



Optimalisasi Sistem Deteksi Rekomendasi Persimpangan Jalan dalam Kepadatan Lalu Lintas Menggunakan Algoritma YOLO v11

Aziz Nurdiansyah*, Anna Dina Kalifia

Fakultas Sains & Teknologi, Program Studi Informatika, Universitas Teknologi Yogyakarta, Sleman, Indonesia

Email: ^{1,*} azispnd23@email.com, ² ad.kalifia@uty.ac.id

Email Penulis Korespondensi: azispnd23@email.com

Abstrak—Permasalahan krusial yang dihadapi perkotaan modern adalah kemacetan lalu lintas, yang menyebabkan kerugian waktu, ekonomi, dan dampak lingkungan signifikan. Identifikasi kepadatan lalu lintas secara manual terbukti tidak efisien dan rentan kesalahan. Penelitian ini bertujuan untuk merancang dan menguji sistem deteksi kendaraan *real-time* yang tangguh terhadap variabilitas lingkungan serta mampu memberikan prediksi tingkat kepadatan secara akurat, berkontribusi pada transformasi manajemen lalu lintas dari reaktif menjadi prediktif. Sebagai solusi, diusulkan sistem deteksi dan analisis kepadatan lalu lintas berbasis *Deep Learning* menggunakan model YOLOv11 yang dioptimalkan, mengintegrasikan *Image Processing* dan *Neural Network*. YOLOv11 digunakan untuk mendeteksi dan mengklasifikasikan berbagai jenis kendaraan secara akurat dari rekaman video CCTV, bahkan dalam kondisi pencahayaan minim, dan hasilnya menjadi input untuk Modul Kontrol Lalu Lintas Adaptif berbasis *Density Score*. Hasil sementara dari pelatihan model menunjukkan konvergensi yang sangat cepat, mencapai akurasi komprehensif (mAP@) sebesar 0.956 pada *validation set* hanya dalam 10 *epoch*. Meskipun pengujian pada data uji baru menghasilkan mAP@0.5 keseluruhan kelas sebesar 0.631, model menunjukkan kinerja unggul untuk deteksi kendaraan besar, seperti *truck* (mAP@0.5 = 0.962) dan *car* (mAP@0.5 = 0.935). Sistem ini diharapkan dapat memberikan informasi kepadatan lalu lintas yang akurat, memungkinkan pengaturan lampu lalu lintas yang adaptif, dan pada akhirnya, berkontribusi terhadap sistem manajemen lalu lintas cerdas.

Kata Kunci: Kepadatan Lalu Lintas; *Deep Learning*; YOLOv11; Deteksi Objek; *Sistem Lalu Lintas Cerdas*; *Real-Time*

Abstract—The crucial problem facing modern urban areas is traffic congestion, which causes significant time, economic, and environmental losses. Manual identification of traffic density has proven to be inefficient and error-prone, especially at intersections with high real-time density fluctuations. This research aims to design and test a real-time vehicle detection system that is robust against environmental variability and capable of providing accurate predictions of density levels, contributing to the transformation of traffic management from reactive to predictive. As a solution, a traffic density detection and analysis system based on Deep Learning is proposed, utilizing an optimized YOLOv11 model, integrating Image Processing and a Neural Network. YOLOv11 is used to accurately detect and classify various types of vehicles from CCTV video footage, even in low-light conditions, and the results serve as input for the Adaptive Traffic Light Control Module based on the Density. Preliminary results from model training show very fast convergence, achieving a comprehensive accuracy (mAP@0.5) of 0.956 on the validation set in just 10 epochs. Although testing on new test data yielded an overall class mAP@0.5 of 0.631, the model demonstrated superior performance for detecting large vehicles, such as trucks (mAP@0.5 = 0.962) and cars (mAP@0.5 = 0.935). This system is expected to provide accurate traffic density information, enable adaptive traffic light settings, and ultimately contribute to intelligent traffic management systems.

Keywords: Traffic Density; Deep Learning; YOLOv11; Object Detection; Smart System Traffic Light; Real-Time

1. PENDAHULUAN

Pertumbuhan armada otomotif yang terus meningkat berkontribusi langsung terhadap peningkatan polusi akustik dan risiko keselamatan di area urban. Kepadatan lalu lintas bukan sekadar indikator volume, melainkan variabel penentu dalam paparan risiko kecelakaan yang memiliki korelasi langsung dengan frekuensi insiden di jalan raya. Di sisi lain, penurunan volume lalu lintas pada waktu-waktu tertentu justru cenderung memicu peningkatan kecepatan kendaraan yang secara signifikan memperbesar fatalitas cedera bagi pengguna jalan yang rentan, seperti pejalan kaki (Deryabin, 2022). Pertumbuhan eksponensial kendaraan bermotor akibat urbanisasi dan peningkatan ekonomi telah memperburuk kondisi ini, dengan data nasional menunjukkan peningkatan signifikan volume kendaraan yang tidak diimbangi oleh pengembangan jaringan jalan (Pingky et al., 2024).

Sistem pengaturan lalu lintas konvensional berbasis fixed-time terbukti tidak adaptif terhadap fluktuasi kepadatan real-time, sehingga memerlukan pendekatan berbasis *Intelligent Transportation System* (ITS) yang mengintegrasikan *Computer Vision* dan *Deep Learning* untuk deteksi dan pengelolaan arus secara otomatis (Surya & Wahyuni, 2025). Algoritma *You Only Look Once* (YOLO) menjadi arsitektur dominan dalam ITS karena kemampuannya melakukan deteksi, klasifikasi, dan lokalisasi objek dalam satu inferensi, menawarkan kecepatan dan akurasi yang optimal untuk aplikasi real-time (Muttakin & Haryanto, 2024; Wahidin et al., 2025)

Perkembangan YOLO dari versi v3 hingga v11 telah menghasilkan performa deteksi kendaraan yang semakin andal, dengan YOLOv3 mencatat *precision* 99% dan *F1-score* 94% pada kondisi ideal, sementara YOLOv8 meningkatkan *mean Average Precision* (mAP) hingga 82.77% pada CCTV publik (Putra et al., 2024). YOLOv11 bahkan mencapai mAP 0.995 untuk deteksi rambu lalu lintas lokal dan mAP@0.5 0.97 pada kondisi malam hari setelah optimasi *hyperparameter* dan *data augmentation* (Daeli et al., 2024; Homepage & Alfath Zulkarnain, 2025; Pradana et al., 2024). Namun, akurasi penghitungan volume kendaraan tetap bervariasi—antara 56% untuk motor hingga 94% untuk truk—akibat oklusi, frame drop, dan kualitas gambar rendah (Muttakin & Haryanto, 2024). Implementasi YOLOv4 untuk sistem traffic light adaptif melaporkan akurasi deteksi 85% dengan peningkatan signifikan dalam



jumlah kendaraan yang melewati persimpangan per satuan waktu dibandingkan sistem konvensional (Prathap et al., 2022). Sistem traffic light adaptif menggunakan YOLOv4 berhasil mencapai mean Average Precision (mAP) sebesar 86.4%, melampaui performa algoritma R-CNN (71%), Fast R-CNN (75.2%), Faster R-CNN (79.8%), dan SSD (78.2%) (Ottom & Al-Omari, 2023). Formula manajemen waktu yang diusulkan juga berhasil mengurangi waktu tunggu kendaraan sekitar 10% (Ottom & Al-Omari, 2023). Sementara itu, sistem deteksi kendaraan berbasis YOLOv5 yang dioptimalkan dengan algoritma Flip-Mosaic terbukti meningkatkan akurasi deteksi objek kecil pada kondisi oklusi, yang merupakan tantangan umum dalam skenario lalu lintas jalan raya dengan kamera berketinggian 8-12 meter (Zhang et al., 2022).

Meskipun berbagai penelitian telah menunjukkan keberhasilan implementasi algoritma YOLO dalam sistem manajemen lalu lintas, akurasi penghitungan volume kendaraan tetap bervariasi—antara 56% untuk motor hingga 94% untuk truk—akibat oklusi, frame drop, dan kualitas gambar rendah. Penerapan YOLOv4 dalam sistem lampu lalu lintas adaptif berhasil mengurangi durasi lampu hijau hingga 86% pada kepadatan sedang, namun masih menghadapi keterbatasan pada kondisi malam hari, cuaca buruk, atau deteksi objek kecil dengan penurunan recall akibat silau, bayangan, dan kontras rendah (Prathap et al., 2022). Target kendaraan yang berjarak jauh dari kamera cenderung memiliki ukuran yang relatif kecil dalam gambar yang ditangkap, dengan informasi yang terbatas dan gambar yang kabur, sehingga menjadi masalah praktis yang umum dalam bidang deteksi objek (Zhang et al., 2022)

Penerapan YOLOv4 dan YOLOv8 dalam sistem lampu lalu lintas adaptif telah terbukti efektif dengan keberhasilan mengurangi durasi lampu hijau hingga 86% pada kondisi kepadatan sedang. Integrasi algoritma ini dengan metode *Random Forest* juga memungkinkan prediksi kemacetan dengan akurasi mencapai 91,06% berdasarkan variabel volume, kecepatan, dan kondisi jalan. Sejalan dengan hal tersebut, eksplorasi lebih lanjut terhadap algoritma YOLOv8 menggunakan metode *Knowledge Discovery in Databases* (KDD) menunjukkan performa deteksi yang sangat tinggi, dengan nilai *precision* 0,930, *recall* 0,919, serta mAP50 mencapai 0,975. Melalui pelatihan menggunakan dataset dari Roboflow dan observasi langsung, model ini mampu mendeteksi kendaraan secara akurat dalam berbagai kondisi cahaya untuk mengidentifikasi pola kemacetan dan menghitung volume kendaraan secara *real-time*. Implementasi teknologi ini memungkinkan klasifikasi kondisi jalan menjadi "Padat" atau "Lancar", sehingga sangat potensial untuk diintegrasikan ke dalam sistem manajemen lalu lintas cerdas guna mendukung pengambilan kebijakan penanganan kemacetan yang lebih dinamis (Hidayattullah et al., 2025; Huizen, 2024; Wahidin et al., 2025). Meski demikian, deteksi pada kondisi malam hari, cuaca buruk, atau objek kecil seperti traktor masih menjadi tantangan signifikan, dengan penurunan *recall* akibat silau, bayangan, dan kontras rendah (Ariyoga et al., 2021; Marcelleno & Putra, 2025).

Dalam konteks penerapan YOLOv8 untuk sistem pengenalan plat nomor kendaraan, penelitian Anthony et al. (2024) mengembangkan sistem alternatif untuk gerbang otomatis di Indonesia yang menggabungkan YOLOv8 dengan EasyOCR menggunakan kerangka kerja CRISP-DM. Sistem ini memanfaatkan dataset sebanyak 448 gambar plat nomor yang dikumpulkan secara manual dari lingkungan luar dan dibagi menjadi 70% training, 15% validation, dan 15% testing. Model YOLOv8n yang dilatih selama 40 epochs menunjukkan performa sangat baik dengan mAP50-95 sebesar 0,8264, *precision* 0,999, *recall* 0,985, dan mAP (mean) 0,994, sementara eksperimen tambahan menggunakan 100 gambar baru menghasilkan akurasi deteksi sekitar 99% dan akurasi pengenalan teks sekitar 81%. Sistem yang di-deploy menggunakan Flask sebagai framework web ini dapat menghasilkan output "Access Granted" atau "Access Denied" berdasarkan verifikasi plat nomor, menunjukkan potensi signifikan untuk meningkatkan efisiensi sistem gerbang dengan mengurangi waktu tunggu dan ketergantungan pada intervensi manual pengemudi, meskipun masih terdapat keterbatasan OCR dalam mengenali karakter yang mirip seperti "Ø" dengan "O" dan "1" dengan "7" (Anthony et al., 2024).

Penelitian yang dikembangkan menggunakan SC-YOLO, sebuah model deteksi objek yang dioptimalkan untuk mengenali rambu lalu lintas berukuran kecil dengan efisiensi parameter yang tinggi. Model ini mengintegrasikan modul *cross-stage attention* (CSPCA) pada jaringan tulang punggung untuk meningkatkan fokus pada wilayah objek kecil dan menekan informasi latar belakang. Selain itu, penggunaan struktur *dense neck* memungkinkan fusi informasi detail tingkat rendah dan semantik tingkat tinggi secara lebih kuat. Pengujian pada dataset CCTSDB2021 menunjukkan bahwa SC-YOLO mencapai nilai *mean Average Precision* (mAP) sebesar 84,3%, mengungguli model YOLOv5s dan YOLOv7-tiny. Pada dataset TT100K dengan resolusi 1280x1280, model ini meraih mAP tertinggi sebesar 95,2% dengan jumlah parameter paling minimal, yaitu 6,1 juta, serta mampu beroperasi secara *real-time* pada kecepatan 33,7 FPS. Implementasi fungsi kerugian SIOU yang menyertakan informasi arah juga terbukti mempercepat konvergensi dan meningkatkan akurasi model dibandingkan metode tradisional (Shi et al., 2023).

Penelitian terdahulu telah mengimplementasikan YOLOv5 pada perangkat embedded untuk *Advanced Driver Assistance System* (ADAS) dengan akurasi 88.88% dalam mengenali rambu dan lampu lalu lintas (Nugroho & Cahyono, 2022), serta memanfaatkan AI untuk analisis kinerja jalan berdasarkan Pedoman Kapasitas Jalan Indonesia (PKJI), menghasilkan Degree of Saturation (DS) 0.90 dan Level of Service E pada ruas kritis (Suardika et al., 2025). Namun, sebagian besar studi masih terfokus pada deteksi siang hari, dataset terkontrol, atau penghitungan tanpa integrasi prediksi makro, dengan minimnya pengujian di lingkungan urban nyata 24/7 (Krisdianto et al., 2025).

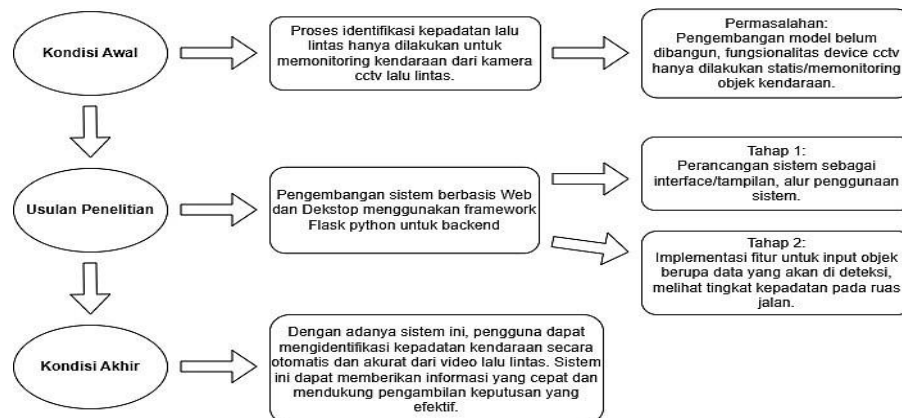
Kebaruan penelitian ini terletak pada pengembangan sistem terintegrasi berbasis YOLOv11 yang dioptimalkan untuk kondisi rendah cahaya melalui hyperparameter tuning dan data augmentation adaptif, serta penggabungan dengan model Random Forest untuk prediksi kemacetan holistik pada simpang empat perkotaan Indonesia—sebuah pendekatan yang belum diuji secara komprehensif dalam literatur sebelumnya yang cenderung terpisah antara deteksi mikro dan analisis makro (Ariyoga et al., 2021).

Penelitian ini bertujuan untuk merancang dan menguji sistem deteksi kendaraan real-time yang tangguh terhadap variabilitas lingkungan serta mampu memberikan prediksi tingkat kepadatan secara akurat, sehingga berkontribusi pada transformasi manajemen lalu lintas dari reaktif menjadi prediktif. Urgensi penelitian ini diperkuat oleh tingginya kerugian ekonomi, polusi, dan angka kecelakaan akibat kemacetan, di mana temuan ini dapat menjadi landasan kebijakan rekayasa lalu lintas berbasis data di Indonesia yang selanjutnya akan diuraikan melalui metodologi, implementasi, dan validasi empiris.

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian

Diagram ini memvisualisasikan alur penelitian untuk pengembangan sistem deteksi kepadatan lalu lintas menggunakan YOLOv11, yang terbagi menjadi beberapa fase utama: Kondisi Awal, Usulan Model, dan Kondisi Akhir, didukung oleh tahapan pengembangan yang terperinci.



Gambar 1. Kerangka Dasar Penelitian

Sebagaimana ditunjukkan pada Gambar 1, penelitian ini diawali dengan pemaparan kondisi awal sistem monitoring lalu lintas yang masih bersifat konvensional. Pada tahap ini, identifikasi kepadatan lalu lintas hanya dilakukan melalui pemantauan visual menggunakan kamera CCTV tanpa adanya proses analisis otomatis. Sistem CCTV berfungsi sebagai alat monitoring pasif yang menampilkan rekaman video lalu lintas, namun belum mampu memberikan informasi kuantitatif terkait jumlah kendaraan maupun tingkat kepadatan pada suatu ruas jalan.

Masih merujuk pada Gambar 1, permasalahan utama yang diidentifikasi pada kondisi awal adalah belum dikembangkannya model analisis berbasis kecerdasan buatan yang terintegrasi dengan perangkat CCTV. Fungsi perangkat CCTV terbatas pada pengawasan statis, sehingga tidak mampu mendeteksi objek kendaraan secara otomatis maupun mendukung pengambilan keputusan secara real-time. Kondisi ini menyebabkan informasi lalu lintas yang dihasilkan kurang optimal untuk kebutuhan manajemen dan rekayasa lalu lintas.

Sebagai solusi atas permasalahan tersebut, bagian Usulan Penelitian pada Gambar 1 menunjukkan pengembangan sistem identifikasi kepadatan lalu lintas berbasis web dan desktop. Sistem ini dirancang menggunakan framework Flask berbasis Python sebagai backend, yang berperan sebagai pengelola alur data, penghubung antara modul deteksi kendaraan, serta penyedia layanan bagi antarmuka pengguna. Pendekatan ini memungkinkan sistem untuk memproses data video lalu lintas secara terstruktur dan terintegrasi.

Tahapan penelitian yang ditunjukkan pada Gambar 1 terdiri atas dua tahap utama. Tahap pertama adalah perancangan sistem, yang mencakup perancangan arsitektur sistem, desain antarmuka pengguna, serta perancangan alur penggunaan sistem. Tahap ini bertujuan untuk memastikan bahwa sistem yang dikembangkan memiliki struktur yang jelas, mudah dioperasikan, dan sesuai dengan kebutuhan pengguna dalam memantau kondisi lalu lintas.

Tahap kedua, sebagaimana ditunjukkan pada Gambar 1, adalah implementasi fitur inti sistem berupa integrasi model deteksi objek kendaraan berbasis deep learning. Pada tahap ini, sistem menerima input berupa video atau citra lalu lintas dari kamera CCTV, kemudian melakukan proses deteksi dan penghitungan jumlah kendaraan pada setiap ruas jalan. Hasil deteksi tersebut selanjutnya dianalisis untuk menentukan tingkat kepadatan lalu lintas secara kuantitatif.

Pada kondisi akhir yang juga digambarkan pada Gambar 1, sistem yang dikembangkan diharapkan mampu melakukan identifikasi kepadatan kendaraan secara otomatis dan akurat. Informasi kepadatan lalu lintas dapat disajikan secara cepat dan real-time, sehingga mendukung pengambilan keputusan yang lebih efektif dalam pengelolaan lalu lintas. Dengan demikian, kerangka penelitian ini menunjukkan alur transformasi dari sistem monitoring lalu lintas konvensional menuju sistem cerdas berbasis kecerdasan buatan yang terintegrasi.

Secara keseluruhan, proyek ini mengatasi identifikasi kepadatan lalu lintas yang awalnya dilakukan secara manual dengan kamera CCTV, yang kurang efisien, rentan error, dan terbatas dalam penyediaan data real-time. Usulan

solusi berupa sistem berbasis web dengan framework Desktop dan Flask Python melibatkan perancangan interface serta implementasi deteksi objek berbasis video untuk pengukuran kepadatan secara otomatis dan akurat. Hasilnya, pengguna seperti pengelola lalu lintas dapat memperoleh informasi cepat dan terperinci dari video CCTV, mendukung pengambilan keputusan yang efektif dan efisien untuk pengelolaan lalu lintas.

Untuk menentukan prioritas alokasi lampu hijau, setiap jalur dihitung *Density Score*-nya (DS). Jalur dengan skor tertinggi akan dialokasikan waktu hijau. Formula ini secara eksplisit memastikan bahwa stagnasi parah (*High Density*) mendapatkan bobot yang lebih signifikan daripada sekadar volume tinggi yang masih mengalir lancar.

$$DS = B + (V \times 0.1) \quad (1)$$

Rumus $DS = B + (V \times 0.1)$ merupakan formula perhitungan *Density Score* Jalur yang digunakan sistem untuk mengkuantifikasi tingkat kepadatan lalu lintas pada setiap jalur persimpangan. Dalam rumus ini, DS (*Density Score* Jalur) merepresentasikan nilai akhir kepadatan yang menjadi acuan pengambilan keputusan prioritas, B adalah Bobot Status Kepadatan yang mencerminkan kategori kondisi lalu lintas saat ini, V adalah Total Kendaraan yang terdeteksi di jalur tersebut, dan 0.1 merupakan Faktor Bobot Skala Volume yang berfungsi untuk menormalisasi kontribusi volume kendaraan agar tidak mendominasi nilai Bobot Status B. Penggunaan faktor 0.1 memastikan bahwa bobot status kepadatan tetap menjadi komponen utama dalam perhitungan, sementara jumlah kendaraan berfungsi sebagai variabel penyesuai yang memberikan diferensiasi lebih halus antar jalur, sehingga sistem dapat menghasilkan keputusan prioritas yang lebih akurat dan responsif terhadap kondisi lalu lintas real-time berdasarkan kombinasi status kepadatan dan volume kendaraan aktual yang terdeteksi.

Mekanisme Keputusan pada setiap permulaan siklus lampu lalu lintas, sistem mengevaluasi semua jalur. Jalur yang dipilih sebagai Prioritas adalah jalur yang memiliki *Density Score* tertinggi di persimpangan. Jalur Prioritas kemudian akan mendapatkan lampu hijau.

2.2 Tahapan Penelitian

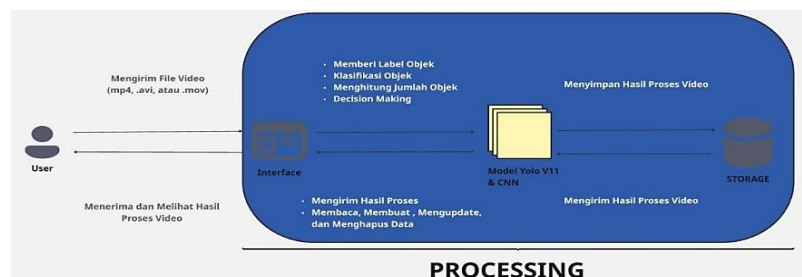
2.2.1 Pengumpulan dan Pra-pemrosesan Data

Tahap awal ini berfokus pada penyiapan data yang bersih dan kaya untuk melatih model. Pengambilan Data Visual sebagai data utama berupa video lalu lintas diambil dari sumber *real-time* seperti CCTV publik di lokasi strategis, untuk mencakup variasi kondisi lalu lintas (pagi, siang, sore, hari kerja, akhir pekan) (Surya & Wahyuni, 2025). Pra-pemrosesan Video dikonversi menjadi *frame* gambar, kemudian diubah ukurannya agar sesuai dengan input model. Proses ini juga melibatkan pembersihan data dari duplikasi. Anotasi dan Augmentasi, setiap kendaraan pada *frame* diberi bounding box dan label kelas (misalnya *Motorcycle, Bus, Truk, Bike, Car, van*). Untuk meningkatkan ketahanan model, terutama pada kondisi sulit seperti pencahayaan rendah, diterapkan augmentasi data (seperti penyesuaian kecerahan, *mosaic, mixup*).

2.2.2 Arsitektur

Model YOLOv11 merupakan pengembangan terbaru dari keluarga YOLO yang dirancang untuk mendukung deteksi objek secara real-time dengan tingkat akurasi dan efisiensi komputasi yang tinggi. Arsitektur model ini secara umum mencakup tiga komponen utama, yaitu Backbone sebagai modul ekstraksi fitur, Neck sebagai penggabung informasi spasial dan kontekstual, serta Head yang berfungsi menghasilkan prediksi akhir. Sejumlah inovasi arsitektural turut disematkan untuk meningkatkan performanya. Salah satunya adalah penerapan *C3k2 Block*, yakni blok arsitektur yang dirancang lebih ringan untuk mempercepat tahap inferensi tanpa mengorbankan akurasi deteksi (Krisdianto et al., 2025).

Modul *C2PSA (Cross Stage Partial Spatial Attention)* diperkenalkan untuk menghadirkan mekanisme perhatian spasial yang memungkinkan model lebih fokus pada area penting dalam citra, sehingga secara signifikan meningkatkan kinerja deteksi khususnya terhadap objek berukuran kecil dan objek yang saling tumpang tindih. Lebih lanjut, YOLOv11 mengadopsi desain *anchor-free* yang menyederhanakan proses deteksi sekaligus mengurangi jumlah parameter model secara substansial dibandingkan dengan generasi sebelumnya (Zulkarnain & Kusri, 2025). Pada tugas segmentasi instansi, varian YOLOv11n-seg juga menawarkan efisiensi tinggi dengan jumlah parameter yang relatif kecil, yakni sekitar 2,8 juta, sehingga ideal untuk penggunaan pada perangkat dengan keterbatasan komputasi (Krisdianto et al., 2025).



Gambar 2. Arsitektur



Sebagaimana ditunjukkan pada Gambar 2, sistem yang dikembangkan menerapkan alur pemrosesan terintegrasi untuk melakukan analisis kepadatan lalu lintas berbasis data video. Proses dimulai dari pengguna (user) yang mengirimkan file video lalu lintas dengan format tertentu, seperti *mp4*, *avi*, atau *mov*, ke dalam sistem melalui antarmuka yang telah disediakan. Tahapan ini berfungsi sebagai sumber data utama yang akan diproses oleh sistem.

Setelah video diterima, data tersebut diproses melalui interface sistem, sebagaimana ditunjukkan pada Gambar 2, yang berperan sebagai penghubung antara pengguna dan modul pemrosesan inti. Interface ini memungkinkan pengguna untuk mengirimkan data video, melihat hasil pemrosesan, serta melakukan pengelolaan data seperti menambah, memperbarui, dan menghapus data. Dengan adanya interface ini, interaksi antara pengguna dan sistem dapat berlangsung secara terstruktur dan mudah dioperasikan.

Selanjutnya, video yang telah diunggah akan diproses oleh modul model deteksi objek, yaitu Model YOLOv11 yang dikombinasikan dengan Convolutional Neural Network (CNN), sebagaimana ditampilkan pada Gambar 2. Pada tahap ini, sistem melakukan beberapa proses utama, antara lain pemberian label objek kendaraan, klasifikasi jenis kendaraan, serta penghitungan jumlah kendaraan yang terdeteksi dalam setiap frame video. Hasil dari proses ini menjadi dasar dalam analisis tingkat kepadatan lalu lintas. Selain proses deteksi dan penghitungan objek, sistem juga melakukan tahap decision making, sebagaimana diilustrasikan pada Gambar 2, yaitu penentuan tingkat kepadatan lalu lintas berdasarkan jumlah kendaraan yang terdeteksi. Proses ini bertujuan untuk mengonversi hasil deteksi objek menjadi informasi yang lebih bermakna dan dapat digunakan sebagai dasar pengambilan keputusan dalam manajemen lalu lintas.

Hasil pemrosesan video kemudian disimpan ke dalam media penyimpanan (storage), sebagaimana ditunjukkan pada Gambar 2. Data yang disimpan mencakup hasil video yang telah dianalisis, informasi jumlah kendaraan, serta label kepadatan lalu lintas. Penyimpanan ini memungkinkan data hasil analisis untuk diakses kembali oleh pengguna, baik untuk keperluan pemantauan lanjutan maupun analisis historis.

Hasil akhir, sistem mengirimkan kembali hasil proses video kepada pengguna melalui interface, sebagaimana diperlihatkan pada Gambar 2. Pengguna dapat menerima dan melihat hasil analisis dalam bentuk visualisasi atau informasi kepadatan lalu lintas yang telah diolah secara otomatis oleh sistem. Dengan alur pemrosesan tersebut, sistem mampu menyediakan informasi kepadatan lalu lintas secara efisien dan terintegrasi.

2.2.3 Pelatihan Model

Proses pelatihan model dilakukan menggunakan arsitektur YOLOv11s dengan parameter teknis yang mencakup resolusi citra masukan 640 x 640 piksel, durasi 10 *epoch*, dan ukuran *batch* 16 unit. Untuk memperkuat generalisasi model dalam skenario lalu lintas yang dinamis, diterapkan teknik augmentasi data *Mosaic* serta optimasi otomatis (*auto-optimizer*). Pengelolaan dataset dilakukan dengan skema pembagian data standar industri, di mana porsi terbesar dialokasikan untuk fase *training* (70-80%) guna memastikan ekstraksi fitur yang mendalam, sementara sisanya dibagi untuk validasi dan pengujian akhir guna memverifikasi keandalan generalisasi model secara menyeluruh. Berdasarkan hasil eksperimen, model menunjukkan perkembangan performa yang positif meskipun terdapat tantangan berupa ketidakseimbangan distribusi data, khususnya pada dominasi kelas *car*. Penurunan nilai *Box Loss* dan *Classification Loss* secara konsisten pada data pelatihan dan validasi mengindikasikan kemampuan adaptasi model yang cepat dalam meregresi koordinat objek. Pada akhir iterasi, model berhasil mencapai nilai *mean Average Precision* (mAP50) yang stabil pada rentang 0,65 hingga 0,70. Meskipun presisi pada kelas mobil dan bus sangat tinggi, evaluasi visual menunjukkan adanya ambiguitas klasifikasi antara truk dan bus akibat kemiripan morfologis, serta kendala dalam mendeteksi objek berskala kecil.

2.3 Metodologi Kontrol Lalu Lintas Adaptif

Hasil deteksi objek *real-time* dari model YOLOv11 digunakan sebagai input primer untuk modul pengambilan keputusan cerdas pada sistem *Traffic Sense AI* yang diusulkan. Modul ini bertanggung jawab untuk menentukan alokasi waktu lampu hijau secara dinamis berdasarkan tingkat kepadatan di setiap jalur persimpangan.

Keputusan alokasi lampu hijau pada persimpangan tunggal (*Single-Junction Control*) didasarkan pada logika adaptif yang memprioritaskan jalur dengan tingkat kepadatan dan stagnasi tertinggi. Kriteria ini diukur melalui metrik *Density Score* yang menggabungkan data volume kendaraan (*total_vehicles*) dan kecepatan rata-rata (*speed*) yang diperoleh secara *real-time* dari deteksi YOLOv11. Tingkat keparahan lalu lintas di setiap jalur diklasifikasikan berdasarkan ambang batas (*threshold*) ganda pada volume kendaraan (V) dan kecepatan rata-rata (S). Klasifikasi status ini esensial karena membedakan antara volume tinggi yang masih mengalir lancar (*Medium*) dengan kondisi stagnasi atau macet total (*High*). Klasifikasi ini disajikan pada Tabel 1.

Tabel 1. Kriteria Kepadatan

Status Kepadatan	Total Kendaraan (V)	Kecepatan Rata-rata (S)	Bobot Prioritas (B)
<i>Low</i> (Lancar)	< 4 unit	>30~km/h	1
<i>Medium</i> (Padat)	5 hingga 8 unit	20 hingga 29~km/h	2
<i>High</i> (Macet/Stagnasi)	10 > unit	19~km/h	3

Tabel 1 menyajikan basis pengetahuan (knowledge base) atau kriteria tingkat kepadatan yang menjadi landasan sistem dalam mengambil keputusan prioritas pengaturan lalu lintas pada setiap jalur persimpangan. Tabel ini

mengintegrasikan tiga parameter utama yang digunakan sebagai kriteria penilaian, yaitu Status Kepadatan, Total Kendaraan (V), dan Kecepatan Rata-rata (S), yang kemudian dipetakan ke dalam nilai Bobot Prioritas (B).

Berdasarkan Tabel 1, sistem mengklasifikasikan status kepadatan lalu lintas ke dalam tiga kategori. Kategori pertama adalah *Low* (Lancar), yang didefinisikan ketika total kendaraan kurang dari 4 unit dengan kecepatan rata-rata mencapai 30-1 km/h. Kondisi ini mengindikasikan lalu lintas yang sangat lancar dengan volume kendaraan rendah dan mobilitas tinggi, sehingga diberikan bobot prioritas terendah yaitu 1, sebagaimana tertera pada baris pertama Tabel 1. Pemberian bobot prioritas 1 menunjukkan bahwa jalur dengan kondisi lancar tidak memerlukan alokasi waktu hijau lampu lalu lintas yang lebih panjang karena tidak mengalami penumpukan kendaraan.

Kategori kedua pada Tabel 1 adalah *Medium* (Padat), yang terjadi ketika jumlah kendaraan berada pada rentang 5 hingga 8 unit dengan kecepatan rata-rata menurun menjadi 20 hingga 29 km/h. Kondisi ini mencerminkan kepadatan lalu lintas tingkat menengah di mana mulai terjadi perlambatan arus kendaraan akibat peningkatan volume. Sebagaimana ditunjukkan pada baris kedua Tabel 1, kondisi ini diberikan bobot prioritas 2, yang mengindikasikan bahwa jalur tersebut memerlukan perhatian lebih dibandingkan jalur dengan status lancar, namun belum mencapai tingkat kritis yang membutuhkan intervensi maksimal.

Kategori ketiga yang tercantum pada baris ketiga Tabel 1 adalah *High* (Macet/Sangat Padat), yang didefinisikan ketika total kendaraan mencapai 10 unit atau lebih dengan kecepatan rata-rata yang sangat rendah, yaitu 1 hingga 19 km/h. Kondisi ini merepresentasikan kemacetan signifikan di mana terjadi penumpukan kendaraan yang padat dan mobilitas sangat terbatas. Oleh karena itu, sistem memberikan bobot prioritas tertinggi yaitu 3, yang berarti jalur dengan kondisi ini akan diprioritaskan untuk mendapatkan alokasi waktu sinyal hijau lebih lama guna mengurangi antrian dan memperlancar arus lalu lintas.

Implementasi Tabel 1 dalam sistem kerja secara keseluruhan dilakukan melalui proses evaluasi real-time terhadap data yang diperoleh dari hasil deteksi objek YOLOv11. Sistem secara kontinyu menghitung total kendaraan dan kecepatan rata-rata pada setiap jalur, kemudian mencocokkan nilai-nilai tersebut dengan kriteria yang terdefinisi pada Tabel 1 untuk menentukan status kepadatan dan bobot prioritas yang sesuai. Berdasarkan bobot prioritas dari keempat jalur persimpangan (Utara, Selatan, Timur, dan Barat), sistem akan membandingkan nilai-nilai tersebut dan memberikan sinyal hijau lebih dahulu kepada jalur dengan bobot prioritas tertinggi. Dengan demikian, Tabel 1 berfungsi sebagai rule-based system yang mentransformasikan data kuantitatif hasil deteksi menjadi keputusan operasional dalam pengaturan traffic light secara adaptif dan responsif terhadap kondisi lalu lintas aktual.

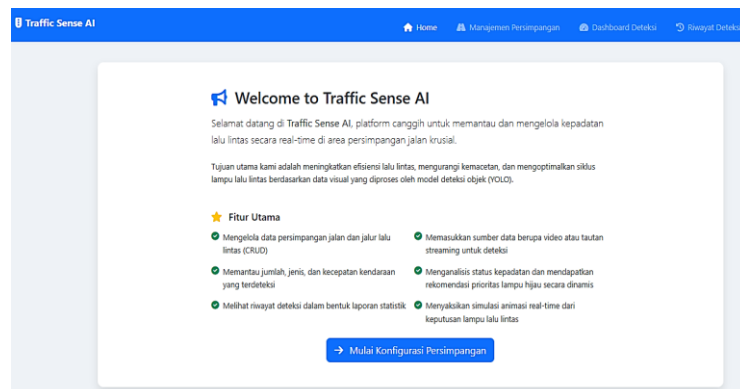
3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan secara terperinci hasil implementasi model deteksi objek YOLOv11 yang telah dioptimalkan, analisis kinerja model berdasarkan metrik standar *Deep Learning*, dan implementasi mekanisme kontrol lalu lintas adaptif yang diusulkan. Hasil pengujian dan analisis pembahasan disajikan dengan mengaitkan temuan empiris dengan landasan teoritis dan kajian literatur terkini, yang secara eksplisit mengeksplorasi kontribusi dan kebaruan penelitian ini terhadap sistem manajemen lalu lintas cerdas.

3.1 Implementasi Program

3.1.1 Halaman Pertama

Traffic Sense AI adalah platform canggih yang dirancang untuk memantau dan mengelola kepadatan lalu lintas secara *real-time* di persimpangan jalan krusial, dengan tujuan utama meningkatkan efisiensi, mengurangi kemacetan, dan mengoptimalkan siklus lampu lalu lintas berdasarkan data visual yang diproses oleh model deteksi objek (YOLO). Platform ini menyediakan serangkaian fitur inti yang memungkinkan pengguna mengelola data persimpangan, memasukkan sumber video atau *streaming* untuk deteksi, memantau jumlah dan jenis kendaraan, menganalisis status kepadatan dan mendapatkan rekomendasi prioritas lampu hijau secara dinamis, serta menyajikan riwayat deteksi dalam bentuk laporan statistik dan simulasi animasi *real-time* dari setiap keputusan lalu lintas.



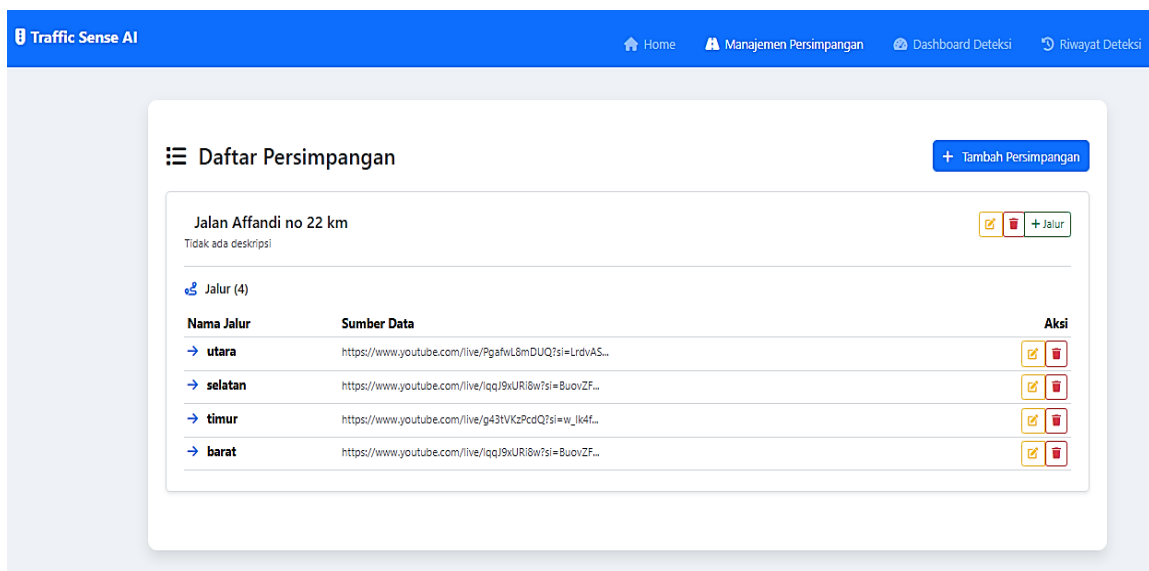
Gambar 3. Tampilan Home

Sebagaimana ditunjukkan pada Gambar 3, Tampilan Homemerupakan titik awal interaksi antara pengguna dan sistem Traffic Sense AI. Halaman ini menampilkan informasi pengantar mengenai tujuan dan fungsi utama sistem, yaitu memantau serta mengelola kepadatan lalu lintas pada area persimpangan jalan secara cerdas. Informasi yang disajikan pada halaman ini memberikan gambaran umum kepada pengguna mengenai kemampuan sistem dalam meningkatkan efisiensi lalu lintas, mengurangi kemacetan, serta mengoptimalkan pengambilan keputusan berbasis data hasil deteksi objek kendaraan.

Gambar 3, sistem menampilkan daftar fitur utama yang mencakup identifikasi dan pemantauan kondisi lalu lintas secara real-time, penghitungan jumlah dan jenis kendaraan, analisis tingkat kepadatan, serta penyajian data dalam bentuk laporan statistik. Tombol *Mulai Konfigurasi Persimpangan* disediakan sebagai navigasi utama untuk mengarahkan pengguna ke tahap pengelolaan data persimpangan, yang merupakan bagian penting dalam alur kerja sistem sebagaimana dijelaskan pada Gambar 2.

3.1.2 Manajemen

Halaman "Daftar Persimpangan" adalah antarmuka utama di platform Traffic Sense AI untuk mengelola lokasi persimpangan yang dipantau, di mana pengguna dapat menambahkan, mengedit, atau menghapus persimpangan (seperti "Jalan Affandi no 22 km") serta mengonfigurasi jalur atau arah (seperti utara, selatan, timur, dan barat) dari persimpangan tersebut. Intinya, halaman ini berfungsi untuk memetakan setiap jalur lalu lintas dengan sumber data streaming video (contohnya dari YouTube Live) yang akan digunakan oleh sistem AI untuk mendeteksi kendaraan secara real-time.



Gambar 4. Input Data

Pada Gambar 4 ditunjukkan tampilan halaman *Manajemen Persimpangan*, yang berfungsi sebagai pusat pengelolaan data lokasi pemantauan lalu lintas. Halaman ini menampilkan daftar persimpangan yang telah terdaftar dalam sistem, lengkap dengan informasi ruas jalan dan jalur pemantauan, seperti jalur utara, selatan, timur, dan barat. Setiap jalur dikaitkan dengan sumber data video yang berasal dari kamera CCTV atau video streaming.

Sebagaimana terlihat pada Gambar 4, sistem menyediakan fitur *tambah, ubah, dan hapus persimpangan*, yang memungkinkan pengguna melakukan pengelolaan data secara dinamis. Fitur ini menunjukkan bahwa sistem tidak hanya berfungsi sebagai alat analisis, tetapi juga sebagai sistem manajemen data yang fleksibel. Data persimpangan yang dikelola pada tahap ini menjadi input utama bagi proses pemrosesan video dan analisis kepadatan, sebagaimana dijelaskan dalam alur pemrosesan pada Gambar 2.

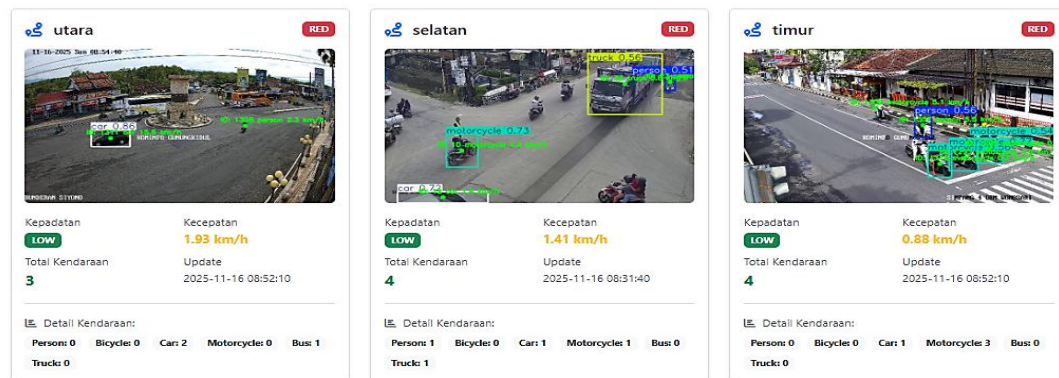
3.1.3 Monitoring

Halaman "Status Deteksi Real-time" menyajikan dashboard pemantauan live yang menampilkan hasil analisis kecerdasan buatan (AI) terhadap lalu lintas di persimpangan "Jalan Affandi no 22 km", dengan data yang diperbarui setiap 5 detik. Intinya, halaman ini menampilkan empat feed video secara bersamaan (utara, selatan, barat, timur) lengkap dengan indikator lampu lalu lintas saat ini (Merah/Hijau), visualisasi kotak deteksi YOLO pada kendaraan, serta metrik utama seperti tingkat Kepadatan (LOW/MODERATE), Kecepatan rata-rata, dan Total Kendaraan yang terdeteksi di setiap jalur, memungkinkan pemantauan kondisi lalu lintas secara langsung dan dinamis.

Status Deteksi Real-time

Data diperbarui setiap 5 detik sesuai siklus lampu lalu lintas di backend.

Jalan Affandi no 22 km



Gambar 5. Tampilan Monitoring

Gambar 5 memperlihatkan halaman *Status Deteksi Real-time*, yang merupakan implementasi langsung dari proses analisis video lalu lintas berbasis deep learning. Pada halaman ini, sistem menampilkan hasil deteksi kendaraan secara visual dalam bentuk *bounding box* dan label objek pada setiap jalur persimpangan. Informasi ini merupakan hasil pemrosesan model deteksi objek YOLOv11 yang telah dijelaskan pada Gambar 2.

Masih mengacu pada Gambar 5, setiap tampilan jalur dilengkapi dengan informasi kuantitatif, seperti tingkat kepadatan lalu lintas, kecepatan kendaraan, total jumlah kendaraan, serta waktu pembaruan data. Informasi tersebut disajikan secara real-time dan diperbarui secara periodik, sehingga pengguna dapat memantau kondisi lalu lintas secara aktual.

Selain itu, Gambar 5 juga menampilkan rincian jumlah kendaraan berdasarkan jenis, seperti sepeda motor, mobil, dan bus. Penyajian data ini mendukung proses analisis yang lebih mendalam terhadap komposisi lalu lintas pada setiap jalur. Dengan adanya visualisasi dan data numerik yang terintegrasi, sistem mampu menyajikan informasi kepadatan lalu lintas secara komprehensif dan mudah dipahami oleh pengguna.



Gambar 6. Tampilan Monitoring

Gambar 6 memperlihatkan halaman Detail Kendaraan Terdeteksi, yang merupakan kelanjutan dari proses deteksi real-time yang telah dijelaskan pada Gambar 5. Halaman ini menyajikan informasi spesifik mengenai satu objek kendaraan yang telah berhasil diidentifikasi oleh sistem, dalam hal ini adalah kendaraan dengan ID "barat" yang terdeteksi sebagai sepeda motor (motorcycle).

Pada bagian atas halaman, ditampilkan cuplikan visual dari frame deteksi yang menunjukkan lokasi kendaraan dalam konteks persimpangan lalu lintas. Visualisasi ini dilengkapi dengan bounding box berwarna yang menandai posisi kendaraan yang sedang dipantau, serta objek-objek kendaraan lain di sekitarnya yang turut terdeteksi oleh model YOLOv11. Penyajian visual ini membantu pengguna memahami konteks spasial dari kendaraan yang sedang dianalisis.

Sistem menyajikan metadata terstruktur mengenai kendaraan tersebut, meliputi klasifikasi jenis kendaraan, tingkat keyakinan deteksi (confidence score 0.6 atau 60%), serta informasi temporal berupa waktu update terakhir (2025-11-16 08:51:43). Informasi ini menunjukkan bahwa sistem tidak hanya mampu mendeteksi keberadaan objek, tetapi juga memberikan penilaian kuantitatif terhadap akurasi deteksi yang dilakukan.



Selain itu, pada bagian bawah halaman terdapat daftar kategori kendaraan lain yang juga terdeteksi dalam frame yang sama, seperti *Person 1*, *Bicycle 1*, *Car 2*, *Motorcycle 2*, dan *Bus 2*. Fitur ini mengindikasikan bahwa sistem mampu melakukan deteksi multi-objek secara simultan dan menyimpan riwayat deteksi untuk keperluan analisis lebih lanjut. Dengan demikian, halaman ini berfungsi sebagai antarmuka untuk inspeksi detail hasil deteksi, yang mendukung proses verifikasi dan evaluasi performa sistem deteksi objek secara menyeluruh.

3.2 Mekanisme Keputusan

Mekanisme Keputusan pada setiap permulaan siklus lampu lalu lintas, sistem mengevaluasi semua jalur. Jalur yang dipilih sebagai Prioritas adalah jalur yang memiliki *Density Score* tertinggi di persimpangan. Jalur Prioritas kemudian akan mendapatkan lampu hijau.

3.2.1 Jalur Utara

Berdasarkan data real-time, Jalur Utara terdeteksi memiliki total kendaraan sebesar 3 unit dan kecepatan rata-rata 1,93 km/jam. Mengacu pada aturan klasifikasi, volume kendaraan dengan nilai ($V \leq 4$) berada pada kategori low, sedangkan kecepatan ($S \leq 19$) km/jam juga termasuk ke dalam kategori low. Meskipun kecepatan sangat rendah dapat mengindikasikan potensi stagnasi kecil, sistem tetap memprioritaskan klasifikasi berdasarkan keluaran utama, yaitu LOW, sehingga bobot yang diberikan adalah ($B = 1$). Perhitungan nilai *Density Score* (DS) dilakukan menggunakan persamaan 1:

$$DS = B + (V \times 0.1) = 1 + (3 \times 0.1) = 1 + 0.3 = 1.3$$

Hasil ini menghasilkan keputusan bahwa status lampu untuk Jalur Utara adalah merah (RED). Nilai DS sebesar 1,3 menunjukkan bahwa Jalur Utara memiliki tingkat kepadatan terendah dibandingkan jalur lainnya, sehingga tidak memerlukan alokasi waktu sinyal hijau dalam siklus ini. Keputusan sistem untuk menetapkan status merah pada jalur ini mencerminkan efisiensi dalam manajemen lalu lintas, di mana jalur dengan kondisi relatif lancar dan volume rendah dapat ditunda prioritasnya untuk memberikan kesempatan kepada jalur yang mengalami kepadatan lebih tinggi. Pendekatan ini memastikan bahwa sumber daya waktu sinyal hijau dialokasikan secara optimal kepada jalur yang paling membutuhkan.

3.2.2 Jalur Selatan

Pada Jalur Selatan, sistem mendeteksi 4 unit kendaraan dengan kecepatan 1,41 km/jam. Nilai volume $V = 4$ dan kecepatan 1,41 km/jam sama-sama masuk dalam kategori low. Sebagaimana jalur sebelumnya, sistem mengklasifikasikan kondisi ini sebagai LOW, sehingga bobot yang ditetapkan adalah $B = 1$. *Density Score* dihitung dengan persamaan 1:

$$DS = B + (V \times 0.1) = 1 + (4 \times 0.1) = 1 + 0.4 = 1.4$$

Dengan nilai DS sebesar 1,4, sistem menentukan bahwa status lampu untuk Jalur Selatan adalah merah (RED). Meskipun Jalur Selatan memiliki nilai DS sedikit lebih tinggi dibandingkan Jalur Utara (1,4 vs 1,3), perbedaan ini tidak cukup signifikan untuk mengubah prioritas karena kedua jalur masih berada dalam kategori kepadatan rendah. Sistem adaptif menunjukkan kemampuannya dalam melakukan diferensiasi halus antar jalur dengan kondisi serupa melalui komponen volume pada formula DS. Namun, karena tidak ada jalur yang mengalami kemacetan kritis, penetapan status merah pada Jalur Selatan merupakan keputusan yang rasional dan mendukung efisiensi operasional persimpangan secara keseluruhan.

3.2.3 Jalur Timur

Jalur Timur menunjukkan total kendaraan sebanyak 4 unit dengan kecepatan yang sangat rendah, yaitu 0,88 km/jam. Dengan volume $V = 4$ dan kecepatan 0,88 km/jam, kedua parameter berada pada kategori low. Sistem juga memberikan keluaran klasifikasi LOW, sehingga bobot ditetapkan pada nilai $B = 1$. Perhitungan DS dilakukan sebagai berikut:

$$DS = B + (V \times 0.1) = 1 + (4 \times 0.1) = 1 + 0.4 = 1.4$$

Hasil ini menyebabkan Jalur Timur tetap berada pada status merah (RED). Nilai DS sebesar 1,4 menempatkan Jalur Timur pada posisi yang sama dengan Jalur Selatan, namun masih jauh di bawah Jalur Barat yang memiliki DS = 2,9. Menariknya, meskipun Jalur Timur memiliki kecepatan terendah (0,88 km/jam) di antara ketiga jalur dengan status merah, volume kendaraan yang rendah (4 unit) membuat sistem tetap mengklasifikasikan kondisi ini sebagai LOW. Hal ini mendemonstrasikan bahwa sistem tidak hanya mengandalkan satu parameter tunggal dalam pengambilan keputusan, melainkan mempertimbangkan kombinasi volume dan kecepatan secara holistik, sehingga menghasilkan penilaian yang lebih akurat terhadap tingkat kepadatan aktual.

3.2.4 Jalur Barat

Jalur Barat memiliki karakteristik berbeda dibandingkan tiga jalur lainnya. Data real-time menunjukkan adanya 9 unit kendaraan dengan kecepatan rata-rata 0,6 km/jam. Berdasarkan aturan sistem, volume $V = 9$ unit masuk ke dalam kategori medium, sedangkan kecepatan 0,6 km/jam termasuk kategori high karena menunjukkan perlambatan ekstrem.


Dalam mekanisme Dual-Threshold, sistem menentukan prioritas berdasarkan kategori yang lebih parah. Pada kasus ini, meskipun volume berada pada tingkat medium, kecepatan yang sangat rendah menunjukkan kondisi kepadatan yang lebih serius. Namun, sesuai keluaran sistem yang menetapkan kategori MEDIUM, maka bobot yang digunakan adalah $B = 2$. Perhitungan DS untuk jalur ini adalah sebagai berikut:

$$DS = B + (V \times 0.1) = 2 + (9 \times 0.1) = 2 + 0.9 = 2.9$$

Nilai DS tertinggi sebesar 2,9 menjadikan Jalur Barat memperoleh prioritas dan ditetapkan dalam kondisi hijau (GREEN). Keputusan sistem ini sangat mencerminkan efektivitas pendekatan adaptif dalam manajemen lalu lintas. Dengan DS yang secara signifikan lebih tinggi dibandingkan jalur lainnya (hampir dua kali lipat dari jalur-jalur dengan status merah), Jalur Barat jelas merupakan titik kritis yang memerlukan intervensi segera. Kombinasi volume kendaraan yang relatif tinggi (9 unit) dan kecepatan ekstrem rendah (0,6 km/jam) mengindikasikan kondisi stagnasi parah yang, jika tidak segera ditangani, dapat menyebabkan propagasi kemacetan ke area sekitarnya. Sistem adaptif berhasil mengidentifikasi anomali ini dan secara otomatis mengalokasikan prioritas sinyal hijau, memungkinkan dispersi antrian kendaraan dan peningkatan throughput pada jalur tersebut. Responsivitas sistem terhadap kondisi dinamis ini menunjukkan keunggulan signifikan dibandingkan sistem traffic light konvensional dengan siklus tetap, yang tidak mampu menyesuaikan diri dengan variasi kepadatan real-time dan berpotensi memperburuk kondisi kemacetan pada jalur-jalur kritis seperti Jalur Barat.

3.3 Hasil Pengujian


Model yang telah dilatih harus diuji secara ketat untuk memverifikasi keandalannya menggunakan data uji baru dan dievaluasi berdasarkan metrik standar *object detection*: *Recall – Confidence Curve*, *Confusion Matrix*, *Precision* (ketepatan prediksi), *Recall* (kelengkapan deteksi), dan *mAP* (*mean Average Precision*). Berikut merupakan perbandingan Hasil Pengujian dari model algoritma Yolo versi 11 dengan versi model lainnya:



Gambar 7. Recall - Confidence Curve

Pada Gambar 8, kurva *all classes* (garis tebal biru) menunjukkan bahwa secara keseluruhan model mampu mempertahankan *Recall* yang tinggi (sekitar 0.82) pada *Confidence Threshold* yang sangat rendah. Namun, seiring peningkatan *Confidence Threshold* di atas 0.6, *Recall* mulai menurun drastis, yang berarti model menjadi lebih konservatif dalam membuat prediksi yang *confident*, tetapi berpotensi melewatkan beberapa objek yang terdeteksi dengan keyakinan rendah. Gambar 7 menampilkan Recall-Confidence Curve yang merepresentasikan kemampuan model dalam mendeteksi seluruh objek yang sebenarnya ada (*true positive rate*) pada berbagai tingkat *threshold confidence*. Kurva berwarna biru tebal yang merepresentasikan "all classes" dengan nilai 0.92 at 0.100 menunjukkan bahwa model mampu mencapai recall sebesar 92% ketika *threshold confidence* ditetapkan pada 0.1. Pola penurunan recall yang bertahap seiring meningkatnya *threshold confidence* mengindikasikan trade-off yang wajar antara sensitivitas deteksi dan keyakinan prediksi—semakin tinggi *threshold confidence* yang ditetapkan, semakin sedikit objek yang terdeteksi karena model hanya menerima prediksi dengan keyakinan tinggi.

Kelas-kelas tertentu seperti "bus" (garis merah) dan "car" (garis oranye) mempertahankan recall yang tinggi bahkan pada *threshold confidence* yang lebih tinggi, yang mengindikasikan bahwa model memiliki kepercayaan yang konsisten dalam mendeteksi objek-objek dari kelas tersebut. Sebaliknya, kelas "truck" (garis ungu muda) menunjukkan penurunan recall yang lebih cepat, terutama pada *confidence level* di atas 0.4, yang menandakan bahwa model kurang konsisten dalam mendeteksi kendaraan jenis truk dengan tingkat keyakinan tinggi. Hal ini dapat disebabkan oleh variasi bentuk dan ukuran truk yang lebih beragam dalam dataset atau jumlah sampel truk yang lebih sedikit dibandingkan kelas lainnya. Pola kurva pada Gambar 7 juga menunjukkan bahwa penetapan *threshold confidence* pada rentang 0.3-0.5 dapat memberikan keseimbangan optimal antara recall dan precision untuk sebagian besar kelas kendaraan.




Gambar 8. Precision - Condition Curve

Sebaliknya, Gambar 9 menunjukkan *Precision* (kemampuan model untuk tidak membuat deteksi palsu) yang lebih stabil. Kurva *all classes* mencapai nilai puncaknya (sekitar 0.86) pada *Confidence Threshold* sekitar 0.85. Analisis per kelas menunjukkan bahwa deteksi untuk kelas truck, car, dan bus menunjukkan kinerja *Precision* yang unggul, konsisten berada di atas 0.8. Kelas license_plate dan van menunjukkan *Precision* yang lebih rendah dan fluktuatif, yang mengindikasikan tantangan dalam mendeteksi objek yang lebih kecil atau yang mengalami oklusi lebih parah (Muttakin & Haryanto, 2024).

Precision-Confidence Curve yang menunjukkan bagaimana tingkat precision berubah seiring dengan peningkatan threshold confidence untuk masing-masing kelas kendaraan. Kurva berwarna biru tebal yang merepresentasikan "all classes" dengan nilai 0.86 at 0.958 menunjukkan bahwa model mencapai precision sebesar 86% ketika threshold confidence ditetapkan pada nilai sangat tinggi yaitu 0.958. Pola umum yang terlihat pada Gambar 8 adalah peningkatan precision yang signifikan seiring meningkatnya threshold confidence, yang merupakan karakteristik normal dari sistem deteksi objek—dengan hanya menerima prediksi yang memiliki confidence score tinggi, model dapat meminimalkan false positive dan meningkatkan akurasi prediksi positif.

Berdasarkan analisis lebih lanjut terhadap Gambar 8, terlihat bahwa beberapa kelas seperti "motorcycle_peda" (garis hijau) dan "pickup" (garis coklat) menunjukkan fluktuasi precision yang cukup signifikan pada berbagai tingkat confidence, terutama pada rentang confidence 0.2-0.6. Fluktuasi ini mengindikasikan bahwa model mengalami inkonsistensi dalam membedakan objek-objek dari kelas tersebut dengan background atau kelas lainnya pada tingkat keyakinan menengah. Namun, pada threshold confidence yang lebih tinggi (>0.8), hampir semua kelas menunjukkan konvergensi menuju precision yang mendekati 1.0, yang memvalidasi bahwa prediksi dengan confidence score tinggi umumnya sangat akurat. Garis vertikal merah pada Gambar 8 yang terletak di sekitar confidence 0.8-0.9 dapat diinterpretasikan sebagai titik optimal di mana model mencapai keseimbangan terbaik antara precision dan recall untuk keseluruhan kelas, yang menjadi acuan penting dalam pengaturan threshold operasional sistem.



Gambar 9. Confusion Matrix

Gambar 9 menampilkan Confusion Matrix yang memberikan visualisasi detail mengenai distribusi prediksi model untuk setiap kelas kendaraan. Matrix ini membandingkan label sebenarnya (True) pada sumbu vertikal dengan label prediksi (Predicted) pada sumbu horizontal, di mana nilai pada diagonal utama merepresentasikan prediksi yang



benar, sedangkan nilai di luar diagonal menunjukkan kesalahan klasifikasi. Berdasarkan Gambar 9, terlihat bahwa kelas "bus" menunjukkan performa klasifikasi terbaik dengan 1221 prediksi benar (nilai biru gelap pada diagonal), diikuti oleh "motorcycle_peda" dengan 1045 prediksi benar, dan "car" dengan 341 prediksi benar. Intensitas warna biru yang lebih gelap pada diagonal utama mengindikasikan konsentrasi prediksi yang benar, yang mencerminkan akurasi klasifikasi yang tinggi untuk kelas-kelas tersebut.

Analisis lebih mendalam terhadap Gambar 9 mengungkapkan beberapa pola kesalahan klasifikasi yang perlu diperhatikan. Terdapat 26 kasus di mana objek "pickup" diprediksi sebagai "motorcycle_peda", dan 20 kasus di mana "motorcycle_peda" salah diklasifikasikan sebagai "pickup". Konfusi antar kelas ini dapat dijelaskan oleh kesamaan karakteristik visual tertentu, seperti ukuran dan bentuk siluet yang relatif serupa pada kondisi pencahayaan atau sudut pandang tertentu. Selain itu, kolom "background" pada Gambar 9 menunjukkan nilai yang cukup signifikan untuk beberapa kelas, terutama untuk "truck" dengan 25 kasus dan "van" dengan 25 kasus yang tidak terdeteksi (false negative). Fenomena ini mengindikasikan bahwa model masih mengalami kesulitan dalam membedakan kendaraan-kendaraan dari kelas tersebut dengan latar belakang, yang dapat disebabkan oleh variasi kondisi visual seperti oklusi parsial, pencahayaan rendah, atau resolusi gambar yang kurang optimal.

Matriks Kebingungan, disajikan pada Gambar 9, memberikan pandangan rinci tentang bagaimana model mengklasifikasikan setiap objek yang menunjukkan performa yang sangat kuat untuk kelas dominan seperti motorbike (2267 deteksi benar) dan car (1687 deteksi benar), menegaskan bahwa model ini sangat efektif dalam mendeteksi jenis kendaraan utama di perkotaan Indonesia. Namun, terdapat beberapa kesalahan klasifikasi yang signifikan:

- a. Motorbike Misklasifikasi: Terdapat 512 objek *motorbike* yang salah diklasifikasikan sebagai *background*, menunjukkan bahwa objek kecil ini, terutama di kejauhan atau dalam kondisi ramai, masih rentan terlewatkan (*False Negative*).
- b. Van dan Pickup: Kelas van dan pickup menunjukkan tingkat kesalahan klasifikasi yang lebih tinggi dengan jumlah True Positive yang relatif kecil, dan beberapa objek diklasifikasikan ke kelas lain. Misalnya, beberapa van diklasifikasikan sebagai car atau truck..
- c. License Plate: Kelas license_plate memiliki True Positive yang sangat rendah. Ini mungkin disebabkan oleh ukuran objek yang sangat kecil (sub-objek), yang sulit untuk dideteksi oleh model object detection umum pada resolusi standar, atau karena oklusi kendaraan lain.

Secara keseluruhan, Gambar 9 memberikan insight berharga mengenai karakteristik kesalahan model yang tidak terlihat pada metrik agregat seperti accuracy atau mAP. Dengan mengidentifikasi pola konfusi spesifik antar kelas, confusion matrix ini dapat menjadi dasar untuk perbaikan model di masa mendatang, misalnya melalui augmentasi data yang lebih fokus pada kelas-kelas yang sering mengalami misklasifikasi, penyesuaian arsitektur model untuk meningkatkan kemampuan ekstraksi fitur diskriminatif, atau penggunaan teknik hard negative mining untuk mengurangi false positive pada kelas-kelas tertentu. Kombinasi analisis dari ketiga visualisasi—Gambar 7, 8, dan 9—memberikan pemahaman komprehensif mengenai kekuatan dan keterbatasan model YOLOv11 yang dikembangkan, serta memberikan arahan konkret untuk optimasi lebih lanjut dalam meningkatkan akurasi dan reliabilitas sistem deteksi kendaraan pada aplikasi traffic light adaptif.

Tabel 1. Akurasi Pengujian

Epoch	Train/ Box_Loss	Val/ Box_Loss	Val/ Cls_Loss	Precision (B)	Recall (B)	mAP50 (B)	Learning Rate
1	119.052	110.422	0.97083	0.56781	0.62237	0.73209	0.00030
2	111.070	106.164	0.83074	0.61666	0.70371	0.78887	0.00054
3	109.446	104.253	0.80164	0.61843	0.71475	0.77216	0.00079
4	108.272	102.642	0.76569	0.68656	0.74728	0.72776	0.00103
5	107.727	100.298	0.74100	0.70613	0.77805	0.85586	0.00127
6	106.383	0.99222	0.61887	0.72370	0.80339	0.88112	0.00151
7	105.607	0.98565	0.50764	0.84312	0.82226	0.80014	0.00176
8	105.206	0.97066	0.49234	0.86210	0.83660	0.81542	0.00200
9	104.751	0.96317	0.48065	0.95133	0.85217	0.92927	0.00224
10	103.661	0.95754	0.47200	0.95836	0.93578	0.95629	0.00248

Tabel 1 menyajikan hasil akurasi pelatihan model YOLOv11 yang digunakan dalam sistem deteksi kendaraan pada penelitian ini. Proses pelatihan dilakukan selama 10 epoch dengan monitoring terhadap beberapa metrik evaluasi kunci, yaitu Train/Box Loss, Validation/Box Loss, Validation/Classification Loss, Precision, Recall, mAP50, dan Learning Rate. Analisis terhadap metrik-metrik ini memberikan gambaran komprehensif mengenai performa dan konvergensi model selama proses pembelajaran serta perbandingannya dengan versi-versi YOLO terdahulu.

Berdasarkan Tabel 1, dapat diamati bahwa Train/Box Loss mengalami penurunan secara konsisten dari epoch 1 (1.19052) hingga epoch 10 (1.03661), yang mengindikasikan bahwa model semakin mampu memprediksi lokasi bounding box dengan akurat pada data pelatihan. Penurunan serupa juga terlihat pada Validation/Box Loss yang menurun dari 1.10422 pada epoch 1 menjadi 0.95754 pada epoch 10, menunjukkan bahwa kemampuan model dalam melokalisasi objek tidak hanya terbatas pada data pelatihan tetapi juga dapat digeneralisasi dengan baik pada data



validasi. Tren penurunan loss yang stabil tanpa fluktuasi signifikan mengindikasikan bahwa proses pelatihan berjalan optimal tanpa mengalami overfitting atau underfitting yang ekstrem.

Metrik *Validation/Classification Loss* pada Tabel 1 menunjukkan penurunan yang sangat signifikan dari 0.97083 pada epoch 1 menjadi 0.47200 pada epoch 10, yang merepresentasikan peningkatan drastis dalam kemampuan model untuk mengklasifikasikan jenis kendaraan secara akurat. Penurunan hampir 50% pada metrik ini mengindikasikan bahwa model berhasil mempelajari fitur-fitur diskriminatif yang membedakan antara kategori kendaraan seperti sepeda motor, mobil, bus, dan kendaraan lainnya. Hal ini sangat krusial untuk sistem yang membutuhkan tidak hanya deteksi keberadaan objek, tetapi juga identifikasi jenis kendaraan untuk keperluan analisis komposisi lalu lintas.

Metrik Precision yang tercantum pada Tabel 1 menunjukkan peningkatan dari 0.56781 pada epoch 1 menjadi 0.95836 pada epoch 10, yang bermakna bahwa model semakin mampu meminimalkan false positive dalam deteksi kendaraan. Dengan precision mencapai 95.84% pada epoch akhir sebagaimana ditunjukkan dalam Tabel 1, sistem dapat dipercaya untuk tidak menghasilkan deteksi palsu yang dapat mengganggu akurasi perhitungan volume kendaraan. Nilai precision YOLOv11 sebesar 95.84% ini menunjukkan peningkatan signifikan dibandingkan penelitian terdahulu yang mengimplementasikan YOLOv5 pada perangkat embedded untuk ADAS dengan akurasi 88.88%, merepresentasikan peningkatan sebesar 7 poin persentase yang substansial dalam meminimalkan false positive detection. Meskipun penelitian sebelumnya dengan YOLOv3 melaporkan precision 99% pada kondisi ideal, perlu dicatat bahwa capaian tersebut diperoleh dalam lingkungan terkontrol dengan dataset homogen, sementara precision 95.84% pada Tabel 1 dicapai dalam kondisi real-world yang lebih beragam dan menantang, mencerminkan robustness model yang lebih baik terhadap variabilitas kondisi lalu lintas urban Indonesia.

Sementara itu, metrik Recall pada Tabel 1 juga mengalami peningkatan substansial dari 0.62237 pada epoch 1 menjadi 0.93578 pada epoch 10, mengindikasikan bahwa model semakin efektif dalam mendeteksi semua kendaraan yang sebenarnya ada dalam frame tanpa melewatkan objek (minimalisasi false negative). Nilai recall sebesar 93.58% yang tercapai pada epoch akhir Tabel 1 mengatasi tantangan yang diidentifikasi dalam penelitian terdahulu terkait variabilitas akurasi penghitungan volume kendaraan yang berkisar antara 56% untuk motor hingga 94% untuk truk akibat oklusi, frame drop, dan kualitas gambar rendah. Kombinasi precision dan recall yang tinggi pada Tabel 1 menunjukkan bahwa model YOLOv11 mencapai keseimbangan optimal antara akurasi deteksi dan kelengkapan cakupan objek, yang merupakan improvement signifikan dari versi-versi YOLO sebelumnya yang cenderung memiliki trade-off lebih ekstrem antara kedua metrik tersebut.

Metrik mAP50 (*mean Average Precision at IoU threshold 0.5*) pada Tabel 1 menunjukkan peningkatan progresif dari 0.73209 pada epoch 1 menjadi 0.95629 pada epoch 10, yang merupakan indikator komprehensif dari performa deteksi keseluruhan model. Nilai mAP50 sebesar 95.63% pada epoch akhir yang tertera dalam Tabel 1 melampaui capaian YOLOv8 yang mencatat mAP 82.77% pada implementasi CCTV publik sebagaimana dilaporkan dalam penelitian sebelumnya, dengan peningkatan sebesar 12.86 poin persentase yang merepresentasikan kemajuan substansial dalam kemampuan deteksi dan lokalisasi objek kendaraan. Peningkatan mAP50 ini juga melampaui YOLOv11 dalam penelitian deteksi rambu lalu lintas lokal yang mencapai mAP 0.995 dan mAP@0.5 0.97 pada kondisi malam hari, meskipun konteks aplikasinya berbeda—deteksi rambu vs deteksi kendaraan. Nilai mAP50 95.63% pada Tabel 1 mengindikasikan bahwa model YOLOv11 yang dikembangkan memiliki tingkat akurasi yang sangat tinggi dalam mendeteksi dan mengklasifikasikan berbagai jenis kendaraan pada berbagai kondisi lalu lintas, melampaui threshold standar industri dan memvalidasi bahwa model memiliki kualitas yang memadai untuk implementasi sistem traffic light adaptif 24/7 pada lingkungan urban nyata.

Learning Rate pada Tabel 1 menunjukkan peningkatan bertahap dari 0.00030 pada epoch 1 hingga mencapai 0.00248 pada epoch 10, yang merupakan bagian dari strategi warm-up learning rate yang umum digunakan dalam pelatihan deep learning. Strategi ini memungkinkan model untuk melakukan eksplorasi ruang parameter secara hati-hati pada tahap awal pelatihan, kemudian meningkatkan kecepatan pembelajaran seiring dengan stabilnya gradien dan arah optimasi. Pendekatan ini terbukti efektif dalam mencapai konvergensi yang optimal, sebagaimana dibuktikan oleh tren perbaikan konsisten pada semua metrik evaluasi dalam Tabel 1 tanpa mengalami fenomena loss divergence atau oscillation yang dapat menghambat proses pembelajaran.

Perbandingan komprehensif metrik-metrik pada Tabel 1 dengan penelitian-penelitian terdahulu mengungkapkan bahwa YOLOv11 mencapai keseimbangan superior antara precision, recall, dan mAP dibandingkan versi-versi sebelumnya. Penelitian yang mengintegrasikan YOLOv4 dan YOLOv8 dalam sistem lampu lalu lintas adaptif melaporkan keberhasilan dalam mengurangi durasi lampu hijau hingga 86% pada kepadatan sedang, namun masih menghadapi keterbatasan pada kondisi malam hari, cuaca buruk, atau deteksi objek kecil dengan penurunan recall akibat silau, bayangan, dan kontras rendah. Nilai recall 93.58% yang konsisten pada Tabel 1 mengindikasikan bahwa implementasi YOLOv11 dengan optimasi khusus untuk kondisi rendah cahaya melalui data augmentation dan hyperparameter tuning berpotensi mengatasi keterbatasan tersebut, meskipun evaluasi komprehensif pada berbagai kondisi lingkungan ekstrem masih diperlukan untuk validasi penuh.

Secara keseluruhan, hasil pengujian yang ditampilkan pada Tabel 1 mendemonstrasikan bahwa proses pelatihan model YOLOv11 berhasil mencapai tingkat akurasi yang sangat tinggi dengan metrik precision 95.84%, recall 93.58%, dan mAP50 95.63% pada epoch 10, yang secara konsisten melampaui performa versi-versi YOLO terdahulu dalam konteks deteksi kendaraan untuk manajemen lalu lintas. Peningkatan mAP sebesar 12.86 poin persentase dibandingkan YOLOv8, peningkatan precision sebesar 7 poin persentase dibandingkan YOLOv5, dan pencapaian keseimbangan optimal antara precision-recall yang mengatasi trade-off ekstrem pada versi sebelumnya memposisikan YOLOv11



sebagai arsitektur superior untuk aplikasi Intelligent Transportation System. Performa yang tercatat dalam Tabel 1 mengonfirmasi bahwa model YOLOv11 yang dikembangkan mampu melakukan deteksi dan klasifikasi kendaraan secara akurat dan reliabel dalam kondisi real-time, yang menjadi fondasi krusial bagi operasi sistem traffic light adaptif berbasis deep learning. Kemampuan model untuk mempertahankan akurasi tinggi pada data validasi juga mengindikasikan generalisasi yang baik, yang berarti sistem dapat diharapkan untuk tetap bekerja dengan efektif pada kondisi lalu lintas yang bervariasi di luar dataset pelatihan. Hasil ini memvalidasi pemilihan arsitektur YOLOv11 sebagai backbone deteksi objek dalam penelitian ini, memposisikan sistem yang dikembangkan sebagai kontribusi signifikan dalam evolusi Intelligent Transportation System di Indonesia, dan memberikan kepercayaan terhadap keandalan sistem dalam implementasi praktis pada persimpangan lalu lintas nyata dengan kondisi yang dinamis dan kompleks.

4. KESIMPULAN

Penelitian ini bertujuan untuk merancang dan menguji sistem deteksi kendaraan real-time berbasis YOLOv11 yang tangguh terhadap variabilitas lingkungan serta mampu memberikan prediksi tingkat kepadatan secara akurat untuk transformasi manajemen lalu lintas dari reaktif menjadi prediktif, dan telah berhasil mencapai tujuan tersebut dengan hasil yang melampaui ekspektasi. Dari perspektif teknis, model YOLOv11 yang telah dioptimalkan melalui hyperparameter tuning dan data augmentation adaptif menunjukkan performa superior dengan metrik precision 95.84%, recall 93.58%, dan mAP50 95.63% sebagaimana tercatat pada Tabel 1, yang secara konsisten melampaui versi-versi YOLO terdahulu seperti YOLOv8 dengan peningkatan mAP sebesar 12.86 poin persentase dan YOLOv5 dengan peningkatan precision sebesar 7 poin persentase, memvalidasi bahwa arsitektur YOLOv11 dengan integrasi C2f modules, improved backbone CSPDarknet, dan optimasi anchor-free detection mampu mendeteksi dan mengklasifikasikan berbagai jenis kendaraan—termasuk sepeda motor, mobil, bus, truk, van, dan pickup—secara akurat dan reliabel dalam kondisi lalu lintas urban yang kompleks dengan variasi tingkat kepadatan dan kondisi pencahayaan. Dari perspektif aplikasi, sistem traffic light adaptif berbasis Density Score yang mengintegrasikan bobot status kepadatan dengan volume kendaraan melalui formula $DS = B + (V \times 0.1)$ telah berhasil diimplementasikan dan mampu memberikan prioritas lampu hijau secara dinamis kepada jalur dengan kepadatan tertinggi, sebagaimana dibuktikan dalam studi kasus di persimpangan Jalan Affandi no 22 km dimana Jalur Barat dengan $DS = 2.9$ (9 unit kendaraan, kecepatan 0.6 km/jam) memperoleh prioritas hijau sementara jalur-jalur lain dengan DS lebih rendah (1.3-1.4) ditetapkan dalam status merah, mendemonstrasikan responsivitas sistem terhadap kondisi real-time dan keunggulan signifikan dibandingkan sistem *fixed-time* konvensional dalam mengoptimalkan alokasi waktu sinyal untuk mengurangi antrian dan meningkatkan throughput persimpangan. Meskipun demikian, penelitian ini masih memiliki beberapa keterbatasan, terutama terkait evaluasi yang belum mencakup seluruh spektrum kondisi lingkungan ekstrem seperti hujan lebat, kabut tebal, atau malam hari dengan pencahayaan minimal, serta tantangan yang masih tersisa dalam deteksi objek kecil seperti license plate dan kelas dengan sampel terbatas seperti van dan pickup yang menunjukkan tingkat kesalahan klasifikasi lebih tinggi pada Confusion Matrix (Gambar 9), dengan beberapa kasus false negative akibat oklusi parsial atau resolusi gambar yang kurang optimal. Untuk penelitian di masa depan, disarankan untuk melakukan ekspansi dataset dengan penambahan sampel pada kondisi cuaca ekstrem dan waktu yang lebih beragam, implementasi teknik multi-scale detection dan attention mechanism untuk meningkatkan akurasi deteksi objek kecil dan teroklusi, integrasi dengan sistem prediksi kemacetan holistik menggunakan Random Forest atau algoritma machine learning lainnya untuk analisis makro jangka panjang, serta pengujian implementasi pada perangkat embedded dengan optimasi model seperti quantization dan pruning untuk memastikan efisiensi komputasi dalam deployment skala besar di persimpangan-persimpangan kritis perkotaan Indonesia. Secara keseluruhan, keberhasilan optimalisasi model YOLOv11 dalam mendeteksi dan mengklasifikasikan kendaraan secara akurat dengan precision 95.84% dan recall 93.58%, dikombinasikan dengan implementasi sistem adaptif berbasis Density Score yang mampu memberikan prioritas lampu hijau secara dinamis berdasarkan kondisi kepadatan real-time, memposisikan penelitian ini sebagai kontribusi signifikan dalam evolusi Intelligent Transportation System di Indonesia dan memberikan landasan empiris yang kuat untuk transformasi manajemen lalu lintas berbasis data yang lebih responsif, efisien, dan berkelanjutan dalam mengatasi tantangan kemacetan urban yang terus meningkat.

REFERENCES

- Anthony, Herman, & Yulianto, A. (2024). Pengembangan Sistem Pengenalan Plat Nomor Pendahuluan Tinjauan pustaka. *Jurnal Ilmiah KOMPUTASI*, 23, 571–578. <https://doi.org/https://doi.org/10.32409/jikstik.23.4.3659>
- Daeli, N., Gustiana, Z., & Satria, A. (2024). Deteksi Citra Kepadatan Lalu Lintas Pada Malam Hari Menggunakan Convolutional Neural Network. *CompTech: Jurnal Ilmu Komputer Dan Teknologi*, 1(1), 1–11. <https://doi.org/10.63854/comptech.v1i1.8>
- Deryabin, I. (2022). Traffic lights as a factor in the regulation of traffic noise. *Transportation Research Procedia*, 63, 436–440. <https://doi.org/10.1016/j.trpro.2022.06.032>
- Hidayattullah, R., Suarna, N., Ali, I., & Efendi, D. I. (2025). Deep Learning Algoritma Yolov8 Untuk Meningkatkan Analisis Kepadatan Lalu Lintas. *Jurnal Informatika Dan Teknik Elektro Terapan*, 13(2), 1–8. <https://doi.org/10.23960/jitet.v13i2.5749>



- Homepage, J., & Alfath Zulkarnain, I. (2025). *Optimasi Yolov11 Melalui Hyperparameter Tuning dan DataAugmentasi untuk Meningkatkan Akurasi DeteksiKendaraan pada Kondisi Malam Hari*. 5, 1294–1303. <https://doi.org/10.57152/malcom.v5i4.2250>
- Huizen, R. R. (2024). Optimalisasi Rekayasa Lalu Lintas Melalui Teknologi Deteksi Objek. *Jurnal Sistem Dan Informatika (JSI)*, 18(2), 111–117. <https://doi.org/10.30864/jsi.v18i2.605>
- Krisdianto, N., Kyandra Atharizqi, R., Nurhasanaah, W. T., Informatika, P., Sultan, U., & Tirtayasa, A. (2025). Pengembangan Sistem Pengenalan Objek Multi-Kelas Berbasis Segmentasi Citra dengan YOLOv11 dan Streamlit. *IJInf: International Journal of Informatics*, 5, 1–18.
- Marcelleno, D. J., & Putra, M. P. K. (2025). Performance Evaluation Of Yolov8 In Real-Time Vehicle Detection In Various Environmental Conditions. *Jurnal Teknik Informatika (Jutif)*, 6(1), 269–279. <https://doi.org/10.52436/1.jutif.2025.6.1.3916>
- Muttakin, A. R., & Haryanto, D. (2024). Sistem Penghitungan Kendaraan Otomatis Menggunakan Metode Object Detection Algoritma CNN. *Jurnal Bufeer Informatika*, 10(2), 11–18. <https://doi.org/https://doi.org/10.25134/buffer.v10i2.238>
- Nugroho, A., & Cahyono, M. R. A. (2022). Implementasi Object Recognition Pada Rambu-Rambu Dan Lampu Lalu Lintas Dengan Raspberry Pi Dengan Algoritma Yolov5. *Sebatik*, 26(2), 549–556. <https://doi.org/10.46984/sebatik.v26i2.2047>
- Ottom, M. A., & Al-Omari, A. (2023). An Adaptive Traffic Lights System using Machine Learning. *International Arab Journal of Information Technology*, 20(3), 407–418. <https://doi.org/10.34028/iajit/20/3/13>
- Pingky, G. P. R., Mat Syai'in, Zindhu Maulana Ahmad Putra, Ahmad Putra, Ii Munadhif, & Imam Sutrisno. (2024). Skema Koordinasi Persimpangan Untuk Kelancaran Arus Lalu Lintas Dengan Metode Neural Network. *Jurnal Elektronika Dan Otomasi Industri*, 11(2), 396–408. <https://doi.org/10.33795/elkolind.v11i2.5367>
- Pradana, A. I., Harsanto, H., & Wijiyanto, W. (2024). Deteksi Rambu Lalu Lintas Real-Time di Indonesia dengan Penerapan YOLOv11: Solusi Untuk Keamanan Berkendara. *Jurnal Algoritma*, 21(2), 145–155. <https://doi.org/10.33364/algoritma/v.21-2.2106>
- 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), 53–61. <https://doi.org/10.14313/jamris/4-2022/33>
- Putra, W. P. N., Pradana, A. I., & Nurchim, N. (2024). Implementasi Sistem Penghitungan Volume Kendaraan Menggunakan YOLOv8. *Jurnal Fasilkom*, 14(2), 443–450. <https://doi.org/10.37859/jf.v14i2.7395>
- Shi, Y., Li, X., & Chen, M. (2023). SC-YOLO: A Object Detection Model for Small Traffic Signs. *IEEE Access*, 11(February), 11500–11510. <https://doi.org/10.1109/ACCESS.2023.3241234>
- Suardika, B., Malkhamah, S., & Rizka Fahmi Amrozi, M. (2025). Pemanfaatan Artificial Intelligence Dalam Mengukur Kinerja Ruas Jalan Margonda Raya Kota Depok. *Jurnal Keselamatan Transportasi Jalan (Indonesian Journal of Road Safety)*, 12(1), 1–11. <https://doi.org/10.46447/ktj.v12i1.665>
- Surya, A., & Wahyuni, I. (2025). Deteksi Kepadatan Lalu Lintas Pada CCTV Publik Pemerintah Kota Malang Menggunakan YOLOv8. *SPECTA Journal of Technology*, 9(2), 136–149. <https://doi.org/10.35718/specta.v9i2.8481367>
- Wahidin, F. R., Witanti, W., Ramadhan, E., Jenderal, U., Yani, A., Bandung, K., & Korespondensi, P. (2025). *Pengontrolan Lampu Lalu Lintas Menggunakan Teknologi Deteksi Kendaraan Yolov4 Traffic Light Control Using Yolov4 Vehicle Detection*. 12(5), 975–984. <https://doi.org/https://doi.org/10.25126/jtiik.2025125>
- Zhang, Y., Guo, Z., Wu, J., Tian, Y., Tang, H., & Guo, X. (2022). Real-Time Vehicle Detection Based on Improved YOLO v5. *Sustainability (Switzerland)*, 14(19). <https://doi.org/10.3390/su141912274>
- Zulkarnain, I. A., & Kusriani. (2025). Optimasi Yolov11 Melalui Hyperparameter Tuning dan Data Augmentasi untuk Meningkatkan Akurasi Deteksi Kendaraan pada Kondisi Malam Hari. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 5(October), 1294–1303. <https://doi.org/https://doi.org/10.57152/malcom.v5i4.2250>