

PENGONTROLAN LAMPU LALU LINTAS MENGGUNAKAN TEKNOLOGI DETEKSI KENDARAAN YOLOV4

Farhan Raihan Wahidin^{*1}, Wina Witanti², Edvin Ramadhan³

^{1,2,3}Universitas Jenderal Achmad Yani, Kota Bandung

Email: ¹ farhanraihanw20@if.unjani.ac.id, ² wina.witanti@lecture.unjani.ac.id, ³ edvin.ramadhan@lecture.unjani.ac.id

^{*}Penulis Korespondensi

(Naskah masuk: 27 Agustus 2024, diterima untuk diterbitkan: 29 Oktober 2025)

Abstrak

Deteksi kendaraan adalah aspek kunci dalam pengontrolan lalu lintas yang efisien. Kemacetan lalu lintas bisa terjadi salah satunya akibat pengaturan durasi lampu lalu lintas yang tidak disesuaikan dengan volume kendaraan pada saat itu. Penelitian ini bertujuan mengembangkan sistem pengontrolan lampu lalu lintas adaptif yang menyesuaikan durasi lampu berdasarkan volume kendaraan yang terdeteksi menggunakan YOLOv4, yang dapat mengatasi kekurangan pada sistem pengontrolan lalu lintas konvensional dan mengurangi kemacetan serta meningkatkan efisiensi lalu lintas. Tahapan penelitian dimulai dengan mengumpulkan data video lalu lintas dari CCTV (*Closed Circuit Television*) yang dipasang di berbagai lokasi strategis untuk mendapatkan gambaran lengkap tentang kondisi lalu lintas. Data tersebut kemudian dianalisis menggunakan algoritma YOLOv4 (*You Only Look Once v4*) untuk mendeteksi kendaraan secara real-time. YOLOv4 dipilih karena keunggulannya dalam efisiensi dan akurasi deteksi kendaraan secara real-time. Setelah data deteksi kendaraan terkumpul, data tersebut diintegrasikan dengan sistem lampu lalu lintas. Algoritma ini dirancang untuk mengintegrasikan data deteksi kendaraan secara real-time dan menyesuaikan durasi lampu lalu lintas berdasarkan jumlah kendaraan. Selanjutnya simulasi sistem menggunakan *library pygame* dilakukan untuk mengevaluasi kinerja algoritma di berbagai kondisi lalu lintas. Hasil penelitian menunjukkan bahwa penggunaan YOLOv4 dalam sistem pengontrolan lampu lalu lintas adaptif secara signifikan mengurangi kemacetan. Model YOLOv4 menunjukkan akurasi rata-rata tertinggi sebesar 78% dalam deteksi kendaraan di jalan kedua dengan kualitas video yang cukup baik. Penggunaan YOLOv4 dalam pengontrolan lampu lalu lintas menunjukkan peningkatan efisiensi dan responsivitas terhadap tingkat kepadatan lalu lintas sedang, dengan pengurangan durasi lampu hijau berkisar antara 53% hingga 86%.

Kata kunci: Deteksi, Kendaraan, YOLOv4, Pengontrolan, Lampu Lalu Lintas.

TRAFFIC LIGHT CONTROL USING YOLOV4 VEHICLE DETECTION TECHNOLOGY

Abstract

Vehicle detection is a key aspect of efficient traffic control. Traffic congestion can occur, in part, due to traffic light duration settings that are not adjusted according to the volume of vehicles at a given time. This study develops an adaptive traffic light control system that adjusts the duration of the lights based on the detected vehicle volume, aiming to address the shortcomings of conventional traffic control systems and reduce congestion while improving traffic efficiency. The research began with collecting traffic video data from CCTV (*Closed Circuit Television*) installed at various strategic locations to get a comprehensive overview of traffic conditions. The data was then analyzed using the YOLOv4 (*You Only Look Once v4*) algorithm for real-time vehicle detection. YOLOv4 was chosen for its advantages in efficiency and accuracy in real-time vehicle detection. Once the vehicle detection data was collected, it was integrated with the traffic light system. The algorithm was designed to integrate real-time vehicle detection data and adjust the traffic light duration based on the number of vehicles. A simulation of the system was then conducted using the *Pygame* library to evaluate the algorithm's performance under various traffic conditions. The study results showed that the use of YOLOv4 in adaptive traffic light control systems significantly reduced congestion. The YOLOv4 model demonstrated the highest average accuracy of 78.93% in vehicle detection on the second road with fairly good video quality. The use of YOLOv4 in traffic light control showed increased efficiency and responsiveness to moderate traffic density, with a reduction in green light duration ranging from 53% to 86%.

Keywords: Vehicle, Detection, Yolov4, Traffic Light, Control.

1. PENDAHULUAN

Kemacetan lalu lintas adalah masalah umum di banyak kota metropolitan. Masalah yang timbul antara lain waktu tunggu yang tidak proporsional di lampu lalu lintas, kemacetan kendaraan, dan ketidakmampuan sistem konvensional untuk merespons perubahan volume kendaraan. Salah satu faktor utama yang berkontribusi terhadap kemacetan adalah sistem pengendalian lampu lalu lintas yang tidak efisien (SAHAL et al., 2023). Sistem konvensional yang beroperasi pada waktu tetap sering kali gagal mengakomodasi fluktuasi dinamis dalam volume lalu lintas, terutama selama jam sibuk atau acara khusus yang memengaruhi arus lalu lintas.

Seiring dengan perkembangan teknologi, khususnya dalam bidang kecerdasan buatan dan computer vision, terbuka peluang untuk merevolusi cara kita mengelola lalu lintas perkotaan (CHAUHAN et al., 2019). Salah satu terobosan yang menjanjikan adalah penggunaan algoritma deteksi objek real-time seperti YOLOv4 (*You Only Look Once version 4*) dalam sistem pengontrolan lampu lalu lintas (BOCHKOVSKIY dkk., 2020). YOLOv4 merupakan penyempurnaan dari versi-versi sebelumnya, menawarkan keseimbangan optimal antara kecepatan dan akurasi dalam deteksi objek (Wang et al., 2022b).

Implementasi YOLOv4 dalam sistem pengontrolan lampu lalu lintas memungkinkan deteksi dan penghitungan kendaraan secara real-time di persimpangan jalan (MAHTO et al., 2020). Data yang dihasilkan dapat digunakan untuk mengoptimalkan durasi dan sekuens lampu lalu lintas, menyesuaikan dengan kondisi aktual di lapangan. Pendekatan ini memungkinkan sistem memberikan respons adaptif terhadap perubahan lalu lintas secara real-time, sehingga mengurangi waktu tunggu kendaraan dan meningkatkan efisiensi lalu lintas (Prathap et al., 2022).

Sistem lampu lalu lintas adaptif ini unggul dari sistem statis dengan peningkatan 23% dalam jumlah kendaraan yang melintasi persimpangan. Menggunakan gambar CCTV dan AI dengan YOLO untuk deteksi kendaraan, sistem menyesuaikan waktu sinyal hijau berdasarkan kepadatan lalu lintas real-time. Simulasi dengan pygame menunjukkan efektivitasnya dalam meningkatkan aliran lalu lintas, dengan akurasi deteksi kendaraan 75-80% (GANDHI et al., 2020). Penggunaan metode deep learning, khususnya YOLOv3 (*You Only Look Once v3*), dalam deteksi objek pada manajemen lalu lintas telah terbukti efektif. Model YOLOv3 ini mampu mendeteksi kendaraan secara real-time dari rekaman CCTV dan menyesuaikan lampu lalu lintas berdasarkan jumlah kendaraan yang terdeteksi. Selain itu, teknologi *computer vision* dan integrasi dengan perangkat keras seperti Arduino Mega untuk pembuatan prototipe juga merupakan bagian dari inovasi ini. Akurasi deteksi kendaraan dengan model YOLOv3 mencapai sebesar 69% (HADI dkk., 2022).

Penelitian sebelumnya telah mengusulkan penggunaan algoritma deteksi objek seperti YOLOv3 untuk mengoptimalkan durasi lampu lalu lintas berdasarkan volume kendaraan yang terdeteksi. Namun, metode tersebut memiliki keterbatasan, seperti akurasi deteksi yang rendah pada kondisi pencahayaan buruk dan ketidakmampuan untuk mendeteksi berbagai jenis kendaraan secara bersamaan. Selain itu, implementasi sistem deteksi ini masih memerlukan pengembangan lebih lanjut dalam hal integrasi real-time dengan sistem pengontrolan lampu lalu lintas.

Penelitian ini bertujuan untuk mengatasi keterbatasan tersebut dengan mengembangkan sistem pengontrolan lampu lalu lintas adaptif menggunakan algoritma YOLOv4. Algoritma ini dipilih karena memiliki keunggulan dalam efisiensi dan akurasi deteksi objek real-time dibandingkan dengan algoritma sebelumnya. Sistem yang dikembangkan mampu mendeteksi dan menghitung jumlah kendaraan pada setiap jalur persimpangan jalan secara real-time, sehingga dapat menyesuaikan durasi lampu lalu lintas berdasarkan volume kendaraan yang terdeteksi. Dengan demikian, penelitian ini berkontribusi pada pengembangan solusi teknologi berbasis kecerdasan buatan untuk meningkatkan efisiensi lalu lintas dan mengurangi kemacetan di persimpangan jalan.

2. KAJIAN PUSTAKA

Berbagai penelitian sebelumnya telah mengeksplorasi penggunaan teknologi deteksi kendaraan untuk pengontrolan lampu lalu lintas. Penelitian oleh (HADI, SILALAH and WIBAWA, 2022) sistem pengontrolan lampu lalu lintas yang menggunakan teknologi deteksi kendaraan YOLOv3 memiliki kemampuan mendeteksi objek secara real-time dengan akurasi rata-rata 69%. Hasil penelitian menunjukkan bahwa sistem dapat menyesuaikan waktu sinyal lampu lalu lintas berdasarkan jumlah kendaraan yang terdeteksi. Namun, pendekatan mereka hanya berfokus pada deteksi dua jenis kendaraan, yaitu mobil dan sepeda motor.

Penelitian oleh (GANDHI et al., 2020) memanfaatkan teknologi kecerdasan buatan (*Artificial Intelligence*) berbasis YOLO untuk mengatur durasi lampu lalu lintas secara adaptif. Hasil simulasi menunjukkan peningkatan efisiensi pengaturan lampu hingga 23%. Namun, penelitian ini tidak memperluas implementasi pada berbagai jenis kendaraan atau kondisi lalu lintas yang lebih kompleks. Simulasi yang digunakan juga tidak mencakup penghitungan langsung berdasarkan deteksi kendaraan secara real-time.

Penelitian oleh (SAHAL et al., 2023) Penelitian ini menggunakan YOLO berbasis kamera untuk mengontrol lampu lalu lintas dengan algoritma reinforcement learning. Hasil penelitian menunjukkan kemampuan sistem dalam mengurangi kemacetan, tetapi pendekatan ini memerlukan data

pelatihan yang sangat besar dan integrasi yang kompleks untuk implementasi praktis.

Penelitian ini memanfaatkan YOLOv4 untuk mendeteksi berbagai jenis kendaraan, termasuk mobil, sepeda motor, bus, dan truk. YOLOv4 dilengkapi dengan fitur inovatif seperti Cross Stage Partial Connections (CSP) dan Mosaic Data Augmentation (Wang et al., 2021). Sistem pengontrol lampu lalu lintas yang dirancang mengintegrasikan data deteksi kendaraan secara langsung dengan pengaturan durasi lampu yang bersifat dinamis. Pendekatan ini memungkinkan sistem memberikan respons adaptif terhadap perubahan lalu lintas secara real-time. Simulasi dilakukan menggunakan pustaka Pygame untuk memodelkan persimpangan empat arah, dengan durasi lampu lalu lintas yang diatur berdasarkan jumlah kendaraan yang terdeteksi.

3. DASAR TEORI

3.1. Deteksi Objek

Deteksi objek, merupakan aspek krusial dalam *Computer Vision*, menerangkan cara di mana mesin dapat mengenali objek visual dalam gambar digital (PRISKY dkk, 2020). Deteksi objek diartikan sebagai "tugas penting dalam *computer vision* yang menangani identifikasi instance dari objek visual kelas tertentu (seperti manusia, hewan, atau kendaraan) dalam gambar digital." Tujuan utama dari deteksi objek, sebagai landasan dalam *Computer Vision*, adalah mengembangkan model dan teknik komputasi untuk memberikan informasi fundamental: "*what objects are where?*" (ZOU et al., 2023). Selain mengidentifikasi objek dalam gambar, deteksi objek juga mencakup berbagai tugas penting dalam *Computer Vision* seperti *segmentasi instance*, *Image Captioning*, serta *Object Tracking*.

Di berbagai bidang pekerjaan, deteksi objek merupakan alat yang serbaguna, digunakan mulai dari bidang kesehatan hingga keamanan. Dalam industri transportasi, deteksi objek menjadi krusial untuk mengidentifikasi hal-hal yang mungkin mengganggu kenyamanan berkendara, termasuk klasifikasi objek dalam lingkungan kendaraan otonom seperti yang terlihat pada Gambar 1 (ISSA et al., 2021).



Gambar 1. Mendeteksi Objek pada Kendaraan Otonom

3.2. YOLOv4 (You Only Look Once v4)

YOLO, atau *You Only Look Once*, merupakan salah satu pendekatan single-stage dalam deteksi objek, bersaing dengan metode seperti SSD (*Single*


Shot Detector). Berbeda dengan pendekatan tradisional, YOLO memperlakukan deteksi objek sebagai masalah regresi. Pendekatan ini memungkinkan neural network untuk secara simultan memprediksi bounding box dan kelas probabilitas terkait hanya dengan satu evaluasi keseluruhan citra, menghilangkan kebutuhan untuk langkah-langkah berurutan. Dengan demikian, YOLO mempercepat proses deteksi objek dengan efisiensi tinggi.



Gambar 2. Contoh Cara Kerja YOLO

Pada Gambar 2, dalam algoritma YOLOv4, tahap awal melibatkan pembagian gambar menjadi suatu grid berdimensi $S \times S$. Setiap sel dalam grid akan memprediksi N kotak penghalang potensial, bersama dengan nilai kemungkinan mereka. Algoritma ini akan menyaring dan menghapus kotak yang memiliki probabilitas di bawah batas tertentu, meskipun banyak dari bounding boxes ini memiliki probabilitas yang rendah. Setelah filter bounding boxes, proses Non-Maximum Suppression (NMS) akan digunakan untuk mendapatkan posisi objek yang paling tepat sesuai dengan metode YOLOv4 ini. Dengan demikian, YOLOv4 melakukan pemrosesan yang selektif dan akurat untuk menemukan posisi objek dalam citra (Wang et al., 2022b).

YOLOv4, yang diperkenalkan oleh Alexey Bochkovskiy pada tahun 2020, menghadirkan sejumlah fitur baru yang bertujuan untuk meningkatkan efisiensi dan akurasi deteksi objek. Salah satu inovasi utama adalah *Weighted Residual Connections*, yang mengintegrasikan residu dari lapisan neural network dengan efektif (Tran and Jeon, 2020). *Cross Stage Partial Connections* (CSP) dikembangkan untuk mengurangi komputasi sebesar 20% dan mengintegrasikan fitur map dari awal hingga akhir jaringan, melebihi arsitektur *backbone modern* lainnya. *Cross Mini-Batch Normalization* diterapkan untuk memperbaiki estimasi statistik saat normalisasi (YAO et al., 2021). sementara *Self Adversarial Training* menggunakan augmentasi data dua tahap ke depan dan ke belakang. Metode aktivasi *non-monoton Mish* digunakan untuk mengurangi dirinya sendiri (MISRA, 2020). sementara *Mosaic Data Augmentation* menggabungkan gambar dari dataset menjadi satu untuk regularisasi CNN, dikenal sebagai *DropBlock regularization* (Wang et al., 2022). Fungsi kehilangan CIoU diperkenalkan untuk konvergensi yang lebih cepat dan akurasi yang lebih baik dalam regresi bounding box (ZHENG et al., 2020).



Gambar 3. Arsitektur YOLO v4


Gambar 3 menunjukkan bahwa YOLOv4 menggunakan CSPDarknet53 sebagai *backbone network*. Bagian "Perut" memanfaatkan teknologi *Spatial Pyramid Pooling* (SPP) dan *Path Aggregation Network* (PANet), sementara "Head" terdiri dari tiga YOLO head yang masing-masing menghasilkan feature maps berukuran $SS2 \times (3 * (5 + C))$, di mana S adalah ukuran grid. Setiap YOLO head bertanggung jawab untuk deteksi objek berdasarkan ukuran *bounding box* dan atribut seperti koordinat titik tengah, lebar, tinggi, *objectness score*, dan *confidence score* untuk setiap kelas.

Berbagai bagian dalam YOLOv4 memiliki fungsi spesifik dalam proses deteksi objek. CSPdarknet53 mengekstraksi fitur dari citra, SPP dan PANet memperbaiki kualitas feature map, dan YOLO head mendeteksi objek dengan ukuran yang berbeda. Perbandingan kecepatan YOLOv4 dengan arsitektur lainnya dapat dilihat pada Gambar 4, yang menunjukkan efisiensi relatif dari arsitektur ini dalam konteks deteksi objek.

4. METODE PENELITIAN

Bagian metodologi ini menguraikan langkah-langkah yang terlibat dalam mengembangkan sistem pengontrolan lampu lalu lintas menggunakan teknologi deteksi kendaraan YOLOv4. Langkah-langkah yang dilakukan dalam penelitian ini adalah data kamera CCTV, proses deteksi dan perhitungan kendaraan dengan YOLOv4, mendapatkan durasi lampu lalu lintas, simulasi pengontrolan lampu lalu

lintas, evaluasi parameter performa. Sebagaimana yang terlihat pada diagram Gambar 5.



Gambar 4. Grafik Perbandingan Kecepatan YOLOv4



Gambar 5. Diagram Proses Sistem Kontrol Lampu Lalu Lintas

4.1. Input Data Kamera CCTV

Pada tahap input data kamera CCTV, kamera pengawas ditempatkan di lokasi strategis di persimpangan jalan untuk menangkap video lalu lintas yang ada. Kamera-kamera ini berfungsi sebagai

sumber data utama yang akan diproses lebih lanjut dalam sistem. Memilih posisi kamera yang optimal sangat penting untuk memastikan bahwa semua kendaraan yang mendekati persimpangan dapat terdeteksi dengan jelas oleh sistem.

Data kamera CCTV yang digunakan yaitu kamera CCTV di beberapa jalan yang terdaftar di situs web *Area Traffic Control System* (ATCS) Dinas Perhubungan: <https://cctv.bimakota.go.id/> sebagai Jalan 1, <https://atcs.ciamiskab.go.id/> sebagai Jalan 2, <https://cctv.demak.online/> sebagai Jalan 3, dan <https://atcs.cianjurkab.go.id/> sebagai Jalan 4. Data video CCTV, seperti yang ditunjukkan pada Gambar 6, direkam menggunakan OBS Studio dari situs web ATCS. Selanjutnya, rekaman data lalu lintas disimpan secara lokal dalam format file .mp4.



Gambar 6. Data Video CCTV

4.2. Proses Deteksi dan Perhitungan Kendaraan dengan YOLOv4

Setelah data video CCTV dimasukkan, data tersebut akan diproses menggunakan algoritma YOLOv4 (*You Only Look Once versi 4*). YOLOv4 adalah salah satu metode deteksi objek yang paling efisien dan akurat, mampu mendeteksi dan menghitung kendaraan dalam bingkai gambar atau video secara real-time (SHUBHO et al., 2021). Algoritma ini bekerja dengan membagi gambar menjadi grid dan kemudian memprediksi kotak batas dan probabilitas untuk setiap sel grid. Setiap kendaraan yang terdeteksi oleh YOLOv4 akan dihitung, dan informasi ini akan diteruskan ke tahap berikutnya. Dengan kemampuan deteksi yang cepat dan akurat, YOLOv4 memungkinkan sistem untuk memantau lalu lintas secara terus-menerus dan menyediakan data yang diperlukan untuk pengontrolan lampu lalu lintas.

Model YOLOv4 yang digunakan telah melalui pelatihan sebelumnya, sehingga memerlukan Dataset COCO (*Common Objects in Context*) untuk melatih deteksi objek pada YOLOv4. Dataset COCO merupakan salah satu dataset paling populer untuk deteksi objek karena mencakup berbagai jenis objek dalam konteks yang realistis. Dataset ini meliputi sekitar 80 kategori objek yang berbeda, termasuk kendaraan seperti mobil, bus, dan sepeda motor, yang sangat relevan untuk deteksi kendaraan dalam sistem pengontrolan lampu lalu lintas. Dataset ini dapat diakses

<https://github.com/AlexeyAB/darknet/> dan juga ditampilkan pada Gambar 7.

P. > coco.names	P. > coco.names	P. > coco.names
1 person	32 snowboard	63 tvmonitor
2 bicycle	33 sports ball	64 laptop
3 car	34 kite	65 mouse
4 motorbike	35 baseball bat	66 remote
5 aeroplane	36 baseball glove	67 keyboard
6 bus	37 skateboard	68 cell phone
7 train	38 surfboard	69 microwave
8 truck	39 tennis racket	70 oven
9 boat	40 bottle	71 toaster
10 traffic light	41 wine glass	72 sink
11 fire hydrant	42 cup	73 refrigerator
12 stop sign	43 fork	74 book
13 parking meter	44 knife	75 clock
14 bench	45 spoon	76 vase
15 bird	46 bowl	77 scissors
16 cat	47 banana	78 teddy bear
17 dog	48 apple	79 hair drier
18 horse	49 sandwich	80 toothbrush
19 sheep	50 orange	
20 cow	51 broccoli	
21 elephant	52 carrot	
22 bear	53 hot dog	
23 zebra	54 pizza	
24 giraffe	55 donut	
25 backpack	56 cake	
26 umbrella	57 chair	
27 handbag	58 sofa	
28 tie	59 pottedplant	
29 suitcase	60 bed	
30 frisbee	61 diningtable	
31 skis	62 toilet	

Gambar 7. File Coco.names

Dataset COCO adalah kumpulan gambar besar yang mencakup 328.000 gambar objek sehari-hari dan orang. Dataset ini tersedia dalam format file zip di situs web <https://cocodataset.org/> dengan anotasi Train/Val 2017 berukuran 241MB. Dalam dataset ini, terdapat 43.867 gambar mobil dan 7.133 gambar sepeda motor, yang digunakan sebagai sumber data pelatihan untuk model YOLOv4.

Untuk mendukung model YOLOv4 yang telah dilatih, diperlukan dua komponen utama. Pertama, file konfigurasi (.cfg) yang sesuai dengan model YOLOv4. File ini menentukan struktur dan parameter arsitektur model, termasuk jumlah dan jenis lapisan, hiperparameter seperti laju pembelajaran, dan pengaturan deteksi objek seperti jumlah kelas dan ambang kepercayaan. File konfigurasi juga mencakup informasi tentang ukuran gambar input dan grid pemetaan yang digunakan oleh model. Contoh file konfigurasi YOLOv4 dapat ditemukan di repositori resmi Darknet atau di proyek-proyek yang mengimplementasikan YOLOv4.

Kedua, file bobot YOLOv4 yang sudah dilatih sebelumnya diperlukan. File ini berisi parameter-parameter yang telah disesuaikan selama proses pelatihan model, yang mewakili pengetahuan yang telah diperoleh model tentang objek yang dikenali. Bobot ini terus diperbarui selama pelatihan untuk meningkatkan kinerja deteksi objek, dan file bobot yang dihasilkan dari pelatihan dengan dataset COCO umumnya memiliki ekstensi ".weights". File bobot ini dapat diunduh dari repositori terpercaya seperti GitHub Darknet.

Kedua komponen ini bersama-sama membentuk model YOLOv4 yang siap digunakan untuk deteksi objek dalam gambar atau video. Dengan mengunduh dan menyiapkan komponen-komponen ini, penelitian dapat dilanjutkan dengan mempersiapkan model untuk pengujian lebih lanjut terkait deteksi objek, khususnya dalam konteks penghitungan kendaraan di jalan.

- `yolov4.cfg` - 245 MB; `yolov4.weights` (Google-drive mirror `yolov4.weights`) paper `Yolo v4` just change `width` and `height` parameters in `yolov4.cfg` file and use the same `yolov4.weights` file for all cases:
 - `width=608 height=608` in cfg: 65.7% mAP@0.5 (43.5% AP@0.5:0.95) - 34(R) FPS / 62(V) FPS - 128.5 BFlops
 - `width=512 height=512` in cfg: 64.9% mAP@0.5 (43.0% AP@0.5:0.95) - 45(R) FPS / 83(V) FPS - 91.1 BFlops
 - `width=416 height=416` in cfg: 62.8% mAP@0.5 (41.2% AP@0.5:0.95) - 55(R) FPS / 96(V) FPS - 60.1 BFlops
 - `width=320 height=320` in cfg: 60% mAP@0.5 (38% AP@0.5:0.95) - 63(R) FPS / 123(V) FPS - 35.5 BFlops


Gambar 8. File weights dan cfg

Gambar 8 menunjukkan bahwa file bobot menunjukkan nilai akurasi yang bervariasi tergantung pada pengaturan ukuran. Dengan pengaturan resolusi lebar=608 dan tinggi=608, model mencapai Mean Average Precision (mAP) yang tinggi sebesar 65,7%, meskipun kecepatannya lebih lambat. Sebaliknya, dengan pengaturan lebar=320 dan tinggi=320, kecepatan model meningkat menjadi 63 FPS, tetapi mAP-nya menurun.

Pengaturan dengan lebar=512 dan tinggi=416 menunjukkan keseimbangan yang lebih baik antara kecepatan dan akurasi. Dalam konfigurasi ini, mAP berkisar antara 64,9% hingga 62,8%, dengan kecepatan mencapai 63 FPS. File `yolov4.weights` yang sama digunakan untuk semua pengaturan ini, menunjukkan dampak langsung dari pengaturan resolusi terhadap kinerja dan akurasi model YOLOv4 dalam deteksi objek.

4.3. Mendapatkan Durasi Lampu Lalu Lintas

Pada tahap "*get traffic light duration*", durasi lampu hijau didasarkan pada jumlah kendaraan yang terdeteksi oleh sistem YOLOv4. Penelitian ini menerapkan prinsip pengaturan adaptif untuk durasi lampu lalu lintas berdasarkan jumlah kendaraan yang terdeteksi secara real-time. Penyesuaian lampu hijau mengacu pada penelitian sebelumnya tentang pengelolaan lalu lintas adaptif, seperti yang dijelaskan oleh (SAHAL et al., 2023), yang menyatakan bahwa sistem adaptif dapat meningkatkan efisiensi lalu lintas dan mengurangi kemacetan. Dalam pendekatan ini, setiap kendaraan yang terdeteksi menambah 1 detik pada durasi lampu hijau, sedangkan durasi lampu kuning tetap 5 detik. Misalnya, jika terdeteksi 5 kendaraan, lampu hijau akan menyala selama 5 detik. Perhitungan ini dirancang untuk memastikan kelancaran arus lalu lintas, mengurangi waktu tunggu kendaraan, dan meminimalkan kemacetan. Durasi lampu hijau sebesar 1 detik per kendaraan diasumsikan cukup untuk memungkinkan kendaraan melintasi persimpangan, meskipun durasi tersebut dapat disesuaikan berdasarkan kondisi lalu lintas dan kecepatan kendaraan. Lampu kuning yang diatur selama 5 detik memberikan waktu yang cukup agar kendaraan dapat melewati persimpangan dengan aman. Gambar 9 di bawah ini menunjukkan diagram proses untuk pengaturan lampu hijau, kuning, dan merah.



Gambar 9. Proses Set Up Lampu Lalu Lintas

Proses pengaturan lampu lalu lintas melibatkan beberapa langkah. Pertama, sistem menghitung jumlah kendaraan yang terdeteksi (x) menggunakan teknologi deteksi kendaraan YOLOv4. Jumlah ini disimpan dalam sebuah variabel, dan deteksi dilakukan ketika lampu lalu lintas berwarna merah. Selama 5 detik terakhir dari durasi lampu merah, sistem merekam video dari CCTV dan menghitung jumlah kendaraan yang terdeteksi. YOLOv4, sebuah algoritma deteksi objek yang cepat dan akurat, digunakan untuk mengidentifikasi berbagai jenis kendaraan.

Berikutnya, sistem menentukan durasi lampu hijau berdasarkan jumlah kendaraan yang terdeteksi. Durasi ini dihitung dengan mengalikan jumlah kendaraan (x) dengan 1 detik. Misalnya, jika 5 kendaraan terdeteksi, lampu hijau akan tetap menyala selama 5 detik. Langkah ini bertujuan untuk menyesuaikan durasi lampu hijau sesuai dengan volume lalu lintas, sehingga mengurangi kemacetan.

Jika tidak ada kendaraan ($x = 0$) yang terdeteksi, sistem akan membiarkan lampu merah dalam mode standby. Sebaliknya, jika kendaraan ($x > 0$) terdeteksi, sistem akan mengaktifkan lampu hijau selama durasi yang telah ditentukan berdasarkan jumlah kendaraan, memastikan bahwa kendaraan dapat melintasi persimpangan dengan lancar.

Selama fase lampu hijau, sistem akan membiarkan kendaraan melewati selama durasi yang telah ditentukan. Sistem akan terus memantau lalu lintas untuk memastikan bahwa semua kendaraan memiliki waktu yang cukup untuk melintas.

Setelah lampu hijau, sistem akan menyalakan lampu kuning selama 5 detik. Lampu kuning berfungsi sebagai peringatan kepada pengemudi bahwa lampu akan segera berubah menjadi merah, memberi mereka waktu untuk bersiap berhenti.


Lampu kuning akan menyala selama 5 detik sebagai sinyal peringatan, memungkinkan pengemudi untuk memperlambat laju dan bersiap untuk berhenti.

Setelah fase lampu kuning, lampu merah akan menyala kembali, memberi isyarat kepada kendaraan untuk berhenti. Sistem akan tetap dalam mode siaga untuk mendeteksi jumlah kendaraan selama periode lampu merah. Selama waktu ini, sistem akan kembali ke langkah awal untuk menghitung kendaraan yang terdeteksi baru.

4.4. Sistem Simulasi Pengontrolan Lampu lalu Lintas

Tahap terakhir dalam alur penelitian ini melibatkan pengiriman informasi tentang durasi lampu hijau yang telah dihitung ke sistem lampu lalu lintas yang cerdas. Sistem lampu lalu lintas ini dirancang untuk menyesuaikan durasi lampu hijau berdasarkan data yang diterima dari algoritma YOLOv4, memungkinkan manajemen lalu lintas yang lebih efektif dan efisien. Lampu lalu lintas akan berubah secara dinamis sesuai dengan jumlah kendaraan yang terdeteksi, memastikan bahwa waktu lampu hijau yang diberikan cukup untuk mengosongkan antrian kendaraan yang ada.

Durasi lampu hijau yang telah dihitung akan ditampilkan dalam simulasi lampu lalu lintas untuk persimpangan empat arah, dengan urutan bergantian dari jalan 1 (kiri) ke jalan 2 (atas), kemudian ke jalan 3 (kanan), dan akhirnya ke jalan 4 (bawah). Lampu lalu lintas di setiap jalan akan menyala sesuai dengan durasi yang dihitung. Proses ini akan terus berulang dari jalan 4 (bawah) kembali ke jalan 1 (kiri). Gambar 10 menunjukkan tampilan simulasi lampu lalu lintas.



Gambar 10. Tampilan Sistem Simulasi Pengontrolan Lampu Lalu Lintas

4.5. Evaluasi Kinerja

4.5.1. Pengujian Akurasi Deteksi Kendaraan YOLOv4

Parameter pertama yang akan dianalisis adalah uji akurasi dari jumlah kendaraan yang terdeteksi. Akurasi adalah metrik kinerja untuk input video, yang mengukur seberapa dekat objek yang terdeteksi seperti mobil, sepeda motor, truk, dan bus dalam video dengan data objek sebenarnya. Akurasi dapat dihitung menggunakan Persamaan 1.

$$A = \frac{T}{N} \times 100\% \quad (1)$$

(A) adalah tingkat akurasi. (T) adalah bentuk objek yang terdeteksi oleh model. (N) adalah data objek yang sebenarnya.

Data video CCTV yang dimasukkan akan diuji untuk akurasi jumlah kendaraan yang terdeteksi menggunakan lima putaran lampu lalu lintas, di mana setiap putaran lampu lalu lintas melibatkan empat jalan untuk menguji hasil jumlah kendaraan yang terdeteksi. Objek yang terdeteksi untuk perhitungan kendaraan meliputi mobil, sepeda motor, truk, dan bus. Berikut data jumlah objek kendaraan yang sebenarnya dapat dilihat pada Tabel 1.

Tabel 1. Jumlah objek Kendaraan Sebenarnya

Jalan	Putaran Ke-1		Putaran Ke-2		Putaran Ke-3		Putaran Ke-4		Putaran Ke-5	
	OS	OT	OS	OT	OS	OT	OS	OT	OS	OT
1	18	-	13	-	9	-	17	-	16	-
2	11	-	12	-	11	-	5	-	5	-
3	27	-	21	-	19	-	25	-	24	-
4	13	-	14	-	16	-	7	-	13	-

OS mewakili objek yang sebenarnya dan OT adalah objek yang terdeteksi. OS dan OT digunakan untuk menghitung akurasi.

4.5.2. Pengujian Sistem Pengontrolan Lampu Lalu Lintas

Parameter kedua yang akan dianalisis adalah uji sistem pengendalian lampu lalu lintas. Dalam uji ini, dilakukan perbandingan antara durasi lampu hijau normal dan durasi lampu hijau yang disesuaikan berdasarkan deteksi kendaraan. Perhitungan persentase pengurangan durasi dapat dilakukan menggunakan rumus yang tertera pada persamaan 2.

$$\text{Presentasi Pengurangan} = \left(\frac{\text{Pengurangan Durasi}}{\text{Durasi Normal}} \right) \times 100\% \quad (2)$$

5. HASIL DAN PEMBAHASAN

5.1. Pengujian Akurasi Deteksi Kendaraan YOLOv4

Data video CCTV yang di input akan diuji akurasi jumlah kendaraan yang terdeteksi dilakukan dengan lima putaran, di mana setiap putaran melibatkan empat jalan berbeda untuk menguji hasil perhitungan kendaraan yang terdeteksi. Objek yang dideteksi untuk perhitungan kendaraan meliputi mobil, motor, truk, dan bus. Pengujian akurasi perhitungan kendaraan yang terdeteksi dapat dilihat pada Tabel 2.

Tabel 2. Pengujian Akurasi Deteksi Kendaraan

Jalan	Putaran Ke-1		Putaran Ke-2		Putaran Ke-3		Putaran Ke-4		Putaran Ke-5	
	OS	OT	OS	OT	OS	OT	OS	OT	OS	OT
1	18	10	13	10	9	8	17	10	16	10
2	11	7	12	7	11	8	5	5	5	5
3	27	12	21	13	19	14	25	13	24	9
4	13	6	14	4	16	9	7	6	13	6

Analisis hasil akurasi digunakan untuk mengukur seberapa baik model dalam mendeteksi dan menghitung kendaraan. Sebagaimana terlihat pada Tabel 3.

Tabel 3. Hasil Akurasi Deteksi

Jalan	Putaran Ke-1	Putaran Ke-2	Putaran Ke-3	Putaran Ke-4	Putaran Ke-5	Hasil Rata-Rata
1	55%	76%	88%	58%	62%	68%
2	63%	58%	72%	100%	100%	78%
3	44%	61%	73%	56%	37%	54%
4	46%	28%	56%	85%	46%	52%


Berdasarkan Tabel 3, hasil analisis menunjukkan variasi kinerja model pada empat jalan berbeda, dengan kualitas video, kondisi pencahayaan, dan hambatan visual yang diamati.




Gambar 11. Hasil Deteksi Kendaraan di Jalan 1

Pada Gambar 11, Jalan 1 menunjukkan hasil rata-rata akurasi sebesar 68%. Dengan kualitas video cukup baik, tetapi masih ada beberapa kendaraan tetap tidak terdeteksi akibat hambatan visual, seperti tiang lampu dan pepohonan, yang menghalangi pandangan terhadap objek.

Pada Gambar 12, Jalan 2 menunjukkan hasil rata-rata akurasi sebesar 78%. Jalan 2 menampilkan kinerja terbaik dengan beberapa kondisi lalu lintas pada jalan 2 menampilkan kinerja terbaik mencapai akurasi 100%. Tetapi, masih terdapat beberapa objek sepeda motor yang tidak terdeteksi akibat hambatan visual, seperti sebagian motor yang tertutup sehingga objek tidak terlihat dengan jelas.



Gambar 12. Hasil Deteksi Kendaraan di Jalan 2




Gambar 13. Hasil Deteksi Kendaraan di Jalan 3

Pada Gambar 13, Jalan 3 meskipun memiliki kualitas video yang baik, menunjukkan hasil rata-rata akurasi yang lebih rendah, yaitu 54%. Hal ini mengindikasikan bahwa beberapa kendaraan tidak terdeteksi akibat tumpang tindih objek, yang menyebabkan kendaraan di bagian belakang tidak terlihat dengan jelas.

Pada Gambar 14, Jalan 4 memiliki kualitas video yang kurang baik, menunjukkan hasil rata-rata akurasi terendah sebesar 52%, mengindikasikan bahwa kualitas video yang buruk secara signifikan mempengaruhi kemampuan model dalam mendeteksi kendaraan dengan akurat dan beberapa kendaraan tidak terdeteksi karena kendaraan kecil terhalangi dengan kendaraan yang besar, sehingga kendaraan kecil tidak terlihat.

5.2. Pengujian Sistem Pengontrolan Lampu Lalu Lintas

Dalam pengujian sistem pengontrolan lampu lalu lintas, dilakukan perbandingan antara durasi lampu hijau normal dan durasi lampu hijau yang disesuaikan berdasarkan deteksi kendaraan dalam lima putaran atau siklus lampu lalu lintas. Setiap kendaraan yang terdeteksi menambah 1 detik pada durasi lampu hijau. Durasi lampu hijau standar untuk setiap jalan adalah 30 detik, termasuk untuk Jalan 1, Jalan 2, Jalan 3, dan Jalan 4. Hasil pengurangan durasi lampu hijau dapat dilihat pada Tabel 4.



Gambar 14. Hasil Deteksi Kendaraan di Jalan 4

Tabel 4. Hasil Pengurangan Durasi Lampu Hijau

	Jalan	Durasi Normal	Durasi Deteksi	Pengurangan Durasi	Persentase Pengurangan (%)
Putaran Ke-1	1	30	10	20	66%
	2	30	7	23	76%
	3	30	12	18	60%
	4	30	6	24	80%
Putaran Ke-2	1	30	10	20	66%
	2	30	0	30	100%
	3	30	13	17	56%
	4	30	4	26	86%
Putaran Ke-3	1	30	8	22	73%
	2	30	8	22	73%
	3	30	14	16	53%
	4	30	9	21	70%
Putaran Ke-4	1	30	10	20	66%
	2	30	5	25	83%
	3	30	13	17	56%
	4	30	7	23	76%
Putaran Ke-5	1	30	10	20	66%
	2	30	5	25	83%
	3	30	9	21	70%
	4	30	6	24	80%

Durasi lampu hijau yang berdasarkan deteksi kendaraan menunjukkan pengurangan yang signifikan dari durasi lampu hijau normal di semua skenario dan jalan. Hal ini menunjukkan adanya potensi sistem pengontrolan pengendalian lampu lalu lintas yang lebih efisien yang dapat menyesuaikan dengan kondisi lalu lintas secara real-time, namun hasilnya masih ada beberapa kendaraan yang tidak terdeteksi.

6. KESIMPULAN

Penggunaan YOLOv4 dalam simulasi pengontrolan lampu lalu lintas menunjukkan hasil yang menjanjikan dalam meningkatkan efisiensi durasi lampu hijau berdasarkan jumlah kendaraan

yang terdeteksi, di mana pengurangan durasi lampu hijau mencapai persentase yang relatif tinggi sebesar 53% sampai 86%. Akurasi deteksi kendaraan mencapai rata-rata 78%. Beberapa tantangan, seperti kualitas video, penghalangan objek, dan sudut kamera yang kurang optimal, perlu diatasi untuk meningkatkan akurasi deteksi. Sistem pengontrolan lampu lalu lintas ini lebih efisien untuk lampu lalu lintas dengan tingkat kemacetan rendah hingga sedang. Temuan dari studi ini dapat menjadi dasar untuk pengembangan lebih lanjut sistem pengontrolan lampu lalu lintas berbasis deteksi kendaraan yang lebih efisien dan responsif.

Penelitian lebih lanjut dapat difokuskan pada penggunaan dataset kustom yang lebih besar dan pemanfaatan algoritma deteksi YOLO versi terbaru atau metode pengolahan citra lainnya untuk meningkatkan akurasi dan konsistensi deteksi. Selain itu dapat difokuskan juga pada integrasi algoritma deteksi YOLO dengan sistem fuzzy untuk menciptakan solusi yang lebih holistik dan cerdas dalam manajemen lalu lintas. Eksperimen tambahan dengan variasi parameter fuzzy dan aturan fuzzy yang lebih kompleks juga diharapkan dapat menghasilkan hasil yang lebih optimal. Selain itu, penelitian di masa depan dapat mengeksplorasi penerapan teknologi sensor dan IoT untuk memperkaya data input sistem, serta menyelidiki teknik pembelajaran mesin lainnya untuk meningkatkan kinerja deteksi dan kontrol lalu lintas.

DAFTAR PUSTAKA

- ANINGTIYAS, P.R, SUMIN, A, WIRAWAN, S., 2020. Pembuatan Aplikasi Deteksi Objek Menggunakan TensorFlow Object Detection API dengan Memanfaatkan SSD MobileNet V2 Sebagai Model Pra - Terlatih. *Jurnal Ilmiah Komputasi*, 19(3), pp.421–430.
- BOCHKOVSKIY, A., WANG, C.-Y. and LIAO, H.-Y.M., 2020. YOLOv4: Optimal Speed and Accuracy of Object Detection. [online] (May). Available at: <<http://arxiv.org/abs/2004.10934>> [Diakses 28 Juli 2024].
- CHAUHAN, M.S., SINGH, A., KHEMKA, M., PRATEEK, A. and SEN, R., 2019. Embedded CNN based vehicle classification and counting in non-laned road traffic. *ACM International Conference Proceeding Series*, (January).
- GANDHI, M.M., SOLANKI, D.S., DAPTARDAR, R.S. & BALOORKAR, N.S., 2020. Smart Control of Traffic Light Using Artificial Intelligence. *2020 5th IEEE International Conference on Recent Advances and Innovations in Engineering, ICRAIE 2020 - Proceeding*, 2020.
- HADI, M.I., SILALAH, D.K. & WIBAWA, P.D., 2022. Pengaturan Lampu Lalu Lintas

- Berdasarkan Deteksi Volume Kendaraan Menggunakan Metode YOLOv3 Traffic Light Setting Based On Vehicle Volume Detection Using The YOLOv3 Method. *e-Proceeding of Engineering*, [online] 9(5), pp.2133–2144. Available at: <<https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/18470>> [Diakses 31 Juli 2024].
- ISSA, R. BIN, DAS, M., RAHMAN, M.S., BARUA, M., RHAMAN, M.K., RIPON, K.S.N. & ALAM, M.G.R., 2021. Double deep Q-learning and faster R-CNN-based autonomous vehicle navigation and obstacle avoidance in dynamic environment. *Sensors*, 21(4), pp.1–24.
- MAHTO, P., GARG, P., SETH, P. & PANDA, J., 2020. Refining YOLOv4 for vehicle detection. *International Journal of Advanced Research in Engineering and Technology*, 11(5), pp.409–419.
- MISRA, D., 2020. Mish: A Self Regularized Non-Monotonic Activation Function. *31st British Machine Vision Conference, BMVC 2020*.
- PRATHAP, B.R., KUMAR, K.P., CHOWDARY, C.R. & HUSSAIN, J., 2022. AI-Based YOLO V4 Intelligent Traffic Light Control System. *Journal of Automation, Mobile Robotics and Intelligent Systems*, 16(4), pp.53–61.
- SAHAL, M., HIDAYAT, Z., BILFAQIH, Y., HADY, M.A. & TAMPUBOLON, Y.M.H., 2023. Smart Traffic Light Using YOLO Based Camera with Deep Reinforcement Learning Algorithm. *JAREE (Journal on Advanced Research in Electrical Engineering)*, 7(1), pp.13–19.
- SHUBHO, F.H., IFTEKHAR, F., HOSSAIN, E. & SIDDIQUE, S., 2021. Real-Time traffic monitoring and traffic offense detection using YOLOv4 and OpenCV DNN. *IEEE Region 10 Annual International Conference, Proceedings/TENCON*, 2021-Decem(February 2022), pp.46–51.
- TRAN, T.H.P. & JEON, J.W., 2020. Accurate Real-Time Traffic Light Detection Using YOLOv4. *2020 IEEE International Conference on Consumer Electronics - Asia, ICCE-Asia 2020*, pp.2–5.
- WANG, P., XIAO, J., KAWAGUCHI, K. & WANG, L., 2022a. Automatic Ceiling Damage Detection in Large-Span Structures Based on Computer Vision and Deep Learning. *Sustainability (Switzerland)*, 14(6), pp.1–24.
- WANG, Q., ZHANG, Q., LIANG, X., WANG, Y., ZHOU, C. & MIKULOVICH, V.I., 2022b. Traffic lights detection and recognition method based on the improved yolo v4 algorithm. *Sensors*, 22(1), pp.1–20.
- WANG, R., WANG, Z., XU, Z., WANG, C., LI, Q., ZHANG, Y. & Li, H., 2021. A Real-Time Object Detector for Autonomous Vehicles Based on YOLOv4. *Computational Intelligence and Neuroscience*, 2021.
- YAO, Z., CAO, Y., ZHENG, S., HUANG, G. & LIN, S., 2021. Cross-iteration batch normalization. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp.12326–12335.
- ZHENG, Z., WANG, P., LIU, W., LI, J., YE, R. & REN, D., 2020. Distance-IOU loss: Faster and better learning for bounding box regression. *AAAI 2020 - 34th AAAI Conference on Artificial Intelligence*, (2), pp.12993–13000.
- ZOU, Z., CHEN, K., SHI, Z., GUO, Y. & YE, J., 2023. Object Detection in 20 Years: A Survey. *Proceedings of the IEEE*, 111(3), pp.257–276.