi nilai keakuratan klasifikasi objek. Hal ini juga didasari dari nilai grafik pada *precision*, *recall*, *F1* dan *precision-recall* serta data grafik pada model train, val dan metrics. Dimana dari semua data grafik yang ada menampilkan nilai akurasi yang lebih rendah dibandingkan data video siang hari yang memiliki nilai akurasi tinggi.

Analisa Hasil Penelitian

Dari hasil pengujian sistem yang sudah dilakukan, nantinya akan dilakukan data uji dengan video rekaman baru pada titik CCTV yang sama. Untuk proses finalisasi yakni Analisa hasil dari pengujian data rekaman baru. Dengan mengidentifikasi kondisi sepi dan padat pada data video yang diuji.



Gambar 15. Hasil Deteksi Kendaraan Kondisi Sepi Data Siang Hari




Gambar 16. Hasil Deteksi Kendaraan Kondisi Sepi Data Malam Hari

Pada gambar diatas menampilkan data kondisi sepi pada video siang hari dan malam hari. Dari hasil tersebut, menampilkan hasil data dengan kondisi sepi karena melihat counting mobil

dan motor yang berjumlah sedikit. Kondisi sepi terjadi jika pada satu frame mendeteksi mobil kurang dari 4 dan motor kurang dari 7.



Gambar 17. Hasil Deteksi Kendaraan Kondisi Padat Data Siang Hari.



Gambar 18. Hasil Deteksi Kendaraan Kondisi Padat Data Malam Hari.

Pada gambar diatas menampilkan data kondisi padat pada video siang hari dan malam hari. Dari hasil tersebut, menampilkan hasil data dengan kondisi padat karena melihat counting mobil dan motor yang berjumlah banyak. Kondisi padat terjadi jika pada satu frame mendeteksi mobil lebih dari 4 dan motor lebih dari 7.

KESIMPULAN

Dari pengujian sistem diatas, dapat disimpulkan bahwa Sistem deteksi objek kendaraan di implementasikan pada bagian traffic light dengan menginput rekaman video pada CCTV. Sistem yang digunakan untuk menghitung jumlah kendaraan yang berada di depan traffic light serta membedakan kondisi antara yang sepi dan padat. Pengembangan sistem menggunakan beberapa library untuk melakukan proses deteksi objek serta perhitungan objek berdasarkan label bounding box yang ada. Dalam pengembangannya, sistem akan melakukan serangkaian proses seperti inisialisasi, generalisasi, labeling, resize, indentifikasi, deteksi serta perhitungan. Pengujian sistem dilakukan dengan menggunakan data rekaman video CCTV traffic light. Pengujian deteksi ini menggunakan 2 data video yakni data pada malam hari dan siang hari. Lalu model YOLO yang digunakan adalah YOLO V8 yang dikenal memiliki multitasking object yang baik. Untuk melakukaj tahap pengujian, video yang di input akan diresize terlebih dahulu menjadi ukuran 640x480. Lalu data video akan diambil gambar nya per Frame setiap detiknya. Nantinya data gambar yang diambil akan diproses untuk mendeteksi objek dengan YOLO v8. Hasil dari output pada data input video malam hari dan pagi hari memiliki beberapa perbedaan

yang signifikan pada hasil grafik precision, recall, F1 dan precision-recall. Perbedaan data dapat dilihat dari grafik dan hasil presentasi yang berbeda, dimana hasil dari video siang hari memiliki grafik yang lebih bagus dalam siklusnya dibandingkan dengan video malam hari. Hal ini menandakan bahwa sistem lebih mudah dalam mendeteksi objek kendaraan pada siang hari. Dan menjadi lebih sulit jika mendeteksi objek pada malam hari. Kondisi pada hasil deteksi video yang diuji diambil dari Analisa video yang di latih sebelumnya. Dimana jika kendaraan yang berhenti di traffic light terdapat jumlah mobil kurang dari empat (<4) dan motor kurang dari tujuh (<7) maka akan dianggap kondisi sepi. Sedangkan kendaraan yang berhenti terdapat jumlah mobil diatas (>4) dan jumlah motor diatas tujuh (>7) maka kondisi akan dianggap ramai.

SARAN

Penelitian selanjutnya dapat mengembangkan sistem deteksi objek kendaraan pada traffic light dengan fokus pada beberapa area penting. Pertama, perlu dipertimbangkan pengembangan algoritma yang lebih efektif khususnya untuk kondisi malam hari, mungkin dengan memanfaatkan teknologi penerangan tambahan atau penyesuaian parameter algoritma deteksi. Selain itu, melakukan perbandingan kinerja model deteksi objek lainnya selain YOLO V8 juga penting untuk mengevaluasi kemungkinan adopsi model yang lebih cocok. Studi lebih lanjut juga bisa mengeksplorasi pengaruh faktor lingkungan lainnya seperti cuaca dan kondisi jalan terhadap kinerja sistem deteksi. Pengembangan sistem deteksi real-time yang dapat diimplementasikan secara praktis juga perlu dipertimbangkan, serta penelitian lapangan untuk mengevaluasi kinerja sistem dalam situasi nyata dan analisis kelayakan implementasi dalam infrastruktur lalu lintas yang ada. Selain itu, studi terkait dampak implementasi sistem deteksi objek pada pengaturan lalu lintas dan keselamatan jalan juga dapat memberikan wawasan yang berharga bagi pengembangan sistem deteksi objek kendaraan pada traffic light selanjutnya.

DAFTAR PUSTAKA

- [1] M. R. Ardiansyah, Y. Supit, and M. S. Said, "SISTEM VISI KOMPUTER UNTUK KALKULASI KEPADATAN KENDARAAN MENGGUNAKAN ALGORITMA YOLO," *Simtek: jurnal sistem informasi dan teknik komputer*, vol. 7, no. 1, pp. 52–59, 2022.
- [2] K. Agrawal, M. K. Nigam, S. Bhattacharya, and G. Sumathi, "Ambulance detection using image processing and neural networks," in *Journal of Physics: Conference Series*, IOP Publishing, 2021, p. 012036.
- [3] C.-J. Lin, S.-Y. Jeng, and H.-W. Lioa, "A real-time vehicle counting, speed estimation, and classification system based on virtual detection zone and YOLO," *Math Probl Eng*, vol. 2021, pp. 1–10, 2021.
- [4] L. Zhang, H. Wang, X. Wang, S. Chen, H. Wang, and K. Zheng, "Vehicle object detection based on improved retinanet," in *Journal of Physics: Conference Series*, IOP Publishing, 2021, p. 012070.
- [5] V. Meilinda, S. A. Anjani, and M. Ridwan, "A Platform Based Business Revolution Activates Indonesia's Digital Economy," *Startupreneur Business Digital (SABDA*

- Journal*), vol. 2, no. 2, pp. 155–174, 2023.
- [6] N. Lutfiani, P. A. Sunarya, S. Millah, and S. Aulia Anjani, “Penerapan Gamifikasi Blockchain dalam Pendidikan iLearning,” *Technomedia Journal*, vol. 7, no. 3, pp. 399–407, Dec. 2022, doi: 10.33050/tmj.v7i3.1958.
 - [7] D. S. S. Wuisan and T. Mariyanti, “Analisa Peran Triple Helik dalam Mengatasi Tantangan Pendidikan di Era Industri 4.0,” *Jurnal MENTARI: Manajemen, Pendidikan dan Teknologi Informasi*, vol. 1, no. 2, pp. 123–132, Jan. 2023, doi: 10.34306/mentari.v1i2.258.
 - [8] R. Salam and A. Kho, “Pengaruh Manajemen Pemasaran Virtual Terhadap Produk UMKM,” *Jurnal MENTARI: Manajemen, Pendidikan dan Teknologi Informasi*, vol. 1, no. 2, pp. 198–207, Feb. 2023, doi: 10.34306/mentari.v1i2.272.
 - [9] Q. Aini, W. Febriani, C. Lukita, S. Kosasi, and U. Rahardja, “New normal regulation with face recognition technology using attendx for student attendance algorithm,” in *2022 International Conference on Science and Technology (ICOSTECH)*, IEEE, 2022, pp. 1–7.
 - [10] F. Sutisna, T. Handra, and Y. P. Jap, “The Influence of Social Media Marketing on Purchase Impulses with Brand Attentiveness as A Mediating Variable on UMKM X,” *Aptisi Transactions on Technopreneurship (ATT)*, vol. 5, no. 2, pp. 136–144, Jan. 2023, doi: 10.34306/att.v5i2.247.
 - [11] A. Pratama and A. Wijaya, “Implementasi Sistem Good Corporate Governance Pada Perangkat Lunak Berbasis Website PT. Pusaka Bumi Transportasi,” *Technomedia Journal*, vol. 7, no. 3, pp. 340–353, Dec. 2022, doi: 10.33050/tmj.v7i3.1917.
 - [12] L. Sari, S. D. Nugroho, and N. Yuliati, “Penerapan Hazard Analysis Critical Control Point pada Proses Produksi Udang Cooked Peeled Tail On Di PT. X,” *Technomedia Journal*, vol. 7, no. 3, pp. 381–398, Dec. 2022, doi: 10.33050/tmj.v7i3.1916.
 - [13] P. Nur Kamila and W. Sejati, “Karya ini berlisensi di bawah Creative Commons Attribution 4.0 (CC BY 4.0) Perencanaan Drainase Dengan Konsep Zero Delta Run Off Pada Perumahan Permata Puri Cibubur,” *Technomedia Journal (TMJ)*, vol. 8, pp. 2528–6544, 2023, doi: 10.33050/tmj.v8i1.
 - [14] U. Rahardja, Q. Aini, D. Manongga, I. Sembiring, and Y. P. A. Sanjaya, “Enhancing Machine Learning with Low-Cost P M2. 5 Air Quality Sensor Calibration using Image Processing,” *APTISI Transactions on Management*, vol. 7, no. 3, pp. 201–209, 2023.
 - [15] A. Felix and G. D. Rembulan, “Analysis of Key Factors for Improved Customer Experience, Engagement, and Loyalty in the E-Commerce Industry in Indonesia,” *Aptisi Transactions on Technopreneurship (ATT)*, vol. 5, no. 2sp, pp. 196–208, 2023.
 - [16] S. Purnama, C. S. Bangun, A. R. S. Panjaitan, and S. T. Sampoerna, “The Effect Of Digitalization On Culinary Msmes On Increasing Sales Turnover During Covid 19 Pandemic,” *Aptisi Transactions on Technopreneurship (ATT)*, vol. 4, no. 1, pp. 58–67, 2022.
 - [17] S. Zebua and M. Heru Riza Chakim, “Effect of Human Resources Quality, Performance Evaluation, and Incentives on Employee Productivity at Raharja High School,” *APTISI Transactions on Management (ATM)*, vol. 7, no. 1, pp. 1–8, 2023, doi: 10.34306.

- [18] Y. August Goenawan and S. Tinggi Ilmu Ekonomi Ppi, "Effect of Profitability and Solvency on Stock Prices With Dividend Policy as An Intervening Variable," *ATM*, vol. 7, no. 2, 2023, doi: 10.33050/atm.v7i2.1894.
- [19] A. Singh Bist, "The Importance of Building a Digital Business Startup in College," *Startupreneur Bisnis Digital (SABDA)*, vol. 2, no. 1, 2023, doi: 10.34306/sabda.
- [20] K. Arora, M. Faisal, and I. Artikel, "The Use of Data Science in Digital Marketing Techniques: Work Programs, Performance Sequences and Methods," *Startupreneur Business Digital (SABDA)*, vol. 1, no. 1, 2022, doi: 10.34306/s.
- [21] U. Rahardja, N. Lutfiani, A. Setiani Rafika, and E. Purnama Harahap, "Determinants of Lecturer Performance to Enhance Accreditation in Higher Education," in *2020 8th International Conference on Cyber and IT Service Management, CITSM 2020*, Institute of Electrical and Electronics Engineers Inc., Oct. 2020. doi: 10.1109/CITSM50537.2020.9268871.
- [22] U. Rahardja, A. Ngadi, S. Millah, E. P. Harahap, and Q. Aini, "Blockchain Application in Educational Certificates and Verification Compliant with General Data Protection Regulations."
- [23] N. Lutfiani, S. Wijono, U. Rahardja, A. Iriani, and E. A. Nabila, "Artificial Intelligence Based on Recommendation System for Startup Matchmaking Platform," in *2022 IEEE Creative Communication and Innovative Technology, ICCIT 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/ICCIT55355.2022.10118708.
- [24] T. Hongsuchon *et al.*, "Brand Experience on Brand Attachment: The Role of Interpersonal Interaction, Feedback, and Advocacy," *Emerging Science Journal*, vol. 7, no. 4, pp. 1232–1246, Aug. 2023, doi: 10.28991/ESJ-2023-07-04-014.
- [25] N. K. A. Dwijendra *et al.*, "A Multi-Objective Optimization Approach of Smart Autonomous Electrical Grid with Active Consumers and Hydrogen Storage System," *Environmental and Climate Technologies*, vol. 26, no. 1, pp. 1067–1079, Jan. 2022, doi: 10.2478/rtuect-2022-0080.
- [26] S. Purnama, C. S. Bangun, and S. A. Faaroek, "The Effect of Transaction Experience Using Digital Wallets on User Satisfaction in Millennial Generation," *Aptisi Transactions on Management (ATM)*, vol. 5, no. 2, pp. 161–168, 2021.
- [27] I. Hidayat and F. O. S. Dewi, "Effect of Liquidity, Leverage, and Working Capital Turn on Profitability," *APTISI Transactions on Management (ATM)*, vol. 7, no. 1, pp. 60–68, Feb. 2022, doi: 10.33050/atm.v7i1.1832.
- [28] Z. Kedah, "Use of E-Commerce in The World of Business," *Startupreneur Bisnis Digital (SABDA)*, vol. 2, no. 1, 2023, doi: 10.34306/sabda.v2i1.273.
- [29] S. Arif Putra, "Virtual Reality's Impacts on Learning Results in 5.0 Education : a Meta-Analysis," *International Transactions on Education Technology (ITEE)*, vol. 1, no. 1, pp. 10–18, 2022.
- [30] N. Hussain, "Peer to Peer Lending Business Agility Strategy for Fintech Startups in the Digital Finance Era in Indonesia," *Startupreneur Business Digital (SABDA Journal)*, vol. 2, no. 2, pp. 118–125, 2023.