



Sistem Analisis Kinerja Lalu Lintas Berbasis *Deep Learning* dengan Arsitektur *You Only Look Once (YOLO)*

Andi Ahdan Amir^{1*}, Sukman¹, Astri Delviana Lihara¹, Muhammad Nabil²

¹Program Studi Teknik Sipil, Universitas Nahdlatul Ulama Sulawesi Tenggara, Indonesia

²Program Studi Teknik Informatika, Universitas Nahdlatul Ulama Sulawesi Tenggara, Indonesia

Artikel Info

Kata Kunci:

Deep Learning;
Kinerja Lalu Lintas;
Level of Service;
PKJI 2023;
YOLO.

Keywords:

Deep Learning;
Traffic Performance;
Level of Service;
PKJI 2023;
YOLO.

Riwayat Artikel:

Submitted: 18 November 2025

Accepted: 09 Maret 2026

Published: 09 Maret 2026

Abstrak: Tingginya tingkat kemacetan lalu lintas di perkotaan memerlukan solusi pemantauan dan analisis yang cepat dan akurat. Penelitian ini bertujuan untuk merancang dan mengimplementasikan sistem analisis kinerja lalu lintas otomatis yang mengintegrasikan model deteksi objek YOLOv8 dengan parameter standar Pedoman Kapasitas Jalan Indonesia (PKJI) 2023. Berbeda dengan penelitian sebelumnya yang umumnya berfokus pada kuantifikasi kendaraan, sistem ini secara otomatis mengonversi data deteksi visual menjadi metrik kinerja teknis. Hasil pengujian menunjukkan model YOLOv8s mencapai nilai mAP@0.5 rata-rata 0.948. Implementasi sistem pada dashboard interaktif menunjukkan akurasi perhitungan jumlah kendaraan sebesar 96% dibandingkan data manual, yang kemudian diolah menjadi indikator Derajat Kejenuhan (*Degree of Saturation*) dan Tingkat Pelayanan (*Level of Service*). Temuan ini membuktikan bahwa integrasi *deep learning* dengan regulasi rekayasa transportasi nasional dapat meningkatkan efisiensi pemantauan infrastruktur jalan secara signifikan.

Abstract: Escalating urban traffic congestion necessitates highly efficient and accurate monitoring and analysis frameworks. This study develops an automated traffic performance analysis system that integrates the YOLOv8 object detection architecture with the technical parameters defined in the 2023 Indonesian Highway Capacity Guidelines (PKJI). Distinguishing itself from conventional research that focuses primarily on vehicle quantification, this system provides an end-to-end workflow for autonomously converting visual detection data into robust engineering metrics. Experimental results indicate that the YOLOv8s model achieves superior detection performance with a mean Average Precision (mAP@0.5) of 0.948. System validation via an interactive dashboard demonstrates a vehicle counting accuracy of 96% compared to manual survey data. These results are subsequently processed to generate critical traffic indicators, specifically the Degree of Saturation (DS) and Level of Service (LoS). The findings demonstrate that integrating deep learning with national transportation engineering regulations significantly enhances the efficiency, objectivity, and precision of road infrastructure monitoring.

Corresponding Author:

Andi Ahdan Amir

Program Studi Teknik Sipil, Fakultas Teknik, Universitas Nahdlatul Ulama Sulawesi Tenggara

Alamat: Jl. Brigjend Katamso. No 2, Kendari, Indonesia

Email: ahdanamir@gmail.com

PENDAHULUAN

Permasalahan lalu lintas seperti kemacetan, risiko kecelakaan, dan tingginya emisi gas buang merupakan tantangan utama dalam perencanaan kota dan manajemen transportasi, baik secara global maupun di kota-kota besar di Indonesia. Di Kota Kendari, dinamika ini terlihat dari peningkatan volume kendaraan yang signifikan hingga 30% pada titik-titik strategis, terutama pada jam puncak, yang berujung pada penurunan tingkat pelayanan jalan dan peningkatan angka kecelakaan (Amir et al., 2023; Amir & Suda, 2022; Ditlantas Polda Sultra, 2025). Penanganan masalah ini memerlukan data kinerja lalu lintas yang akurat dan waktu analisis yang cepat guna mendukung pengambilan kebijakan rekayasa lalu lintas yang tepat sasaran (Fadlan et al., 2024).

Hingga saat ini, analisis kinerja lalu lintas di Indonesia masih sangat bergantung pada metode manual yang mengacu pada Pedoman Kapasitas Jalan Indonesia (PKJI) 2023 (Direktorat Jenderal Bina Marga, 2023), yang merupakan pengembangan dari (Manual Kapasitas Jalan Indonesia (MKJI), 1997). Metode konvensional ini memerlukan survei visual langsung oleh tenaga manusia (surveyor) (Jakubec et al., 2025), yang secara metodologis memiliki keterbatasan dalam hal biaya operasional yang tinggi, waktu pengolahan data yang lama (Majumder & Wilmot, 2023), serta risiko subjektivitas yang memengaruhi akurasi data primer dengan tingkat kesalahan (*error rate*) sekitar 6,4%, jauh lebih tinggi dibandingkan sistem otomatis yang hanya 1,3%, (Kamarudin et al., 2025; Zheng & Mike, 2012). Di sisi lain, kemajuan teknologi informasi, khususnya dalam domain deep learning, menawarkan peluang transformasi digital melalui otomatisasi identifikasi pola lalu lintas secara real-time (Kuang et al., 2025; Suardika et al., 2025).

Implementasi teknologi deep learning (Jonathan & Wasito, 2023; Prasiwiningrum & Lubis, 2024), khususnya penggunaan algoritma You Only Look Once (YOLO) telah banyak dikaji untuk deteksi objek karena keunggulannya dalam kecepatan inferensi dan akurasi yang seimbang (Muntiari et al., 2024; Naufaldihanif et al., 2025; Kusuma et al., 2024). Beberapa penelitian sebelumnya, seperti yang dilakukan oleh Wicaksono et al. (2021) dan Ariyoga et al. (2021), telah berhasil menerapkan deep learning untuk deteksi dan klasifikasi kendaraan. Namun, terdapat kesenjangan penelitian yang nyata di mana studi-studi tersebut umumnya berhenti pada tahap deteksi dan kuantifikasi (perhitungan jumlah) kendaraan saja, tanpa melakukan kajian integratif lebih lanjut terhadap parameter kinerja jalan (Marcelleno & Putra, 2025; Subekti & Putra, 2025). Belum ditemukan sistem yang secara otomatis mengonversi data mentah deteksi visual menjadi metrik teknis PKJI 2023 (Direktorat Jenderal Bina Marga, 2023) untuk menghasilkan indikator kinerja secara simultan (Jakubec et al., 2025; Suardika et al., 2025).

Kebaruan (*novelty*) dari penelitian ini terletak pada integrasi arsitektur YOLOv8 dengan modul perhitungan kinerja lalu lintas otomatis yang berbasis pada regulasi PKJI 2023 (Flores-Calero et al., 2024; Khadka et al., 2025; Afifah & Erniwati, 2025). Kontribusi utamanya mencakup pengembangan sistem yang mampu melakukan ekstraksi data volume kendaraan per kelas, yang kemudian diumpankan langsung ke dalam algoritma perhitungan kapasitas (C), derajat kejenuhan (*degree of saturation*), hingga penentuan tingkat pelayanan (*Level of Service* atau *LoS*) (Direktorat Jenderal Bina Marga, 2023). Dengan pendekatan system analisis lalu lintas ini, proses analisis yang sebelumnya memakan waktu hari dapat dipangkas menjadi hitungan detik melalui sistem berbasis web yang interaktif (Tiwari et al., 2023; Yin et al., 2022). Hal ini sejalan dengan upaya optimalisasi infrastruktur digital yang mulai banyak diimplementasikan dalam berbagai layanan teknologi informasi public (Mahusin et al., 2025; Nanos, 2023).

Tujuan dari penelitian ini adalah merancang dan membangun sebuah model deteksi kendaraan menggunakan YOLOv8 yang terintegrasi penuh dengan sistem analisis arus lalu lintas (Q), kapasitas jalan (C), dan derajat kejenuhan atau *degree of saturation* (DS) sebagai indikator utama kinerja lalu lintas. Melalui implementasi sistem ini, diharapkan tersedia solusi manajemen transportasi angkutan jalan cerdas yang efisien, akurat, dan dapat direplikasi untuk mendukung perencanaan infrastruktur jalan di Kota Kendari dan wilayah perkotaan lainnya di Indonesia.

METODE

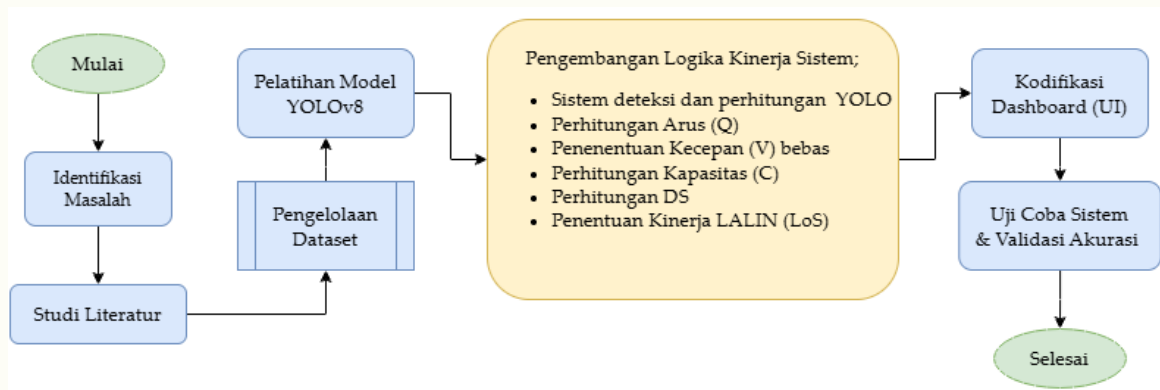
Jenis Penelitian

Penelitian ini menerapkan kerangka kerja Penelitian dan Pengembangan (*Research and Development / R&D*) dengan fokus pada rancang bangun sistem analisis kinerja lalu lintas cerdas berbasis computer vision. Metode yang digunakan dirancang secara sistematis agar dapat direplikasi dan divalidasi keunggulannya dibandingkan metode survei konvensional.

Alur Pengembangan Sistem

Sistem dikembangkan melalui tujuh fase berkesinambungan antara lain:

1. Identifikasi Masalah: Menganalisis parameter kritis kemacetan di jalan perkotaan.
2. Studi Literatur: Mengkaji standar Pedoman Kapasitas Jalan Indonesia (PKJI) 2023 dan evolusi arsitektur YOLOv8.
3. Pengelolaan Dataset: Akuisisi, pembersihan, dan pelabelan citra kendaraan.
4. Pelatihan Model YOLOv8: Optimasi model deteksi melalui penyetelan hyperparameter.
5. Pengembangan Logika Kinerja: Integrasi rumus matematis PKJI ke dalam algoritma sistem.
6. Kodifikasi Dashboard: Membangun antarmuka interaktif menggunakan Streamlit.
7. Validasi Kuantitatif: Menguji akurasi sistem terhadap data ground truth hasil survei manual.



Gambar 1. Diagram Alur Pengembangan Sistem Analisis Kinerja Jalan

Spesifikasi Dataset dan Pre-processing

Dataset penelitian terdiri dari 1606 citra yang bersumber dari rekaman CCTV Badan Pengatur Jalan Tol (BPJT) dan Pemerintah Kota Bandung dengan resolusi minimal 720p, serta rekaman drone aerial dan rekaman kamera handphone pada jam puncak (07.00-09.00 dan 16.00-18.00) pada beberapa titik di Kota Kendari di antaranya pada ruas Jalan D.I. Panjaitan dan Jalan Brigjen Katamso. Anotasi objek dilakukan secara manual menggunakan platform Roboflow dalam format bounding box dengan klasifikasi empat kelas: Mobil, Sepeda Motor, Bus, dan Truk. Untuk memastikan generalisasi model, diterapkan teknik augmentasi data berupa Mosaic (penggabungan 4 citra), Horizontal Flip, dan penyesuaian kecerahan guna mensimulasikan variasi cuaca dan kondisi cahaya rendah. Dataset dibagi secara proporsional menjadi 57% (919) data training, 29% (466) data validation, dan 13.7% (221) data testing.

Tabel 1. Distribusi Kelas Kendaraan dan Skenario Pencahayaan Dataset

Kelas Kendaraan	Siang Hari (Cerah)	Malam Hari (Lampu Jalan)	Total
Mobil	620	252	872
Sepeda Motor	595	276	871
Bus	610	285	895
Truk	635	286	921

Konfigurasi Pelatihan Deteksi Kendaraan

Model yang dipilih adalah YOLOv8s (small version) yang menggunakan pre-trained weights dari dataset COCO guna mempercepat konvergensi. Pelatihan dilakukan selama 100 epoch menggunakan perangkat keras NVIDIA GeForce RTX 3050 dengan konfigurasi teknis yang disajikan pada Tabel 2. Parameter pelatihan ditetapkan sebagai berikut untuk menjamin replikasi:


1. *Input Resolution*: 640x640 piksel.
2. *Batch Size*: 16.
3. *Optimizer*: *Stochastic Gradient Descent (SGD)* dengan momentum 0.937.
4. *Learning Rate (lr)*: 0.01.
5. *Weight Decay*: 0.0005.

Tabel 2. Konfigurasi Hyperparameter Pelatihan Model YOLOv8s

Parameter	Nilai Konfigurasi	Keterangan
Model	YOLOv8s.pt	Varian small (pretrained COCO)
Input Resolution	640x640 pixels	Standar input YOLOv8
Batch Size	16	Kapasitas memori GPU
Optimizer	SGD	Stochastic Gradient Descent
Initial Learning Rate	0.01	Kecepatan pembelajaran awal
Momentum	0.937	Stabilitas gradien

Algoritma Pelacakan dan Logika Penghitungan

Sistem mengimplementasikan algoritma *Centroid Tracking* yang diintegrasikan dengan *DeepSORT* untuk memastikan setiap kendaraan hanya dihitung satu kali (mencegah perhitungan berulang atau *double counting*). Mekanisme penghitungan volume dipicu oleh penempatan garis virtual (*tripwire*) pada koordinat tertentu di layar video. Kendaraan yang melintas akan diberikan ID unik; ID tersebut hanya akan tercatat dalam log volume jika titik tengah (centroid) dari bounding box memotong garis virtual tersebut (Gambar 2).



Gambar 2. Visualisasi Penempatan Garis Virtual (*Tripwire*) pada Antarmuka Video YOLO

Metodologi Integrasi Parameter Pedoman Kapasitas Jalan Indonesia (PKJI) 2023


Logika sistem secara otomatis mengonversi deteksi visual dan perhitungan kendaraan menjadi satuan Mobil Penumpang (smp) menggunakan standar EMP PKJI 2023 (Tabel 3 dan Tabel 4) guna menghasilkan metrik Arus Lalu Lintas (Q), Kapasitas (C), dan Derajat Kejenuhan (DS).

1. Arus Lalu Lintas (Q)

Konversi jumlah kendaraan ke satuan Mobil Penumpang (smp) menggunakan nilai Ekuivalen Mobil Penumpang (EMP).


$$Q = \Sigma \text{Mobil} \times \text{EMP}_{mp} + \Sigma \text{Bus} \times \text{EMP}_{ks} + \Sigma \text{Truk} \times \text{EMP}_{ks} + \Sigma \text{Sepeda Motor} \times \text{EMP}_{sm} \quad (1)$$

Dimana $\Sigma Mobil$ adalah jumlah mobil yang melalui titik pengamatan (memotong garis virtual (*tripwire*)) pada pada layar video, EMP_{mp} adalah nilai EMP mobil penumpang, EMP_{sm} adalah nilai EMP sepeda motor dan EMP_{ks} adalah nilai EMP untuk kendaraan sedang. Alur kerja model YOLOv8 digambarkan sebagaimana pada alur kerja model YOLO berikut:



Gambar 3. Alur Kerja Sistem YOLO

Hasil perhitungan kendaraan yang terintegrasi dengan akan diteruskan pada laman perhitungan arus lalu lintas (Q) hingga pada perhitungan kinerja lalu lintas (LoS). Alur kerja system analisis kinerja lalu lintas terintegrasi dengan model YOLOv8 ditunjukkan pada gambar 4 berikut:



Gambar 4. Alur Kerja Sistem Analisis Kinerja Lalu Lintas.

Penentuan nilai EMP didasarkan pada tipe jalan yang akan dianalisis mengacu pada koefisien standar pada pedoman PKJI 2023 yang dikodifikasi dalam sistem perhitungan Arus (Q).

Tabel 3. Koefisien Ekuivalen Mobil Penumpang (EMP) untuk Tipe Jalan Tidak Terbagi

Tipe Jalan	Volume Lalu Lintas total dua arah (kend/jam)	EMP _{ks}	EMP _{sm}	
			Ljalur ≤ 6 m	Ljalur > 6 m
2/2 TT	<1800	1.3	0.5	0.40
	≥1800	1.2	0.35	0.25

Sumber: Direktorat Jenderal Bina Marga (2023).

Tabel 3. Penentuan Nilai EMP Tipe Jalan Terbagi

Tipe Jalan	Volume Lalu Lintas total dua arah (kend/jam)	EMP _{ks}	EMP _{sm}
4/2 T atau 2/1	<1050	1.3	0.40
	≥1800	1.2	0.25
6/2 T atau 3/1	<1100	1.3	0.40
8/2 T atau 4/1	≥1100	1.2	0.25

Sumber: Direktorat Jenderal Bina Marga (2023)

2. Perhitungan kecepatan arus bebas Mobil Penumpang (MP)

$$vB = (vBD + vBL) \times FVBHS \times FVUK \quad (2)$$

Dimana vB adalah kecepatan arus bebas, vBD adalah kecepatan arus bebas dasar, vBL adalah faktor penyesuaian akibat lebar jalur, $FVBHS$ adalah faktor penyesuaian akibat hambatan samping dan $FVUK$ adalah faktor penyesuaian akibat ukuran kota. Nilai vBD , vBL , $FVBHS$ dan $FVUK$ ditentukan berdasarkan tabel PKJI 2023. Pengukuran lebar jalur dan perhitungan hambatan samping dilakukan secara manual belum terakomodir dalam perhitungan model YOLO.

3. Kapasitas Jalan (C):

Menghitung kapasitas aktual berdasarkan geometri jalan yang diinput ke sistem.

$$C = C_0 \times F_{CL} \times F_{PA} \times F_{HS} \times F_{UK} \quad (2)$$

Dimana C_0 adalah kapasitas dasar; F_{CL} , F_{PA} , F_{HS} , F_{UK} adalah faktor penyesuaian lebar lajur, pemisahan arah, hambatan samping, dan ukuran kota. Koefisien masing-masing faktor penyesuaian ditentukan mengacu pada table-table ketentuan perhitungan kapasitas jalan perkotaan pada PKJI 2023 yang dikodifikasi ke dalam sistem perhitungan kapasitas (C).

4. Derajat Kejenuhan atau Degree of Saturation (DS)

Penentuan rasio arus lalu lintas dengan kapasitas.

$$DS = Q / C \quad (3)$$


Hasil nilai DS secara otomatis dipetakan ke dalam kategori *Level of Service (LoS)* A sampai dengan F yang ditampilkan pada dashboard secara real-time.

HASIL DAN PEMBAHASAN

Dari penelitian yang dilakukan telah dirancang bangun system analisis kinerja lalu lintas berbasis *Deep Learning* dimana perhitungan kendaraan model YOLOv8s terintegrasi dengan sistem analisis kinerja lalu lintas. Gambaran hasil dari proses pengemabgan sistem dijelaskan sebagai berikut;

Pelatihan, Evaluasi dan Validasi Model Deteksi Kendaraan YOLOv8

Hasil pelatihan model menunjukkan konvergensi fitur yang stabil sebagaimana divisualisasikan pada Gambar 5.;




Gambar 5. Grafik Metrik Pelatihan (Loss dan Akurasi) Selama 100 Epoch

Grafik pada gambar 5 menampilkan metrik pelatihan (*training*) dan validasi (*validation*) selama 100 *epoch*, yang merupakan periode waktu model belajar dari data. Secara umum, tren yang ditampilkan menunjukkan bahwa proses pelatihan berjalan dengan baik dan model telah berhasil belajar.

Loss Bounding Box yang mengukur seberapa baik model memprediksi lokasi dan ukuran kotak objek (*bounding box*). *Loss bounding box* terlihat menurun secara stabil, dimulai dari sekitar 1.2 dan berakhir di bawah 0.6. Ini menunjukkan bahwa model secara konsisten semakin baik dalam melokalisasi objek seiring berjalannya pelatihan. *Loss klasifikasi* mengukur seberapa baik model memprediksi kelas objek yang terdeteksi (misalnya, mobil, motor). *Loss klasifikasi* terlihat menurun secara stabil, dimulai dari sekitar 3.0 dan berakhir di bawah 0.5. Ini menunjukkan bahwa model semakin akurat dalam mengidentifikasi jenis objek. *Loss DFL (Distribution Focal Loss)* merupakan *Loss* tambahan untuk meregresi lokasi *bounding box* dengan lebih presisi, sangat umum di YOLOv8. *Loss DFL* menurun secara stabil, dimulai dari sekitar 1.6 dan berakhir di bawah 1.0. Menunjukkan peningkatan presisi lokasi objek.

Presisi *Bounding Box* menandakan proporsi prediksi positif yang benar (*True Positives*) dari semua prediksi positif yang dibuat (*True Positives + False Positives*). Presisi meningkat stabil, dimulai dari 0 dan mencapai sekitar 0.8. Ini berarti model memiliki tingkat kesalahan prediksi positif palsu (*False Positives*) yang rendah. *Recall (Bounding Box)* Proporsi objek aktual yang berhasil dideteksi (*True Positives*) dari semua objek yang ada (*Ground Truth*) meningkat secara stabil. Dimulai dari 0 dan mencapai sekitar 0.75-0.8. Ini menunjukkan model semakin baik dalam menemukan semua objek yang ada di data pelatihan. Presisi mengukur seberapa akurat hasil prediksi positif model. Dengan kata lain, dari semua kasus yang diprediksi model sebagai positif, berapa banyak yang benar-benar positif.

Recall (Sensitivitas atau True Positive Rate) mengukur kemampuan model untuk menemukan semua kasus positif yang relevan. *mAP* adalah metrik yang lebih kompleks, biasanya digunakan dalam Deteksi Objek (*Object Detection*). Ukuran ini merupakan rata-rata dari semua nilai *Average Precision (AP)* di semua kelas objek yang dideteksi oleh model. Nilai 0.941 (atau 94.1%) berarti bahwa dari semua hasil yang diklasifikasikan model sebagai benar (positif), 94.1% di antaranya adalah klasifikasi yang benar. Ini menunjukkan bahwa model memiliki tingkat kesalahan yang rendah dalam membuat prediksi positif palsu. Nilai *Recall* 0.935 (atau 93.5%) berarti bahwa dari semua kasus positif yang ada dalam data, 93.5% di antaranya berhasil diidentifikasi atau ditemukan oleh model. Ini menunjukkan bahwa model sangat baik dalam menghindari prediksi negatif palsu. Nilai *mAP@0.5* 0.948 menunjukkan bahwa secara keseluruhan, pada semua kelas objek yang dideteksi, model memiliki kinerja yang sangat kuat dan seimbang dalam hal presisi dan *recall*. Ini adalah indikator terbaik untuk kinerja model deteksi objek secara menyeluruh.



Gambar 6. Grafik Performa Model YOLOv8s

Berdasarkan grafik performa model YOLO menunjukkan konvergensi yang baik: performa meningkat cepat di awal dan stabil setelah beberapa epoch. Nilai *mAP* yang tinggi (>0.8) menunjukkan kemampuan deteksi yang solid. Nilai *mAP@50:95* yang lebih rendah (~ 0.5) menunjukkan bahwa model masih perlu ditingkatkan dalam hal presisi pada berbagai tingkat *IoU*.

Nilai mAP@0.5 mencapai rata-rata 0.948, namun kelas Truk menunjukkan performa paling rendah (Tabel 4). Hal ini dianalisis terjadi karena variasi geometri truk yang sangat luas (truk engkel, boks, hingga tronton) yang mempersulit model dalam mengekstraksi fitur visual yang homogen.

Tabel 4. Hasil Pengujian Akurasi Deteksi YOLOv8s per Kelas Kendaraan

Kelas Objek	Presisi (P)	Recall (R)	mAP@0.5
Mobil	0.872	0.824	0.873
Sepeda Motor	0.871	0.835	0.884
Bus	0.895	0.811	0.891
Truk	0.921	0.782	0.754
Rata-Rata (Overall)	0.941	0.935	0.948

Evaluasi Performa dan Validasi Sistem

Setelah sistem *backend* dan *frontend* dibuat dan dapat digunakan, selanjutnya dilakukan pengujian fungsional dengan metode black box testing. Pengujian pada kondisi malam hari (BBT-005) menunjukkan penurunan akurasi sebesar 9.5% akibat efek silau lampu depan kendaraan dan hilangnya fitur tekstur pada kondisi pencahayaan rendah (Tabel 5).


Tabel 5. Hasil pengujian fungsionalitas system dengan blak box testing

ID Uji	Skenario Uji	Hasil yang Diharapkan	Hasil Pengujian	Status
BBT-001	Unggah Video	Video dimuat & deteksi mulai	Berhasil terunggah	LULUS
BBT-005	Deteksi Malam	Identifikasi dengan lampu menyala	Berhasil (Akurasi - 9.5%)	LULUS*
BBT-010	Perhitungan Volume	Akurasi vs Data Manual (>95%)	Akurasi 96%	LULUS

BBT-001 menguji kemampuan sistem untuk mengambil input dan memulai proses analisis, maka berdasarkan gambar ini, fungsionalitas tersebut LULUS. BBT-005 menguji system deteksi kendaraan dengan catatan kendaraan menyalakan lampu. Berdasarkan pengujian BBT-010 jumlah kendaraan yang terdeteksi sebanyak 96% dari total kendaraan yang lewat.

Desain Antar Muka Sistem Analisis Kinerja Lalu Lintas

Berdasarkan penelitian dan analisis kebutuhan system, maka telah dibangun system analisis kinerja lalu lintas (SISTEM ANALISIS KINERJA LALU LINTAS) dengan tampilan halaman utama seperti pada gambar 7:



Gambar 7. Tampilan halaman utama system Analisis Kinerja Lalu Lintas (SISTEM ANALISIS KINERJA LALU LINTAS)

Kodifikasi sistem Dengan menggunakan *framework Streamlit*, pustaka *OpenCV (cv2)*, *Ultralytics YOLO* dan *PyTorch* beserta beberapa Pustaka dasar pada python, dibuat kodifikasi sistem analisis kinerja lalu lintas seperti pada gambar 8:

```
import streamlit as st
import cv2
import tempfile
import os
from ultralytics import YOLO
import torch
import datetime
import pandas as pd # Mengimpor Pandas untuk DataFrame
import numpy as np # Digunakan untuk Array numpy pada video

model = YOLO('yolov8.pt')
dict_classes = model.model.names

class_IDS = [0, 1, 2, 3, 5, 7]
conf_threshold = 0.5 # Ambang batas kepercayaan disetel ke 0.5

device = "cuda:0" if torch.cuda.is_available() else "cpu"


LINE_Y = 325
LINE_TOLERANCE = 5 # Toleransi piksel di sekitar garis untuk counting

def main():
    st.set_page_config(page_title="YOLOv8 Traffic Counter", layout="wide")
    st.title("Sistem Analisis Kinerja Lalu Lintas (YOLOv8)")
    st.markdown("""
    Unggah file video (mp4/avi) untuk melakukan deteksi objek (kendaraan dan pejalan kaki)
    dan menghitung volume yang melintasi garis *tripwire* (garis merah).
    """)

    uploaded_file = st.file_uploader("Pilih file video", type=["mp4", "avi"])
```


Gambar 8. Tangkapan layer kodifikasi halaman YOLO pada sistem

Tampilan halama perhitungan lalu lintas dengan YOLO berdasarkan kodifikasi sebelumnya dapat dilihat pada gambar berikut:




Gambar 9. Tampilan halaman Perhitungan Kendaraan dengan YOLOv8s

Hasil perhitungan kendaraan oleh model YOLO disajikan dalam bentuk data frame (tabulasi) pada halama Yolo setelah proses perhitungan selama durasi video selesai. Hasil perhitungan dengan jumlah tertinggi dengan warna paling gelap sepeti pada gambar 10.



Gambar 10. Tampilan halaman output Perhitungan Kendaraan dengan YOLO

Otomatisasi integratif ini divisualisasikan melalui dashboard dashboard Sistem Analisis Kinerja Lalu Lintas (Gambar 11) yang menyajikan grafik DS dan klasifikasi LoS secara dinamis.



Gambar 11. Tampilan Dashboard Sistem untuk Visualisasi Derajat Kejenuhan (DS) dan LoS

KESIMPULAN

Penelitian ini berhasil merancang sistem Analisis Kinerja Lalu Lintas yang mengintegrasikan *deep learning YOLOv8* dengan parameter standar Pedoman Kapasitas Jalan Indonesia (PKJI) 2023. Hasil pengujian menunjukkan model YOLOv8s memiliki performa deteksi solid dengan nilai mAP@0.5 sebesar 0.948, meskipun presisi lokalisasi masih memerlukan optimasi lebih lanjut. Sistem ini mampu mengotomatisasi perhitungan Arus Lalu Lintas (Q), Kapasitas (C), Derajat Kejenuhan (DS), dan Tingkat Pelayanan (LoS) dengan akurasi 96% dibandingkan metode survei manual. Penurunan akurasi 5-10% pada kondisi malam hari serta variasi geometri pada kelas Truk merupakan keterbatasan utama sistem saat ini. Selain itu, pengukuran geometrik jalan dan estimasi hambatan samping yang belum terakomodir pada sistem menjadi bagian yang perlu dikembangkan kedepannya. Secara keseluruhan, sistem Analisis Kinerja Lalu Lintas dapat diimplementasikan agar memberikan solusi pemantauan infrastruktur jalan yang efisien dan objektif bagi otoritas transportasi guna mendukung manajemen kota cerdas serta pengambilan kebijakan rekayasa lalu lintas yang lebih responsif terhadap dinamika kemacetan perkotaan secara real-time.

DAFTAR PUSTAKA

- Amir, A. A., Arsyad, M., Sukman, S., & Diansar, D. (2023). Analisis Karakteristik dan Tingkat Hambatan Samping Ruas Jalan D.I. Panjaitan Kota Kendari. *Jurnal Ilmiah Teknik Sipil*, 11(2), 77-84.. <https://doi.org/10.33019/fropil.v11i2.3940>
- Amir, A. A., & Suda, M. (2022). Analisa Karakteristik Dan Kebutuhan Ruang Parkir Mesjid Al Alam Kota Kendari. *Bandar: Journal Of Civil Engineering*, 4(2), 14–20.
- Ariyoga, D., Rahmadi, R., & Rajagede, R. A. (2021). Penelitian Terkini Tentang Sistem Pendeteksi Pelanggaran Lalu Lintas Berbasis Deep Learning: Sebuah Kajian Pustaka. *Prosiding Automata*, 2(1), 1-6.
- Direktorat Jenderal Bina Marga. (2023). *Pedoman Kapasitas Jalan Indonesia 2023*. <https://binamarga.pu.go.id/index.php/nspk/detail/09pbm2023-pedoman-kapasitas-jalan-indonesia->
- Ditlantas Polda Sultra. (2025). *Evaluasi Efektivitas Rekayasa Lalu Lintas di Wilayah Sultra*. <https://ditlantaspolDasultra.Com>. <https://ditlantaspolDasultra.com/evaluasi-efektivitas-rekayasa-lalu-lintas-di-wilayah-sultra/>
- Fadlan, F., Kamaruddin, K., & Arifai, A. (2024). Implementasi Traffic Accident Analisis Guna Menanggulangi Kecelakaan Lalu Lintas. *Journal Publicuho*, 7(3), 1389–1401. <https://doi.org/10.35817/publicuho.v7i3.497>
- Flores-Calero, M., Astudillo, C. A., Guevara, D., Maza, J., Lita, B. S., Defaz, B., Ante, J. S., Zabala-Blanco, D., & Armingol Moreno, J. M. (2024). Traffic Sign Detection and Recognition Using YOLO Object Detection Algorithm: A Systematic Review. *Mathematics*, 12(2), 297. <https://doi.org/10.3390/math12020297>
- Jakubec, M., Cingel, M., Lieskovska, E., & Drliciac, M. (2025). Integrating Neural Networks for Automated Video Analysis of Traffic Flow Routing and Composition at Intersections. *Sustainability*, 17(5), 2150. <https://doi.org/10.3390/su17052150>
- Jonathan, A., & Wasito, I. (2023). Perancangan Aplikasi Pengenalan Aksara Jawa Digital Menggunakan Convolutional Neural Network dan Computer Vision. *Decode: Jurnal Pendidikan Teknologi Informasi*, 3(2), 364–377. <https://doi.org/10.51454/decode.v3i2.209>
- Kamarudin, A. S., Saiful Bahri, I. S., Ibrahim, A., Tey, L. S., Kuan, W. K., Yahaya, N. N., & Ismail, A. P. (2025). Real-time traffic classification and volume count using automated image processing. *International Conference on Medical Imaging, Electronic Imaging, Information Technologies, and Sensors*, 13631. <https://doi.org/10.1117/12.3058750>
- Khadka, S., Wang, P. (Slade), Li, P. (Taylor), & Mattingly, S. P. (2025). Automated Traffic Signal Performance Measures (ATSPMs) in the Loop Simulation: A Digital Twin Approach. *Transportation Research Record: Journal of the Transportation Research Board*, 2679(1), 2129–2146. <https://doi.org/10.1177/03611981241258985>
- Kuang, S., Liu, Y., Qu, X., & Wei, Y. (2025). Traffic-IT: Enhancing Traffic Scene Understanding For Multimodal Large Language Models. *Transportation Research Part C: Emerging Technologies*, 180, 105325. <https://doi.org/10.1016/j.trc.2025.105325>
- Kusuma, N. T. R., Suarjaya, I. M. A. D. & Vihikan, W. O. (2024). Implementasi Metode YOLOv8 Pada Mobile Apps Untuk Klasifikasi Kain Endek Bali. *Decode: Jurnal Pendidikan Teknologi Informasi*, 4(3), 787–797. <https://doi.org/10.51454/decode.v4i3.610>
- Mahusin, N., Sallehudin, H., Satar, N. S. M., Aman, A. H. M., & Yahya, F. (2025). Modeling Cloud Computing Adoption and its Impact on the Performance of IT Personnel in the Public Sector. *International Journal of Advanced Computer Science and Applications*, 16(2).

<https://doi.org/10.14569/IJACSA.2025.0160242>

- Majumder, M., & Wilmot, C. (2023). Accuracy Assessment and Guidelines for Manual Traffic Counts from Pre-Recorded Video Data. *Journal of Transportation Technologies*, 13(04), 497–523. <https://doi.org/10.4236/jtts.2023.134023>
- Manual Kapasitas Jalan Indonesia. (1997). Manual Kapasitas Jalan Indonesia. *Manual Kapasitas Jalan Indonesia (MKJI)*, 7802112(264), 564. https://docs.google.com/file/d/0BxyPMnah6E_AZDZmMGM yNTEtYjljOS00Yjc3LWI0MTetZTRkOGQ3YjIhMjVj/edit
- 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>
- Muntiari, N. R., Nisa, I. C., Srikaningih, A., Prasetyo, A. Y. A., & Yusril, M. (2024). Penerapan Algoritma YOLOv8 Dalam Identifikasi Wajah secara Real-Time menggunakan CCTV untuk Presensi Siswa. *Decode: Jurnal Pendidikan Teknologi Informasi*, 4(3), 1155–1165. <https://doi.org/10.51454/decode.v4i3.847>
- Nanos, I. (2023). Cloud Computing Adoption in Public Sector: A Literature Review about Issues, Models and Influencing Factors. *Operational Research in the Era of Digital Transformation and Business Analytics*, 243–250. https://doi.org/10.1007/978-3-031-24294-6_26
- Naufaldihanif, R., Kurniawan, D., & Tania, K. D. (2025). Performance Analysis of YOLO, Faster R-CNN, and DETR for Automated Personal Protective Equipment Detection. *Journal of Applied Informatics and Computing*, 9(6), 3810–3820. <https://doi.org/10.30871/jaic.v9i6.11593>
- Prasiwiningrum, E., & Lubis, A. (2024). Classification Of Palm Oil Maturity Using CNN (Convolution Neural Network) Modelling RestNet 50. *Decode: Jurnal Pendidikan Teknologi Informasi*, 4(3), 983–999. <https://doi.org/10.51454/decode.v4i3.822>
- Suardika, B., Malkhamah, S., & Amrozi, M. R. F. (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>
- Subekti, J. N., & Putra, A. D. (2025). Deteksi Trafik Pada Jumlah Kendaraan Yang Lewat Di You See Indonesia Menggunakan Metode Yolov8. *Information System Journal*, 7(02), 78–86. <https://doi.org/10.24076/infosjournal.2024v7i02.1736>
- Tiwari, R., Rumaney, A. H., & Saravanan, M. (2023). Real-time Traffic Surveillance and Detection using Deep Learning and Computer Vision Techniques. *2023 2nd International Conference on Vision Towards Emerging Trends in Communication and Networking Technologies (ViTECoN)*, 1–6. <https://doi.org/10.1109/ViTECoN58111.2023.10157694>
- Afifah, V., & Erniwati, S. (2025). YOLOv8 for Object Detection: A Comprehensive Review of Advances, Techniques, and Applications. *IJACI: International Journal of Advanced Computing and Informatics*, 2(1), 53–61. <https://doi.org/10.71129/ijaci.v2i1.pp53-61>
- Wicaksono, B. A., Yuniar Purbasari, I., & Vita Via, Y. (2021). Deteksi Objek Mobil dan Motor pada Lalu Lintas Berbasis Deep Learning. *Jurnal Informatika Dan Sistem Informasi*, 2(2), 334–342. <https://doi.org/10.33005/jifosi.v2i2.284>
- Yin, X., Wu, G., Wei, J., Shen, Y., Qi, H., & Yin, B. (2022). Deep Learning on Traffic Prediction: Methods, Analysis, and Future Directions. *IEEE Transactions on Intelligent Transportation Systems*, 23(6), 4927–4943. <https://doi.org/10.1109/TITS.2021.3054840>
- Zheng, P., & Mike, M. (2012). An Investigation on the Manual Traffic Count Accuracy. *Procedia - Social and Behavioral Sciences*, 43, 226–231. <https://doi.org/10.1016/j.sbspro.2012.04.095>