

KAJIAN VOLUME LALU LINTAS PADA PERSIMPANGAN JALAN DENGAN METODE PENCITRAAN *IMAGE*

FALAH IKHLASUL NUHA¹, KAMALUDIN²

1. Mahasiswa, Institut Teknologi Nasional Bandung, Bandung, Indonesia
2. Dosen, Institut Teknologi Nasional Bandung, Bandung, Indonesia
Email: falahfin@gmail.com

ABSTRAK

Lalu lintas efisien dan aman adalah salah satu aspek penting dalam perencanaan dan pengelolaan infrastruktur transportasi perkotaan. Terutama terkait masalah pengelolaan kualitas indeks kelayakan jalan dan perhitungan kendaraan yang masih menggunakan cara manual yang rentan akan kesalahan. Penelitian ini mengintegrasikan teknologi deteksi objek terkini, YOLOv5, dengan analisis data lalu lintas harian rata-rata untuk nantinya dapat digunakan dalam berbagai bidang jalan, seperti perencanaan dan perbaikan jalan. melibatkan implementasi model YOLOv5 pada rekaman video CCTV ATCS dishub Bandung untuk mendeteksi dan menghitung jumlah kendaraan secara real-time. Data deteksi tersebut digunakan untuk menganalisis kinerja persimpangan jalan dengan mengukur derajat kejenuhan dan panjang antrian, sehingga dapat diperoleh indeks tingkat pelayanan pada persimpangan tersebut.

Kata Kunci : *Teknologi Deteksi Objek, YOLOV5, Kinerja persimpangan jalan, Indeks tingkat pelayanan persimpangan*

ABSTRACT

Efficient and safe traffic flow is a crucial aspect in the planning and management of urban transportation infrastructure. Particularly concerning the management of the road quality index and the manual vehicle counting methods that are susceptible to errors. This research integrates state-of-the-art object detection technology, YOLOv5, with the analysis of daily average traffic data for potential application in various road-related fields, such as road planning and improvement. The study involves implementing the YOLOv5 model on CCTV video recordings from the Bandung Transportation Agency's Advanced Traffic Control System (ATCS) to detect and real-time count the number of vehicles. The detected data is then used to analyze the performance of road intersections by measuring the degree of congestion and the length of queues, thereby obtaining an index of the level of service at these intersections.

Keywords : *Object Detection Technology, YOLOV5, Road intersection, Performance Intersection service level index*

1. PENDAHULUAN

Penentuan volume lalu lintas pada persimpangan jalan sering melibatkan metode manual untuk menghitung jumlah kendaraan yang melintas. Sukirman (1994) mendefinisikan volume lalu lintas sebagai banyaknya kendaraan yang melewati suatu titik atau garis pada penampang melintang jalan. Dalam konteks ini, teknologi deteksi objek dengan menggunakan metode deep learning seperti YOLO memberikan solusi efektif. Penggunaan citra dan deteksi objek memungkinkan identifikasi jenis kendaraan serta perhitungan volume lalu lintas secara akurat. Penerapan teknologi ini dalam transportasi tidak hanya memperbaiki efisiensi tetapi juga mendukung pengambilan keputusan untuk meningkatkan keselamatan transportasi.

2. METODOLOGI

Penelitian ini menggunakan model deteksi YOLOv5 dan aplikasi web interaktif Streamlit untuk alat deteksi berbasis *Python*. Bobot pendeteksian dilatih dengan nama "*best.pt*" menggunakan pelabelan manual melalui *roboflow*. Akurasi deteksi bobot dievaluasi dalam tiga skenario (bobot dilabeli, bobot default dari library deteksi, perhitungan manual tanpa deteksi) dan tiga kondisi (siang, malam, hujan) dengan kamera ATCS Kota Bandung. Uji akurasi dilakukan untuk mendapatkan nilai *recall* > 80%, dan pendeteksian menggunakan local web streamlit berhasil dilakukan. Data deteksi digunakan untuk menganalisis kinerja persimpangan jalan, mengukur derajat kejenuhan dan panjang antrian. Hasilnya memberikan indeks tingkat pelayanan pada persimpangan Sudirman-Otista.

3. ISI

3.1 Uji Akurasi Alat Deteksi

Langkah awal melibatkan perekaman lalu lintas melalui tiga video berdurasi lima menit dengan variasi cuaca dan waktu (siang cerah, malam, hujan) di Jalan Otista Bandung. Video direkam menggunakan ATCS. Data hasil rekaman disimpan dalam format mp4. Melalui konversi, didapatkan dataset berupa 472 gambar kendaraan, terbagi ke dalam tiga kategori: mobil penumpang (LV), kendaraan besar (HV), dan sepeda motor (MC). Dataset ini akan digunakan untuk pelabelan dan pelatihan jaringan.

Pelabelan Objek Kendaraan

Setelah pengumpulan data, dilakukan pelabelan objek pada frame sesuai format anotasi YOLO untuk melatih jaringan YOLOv5. Fokusnya pada mobil penumpang (LV), kendaraan besar (HV), dan sepeda motor (MC) melalui website roboflow dengan bounding box. Data dibagi menjadi train set (87%), valid set (8%), dan test set (4%). Dan dilakukan augmentasi dengan teknik Flip, Blur, dan rotasi 90° untuk variasi dataset pelatihan dan meningkatkan adaptabilitas model terhadap situasi yang beragam.

Pelatihan Jaringan

Setelah pelabelan dan augmentasi, dataset diekspor sebagai file zip. Setelah diekstrak, terdapat folder train, valid, dan test dengan citra lalu lintas. Google Colab digunakan untuk YOLOv5. Pada pelatihan dataset, file "data.yaml" diubah untuk kelas LV, HV, dan MC. Dilanjutkan dengan pelatihan YOLOv5 selama 100 epoch, mencapai tingkat keakuratan deteksi > 80%.

Proses Deteksi Jaringan *Streamlit*

Setelah pelatihan YOLOv5 dan pengunduhan data dari repository npq-thien, dilakukan penggantian weight "best.pt" dengan model yang telah dilatih. Beberapa file Python seperti track.py dan demo.py diubah untuk mencocokkan kelas data, yang fokus pada satuan mobil penumpang sebelumnya. Setelah penyuntingan file, dibuat input data multi-halaman pada

Streamlit untuk local web, termasuk halaman deteksi. **Gambar 1** menunjukkan tampilan halaman yang telah dimasukkan.



Gambar 1. Tampilan Deteksi pada Streamlit (Sumber : Streamlit)

Pengujian Akurasi Deteksi

Sebelum uji coba, folder frame disiapkan untuk setiap skenario pengujian menggunakan Vegas Pro 21 Trial Version. Diambil frame deteksi kendaraan pada lalu lintas padat dari tiga skenario: skenario 1 (hasil latih dan pelabelan), skenario 2 (bobot default dari GitHub), dan skenario 3 (counting manual). Dengan menggunakan "best.pt" yang telah dilabeli, diambil 5 frame gambar lalu lintas padat dari setiap skenario, dan folder khusus dibuat untuk menguji keakuratan performa jaringan pada setiap skenario. **Tabel 1** menampilkan contoh frame untuk setiap kasus.

Tabel 1. Perhitungan Kendaraan Tiap Skenario Dan Kasus

Total Tiga Skenario dan kasus	Kasus Satu/Dua/Tiga Waktu Siang Cerah/Waktu Malam/Cuaca Hujan		
	Skenario 1 (pelabelan)	Skenario 2 (default)	Skenario 3 (manual)
MC : $\sum TP1$ LV : $\sum TP2$ HV : $\sum TP3$	Frame deteksi kasus 1/2/3	Frame deteksi kasus 1/2/3	Frame deteksi kasus 1/2/3
	MC : TP1	MC : TP1	MC : TP1
	LV : TP2	LV : TP2	LV : TP2
	HV : TP3	HV : TP3	HV : TP3
Total			
MC Aktual : $\sum_{i=1}^n TP1$	MC Prediksi: $\sum_{i=1}^n TP1$	MCD : $\sum_{i=1}^n TP1$	
LV Aktual : $\sum_{i=1}^n TP2$	LV Prediksi: $\sum_{i=1}^n TP2$	LVD : $\sum_{i=1}^n TP2$	
HV Aktual : $\sum_{i=1}^n TP3$	HV Prediksi: $\sum_{i=1}^n TP3$	HVD : $\sum_{i=1}^n TP3$	
	Tidak Terdeteksi		Salah deteksi1
MC	$\sum FN1$	$\sum FND1$	$\sum FP12$ (MC)
LV	$\sum FN2$	$\sum FND2$	$\sum FP21$ (LV)
HV	$\sum FN3$	$\sum FND3$	$\sum FP31$ (HV)
			Salah Deteksi2 $\sum FP12$ (MC)
			$\sum FP21$ (LV)
			$\sum FP31$ (HV)

Pada langkah selanjutnya adalah melakukan perhitungan *Confusion Matrix* bersama dengan nilai-nilai *Precision*, *Recall*, dan *F1 Score* untuk semua skenario dan bobot. Dalam tabel ini, akan dihitung jumlah total objek aktual dan hasil deteksi pada kedua video dari dataset penulis, kemudian dibuat tabel *Confusion Matrix* serupa dengan **Tabel 2**.

Tabel 2. Confusion Matrix

Confusion Matrix		Aktual		
		MC	LV	HV
Prediksi	MC	TP_1	F_{21}	F_{31}
	LV	F_{12}	TP_2	F_{32}
	HV	F_{13}	F_{23}	TP_3
	Tidak Terdeteksi	F_{14}	F_{24}	F_{34}

Kesimpulan mengenai tingkat akurasi akan diambil berdasarkan hasil pengujian yang telah diperoleh. Berikut persamaan 1 hingga persamaan 6 mengenai perhitungan akurasi deteksi.

$$\text{True Positive} = TP_1 + TP_2 + TP_3 \quad (1)$$

$$\text{False Positive} = F12 + F13 + F14 + F21 + F23 \quad (2)$$

$$F24 + F31 + F32 + F34$$

$$\text{False Negative} = FNMC + FNLV + FNHV \quad (3)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (4)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (5)$$

$$\text{F1 Score} = 2 \times \left(\frac{(\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \right) \quad (6)$$

Dimana, TP *True Positives* (deteksi benar), F *False Positives* (salah deteksi), *False Negatives* (tidak terdeteksi), FNMC *False Negative Motorcycle* FNLV *False Negative Light Vehicle*, FNHV *False Negative Heavy Vehicle*, *Recall* kemampuan model klasifikasi untuk mengidentifikasi semua titik data di kelas yang relevan, *Precision* kemampuan model klasifikasi untuk mengembalikan hanya titik data dalam suatu kelas. *F1 Score* metrik tunggal yang menggabungkan perolehan dan presisi menggunakan mean harmonik.

Analisis Akurasi Deteksi

Berdasarkan hasil dari kedua skenario dan ketiga kasus waktu siang, malam dan cuaca hujan maka akan dilakukan Analisis mengenai tingkat akurasi dan kelayakan dengan rangkuman tabel performa jaringan untuk memudahkan tiap perbandingan dari ketiga kasus dan analisis, maka disusunlah ringkasan performa berhasil terdeteksi oleh model pada setiap dataset, sebagaimana terlihat dalam **Tabel 3**.


Tabel 3. Ringkasan Performa Jaringan

Dataset Kasus	Bobot Jaringan	Performa Jaringan					
		TP	FP	FN	Precision	Recall	F1 Score
Waktu Siang	Skenario Satu	67	0	0	1	1	1
	Skenario Dua	24	1	42	0,96	0,36	0,52
	Skenario Tiga (manual)	67	-	-	1	1	1
Waktu Malam	Skenario Satu	61	0	4	1	0,94	0,97
	Skenario Dua	1	0	64	1	0,02	0,039
	Skenario Tiga	65	-	-	1	1	1
Cuaca Hujan	Skenario Satu	47	0	2	1	0,96	0,98
	Skenario Dua	27	0	24	1	0,51	0,68
	Skenario Tiga (manual)	50	-	-	1	1	1

Dalam pengujian dengan berbagai bobot jaringan pada skenario 1, 2, dan 3 pada waktu siang dan malam, terdapat perbedaan performa yang signifikan. Sebagai contoh, skenario 1 (waktu siang) dibandingkan dengan skenario 2 (default) menunjukkan penurunan yang signifikan pada Precision sekitar 0,96, Recall sekitar 0,36, dan F1 Score sekitar 0,52. Hasil menunjukkan bahwa bobot jaringan pada skenario 1 memiliki nilai True Positive tertinggi, dengan Recall yang lebih tinggi, menunjukkan efektivitas dalam mendeteksi kendaraan pada dataset penelitian.

3.2 Penentuan Volume Lalu Lintas Pada Persimpangan Jalan Pengumpulan Data Lapangan

Hasil perbandingan frame pada kasus dan skenario deteksi kendaraan menunjukkan deteksi yang telah diuji. Pengambilan data dilakukan di persimpangan Jalan Sudirman – Otista. Jiwa Sketsa geometri simpang jalan Sudirman – Otista dapat dilihat pada **Gambar 2**.



Gambar 2. Denah Lokasi Penelitian

Pada persimpangan jalan Sudirman-Otista arah 1 (utara) dan arah 2 (timur), terdapat tipe lebar pendekat, Sudirman-Otista (utara) dan Sudirman-Otista (timur) yaitu terlindung.

Pengumpulan Data Volume LHR

Survei lalu lintas dilakukan selama satu minggu dari 18-24 Desember pada jam sibuk (pagi, siang, malam) pukul 07.00 – 08.00 WIB, Siang hari pukul 12.00 – 13.00 WIB, Malam hari pada pukul 16.00 – 18.00 WIB. Lebar jalan 7 m. Jika volume total >1100 kendaraan dan lebar jalan >6 m, EMP diperoleh (LV=1 cm, HV=1,2, MC=0,25). Volume total 1 jam dihitung dengan persamaan 7.

$$Q_{smp} = (emp_{LV} \times LV + emp_{HV} \times HV + emp_{MC} \times MC) \quad (7)$$

Selanjutnya, untuk hari berikutnya, rata-rata jumlah kendaraan maksimum dihitung dari data volume LHR pada arah 1 (utara) dan arah 2 (timur), termasuk belok kiri dan lurus pada kedua arah tersebut.

Kondisi Sinyal dan Geometrik Simpang

Pengamatan kondisi persimpangan mencakup evaluasi terhadap sistem sinyal lalu lintas, termasuk alokasi waktu siklus dan fungsi operasionalnya. Pengumpulan data waktu siklus dilakukan sepanjang satu hari, termasuk selama jam sibuk dan di luar jam sibuk. Dimana Lama waktu hijau (g),50 detik, lama waktu kuning 4 detik ,lama waktu merah 40 detik.

Analisa Data

Dari kumpulan data sebelumnya dibuat analisa data untuk mengetahui indeks tingkat pelayanan jalan yang akan digunakan nantinya pada saat perencanaan jalan dan perbaikan jalan. Berikut **Tabel 4.** mengenai ringkasan data dan hasil indeks tingkat pelayanan jalan pada jalan.

Tabel 4. Ringkasan Data dan Hasil Indeks Tingkat Pelayanan Jalan Utara

ARAH UTARA	Total	Q	ARAH TIMUR	Total	Q
LURUS (ST)	1113	1910	LURUS (ST)	1009	1910
BELOK KIRI (LT)	797		BELOK KIRI (LT)	798	
So	4200	smp/jam hijau	So	4200	smp/jam hijau
S	3990	smp/jam hijau	S	3990	smp/jam hijau
C	2347,059	smp/jam	C	2347,059	smp/jam
Ds	0,814	smp/jam	Ds	0,770	smp/jam
NQ1	1,675	smp/jam	NQ1	1,169	smp/jam
NQ2	55,401	smp/jam	NQ2	55,409	smp/jam
ΣNQ	57,076	smp/jam	ΣNQ	56,578	smp/jam
DT	27,718	det/smp	DT	25,75	det/smp

Dimana pada **Tabel 4** didapatkan data simpang arah utara yaitu data total smp/jam arah lurus 1113 smp/jam dan belok kiri 797 smp/jam, dari data total tersebut didapatkan data Q, So, S,

C, Ds, NQ1, NQ2, ΣNQ, dengan Tundaan lalu lintas 27,718 det/smp arah utara dan timur 25,75 det/smp, tundaan ≥ 60,0 det/smp tingkat pelayanan D. Berikut perhitungan untuk mendapatkan data tersebut dari persamaan 8 sampai 11,

$$Q = \sum ST + \sum LT \quad (8)$$

$$So = 600 \times We \quad (9)$$

$$S = So \times FCCS \times FSF \times FG \times Fp \quad (10)$$

$$C = S \times \frac{G}{c} \quad (11)$$

$$Ds = \frac{Q}{c} \quad (12)$$

$$NQ1 = 0,25 \times C \times \left[(DS - 1) + \sqrt{(DS - 1)^2 + \frac{8 \times (DS - 0,5)}{c}} \right] \quad (13)$$

$$NQ2 = c \times \frac{1 - GR}{(1 - GR) \times DS} \times \frac{Q}{3600} \quad (14)$$

$$DT = C \times \frac{0,5 \times 1 - GR^2}{1 - GR \times DS} + \frac{NQ1}{c} \times 3600 \quad (15)$$

Berdasarkan Hasil DT Oleh indeks tingkat pelayanan tundaan lalu lintas dari persimpangan sudirman-otista rata-rata mendapatkan nilai D.

4. KESIMPULAN

Dibangun dua model deteksi kendaraan dengan YOLOv5 menggunakan dua skenario pelabelan kelas yang berbeda: skenario satu (dengan bobot hasil pelabelan) dan skenario dua (bobot default). Model pada skenario pertama ("best.pt" dari pelabelan Roboflow) menunjukkan kinerja tinggi, dengan Precision, Recall, dan F1 Score di atas 80% untuk tiga kasus (siang cerah, malam, hujan). Hasil pengujian menunjukkan akurasi yang memadai untuk menentukan volume lalu lintas di persimpangan jalan Sudirman Otista. Evaluasi volume lalu lintas menyarankan pertimbangan perubahan konfigurasi untuk mengurangi tundaan dan mempertahankan indeks tingkat pelayanan D.

DAFTAR RUJUKAN

- Amwin, A. (2021). *Deteksi Dan Klasifikasi Kendaraan Berbasis Algoritma You Only Look Once (YOLO)*.
- Artiani, G. P., & Azhiary, R. (2019). *Upaya Perbaikan Kinerja Simpang Empat Bersinyal Pada Jalan Duren Tiga Selatan Dengan Metode Pedoman Kapasitas Jalan Indonesia (PKJI) 2014* (Vol. 16).
- Khatami, S. M. (2022). *DETEKSI KENDARAAN MENGGUNAKAN ALGORITMA YOU ONLY LOOK ONCE (YOLO) V3*.
- MKJI. (1997). *Manual Kapasitas Jalan Indonesia 1997*. Direktorat Jenderal Binamarga.
- US-HCM. (1985). *HIGHWAY CAPACITY MANUAL PROJECT (HCM)*.