

Analisis Beban Kendaraan Terhadap Karakteristik Jalan Menggunakan Metode YOLOv5 Dan Perhitungan ESAL

DOI: <http://dx.doi.org/10.35889/jutisi.v14i2.2713>

Creative Commons License 4.0 (CC BY – NC) 

Melifan Wanda^{1*}, Agustinus Rudatyo Himamunanto², Haeni Budiati³
 Teknik Informatika, Universitas Kristen Immanuel, Yogyakarta, Indonesia
 *e-mail *Corresponding Author*: melifan.wanda@mail.ukrim.ac.id

Abstract

Roads are essential infrastructure supporting various types of vehicles; however, excessive loads are a primary cause of surface damage. The increasing volume of vehicles and imbalanced infrastructure development contribute significantly to road deterioration, leading to a reduction in road service life and increased maintenance costs. This study aims to address these issues by developing a system for vehicle detection, classification, and load estimation using the YOLO (You Only Look Once) algorithm a deep learning method capable of detecting and classifying vehicle objects in real time with high speed and accuracy. The data were obtained from CCTV surveillance video recordings. The results indicate that a total of 4,395 vehicles were successfully detected. These detections were then used to estimate the vehicle load using the Equivalent Single Axle Load (ESAL) method. The estimated total daily traffic reached 632,880 vehicles, with a corresponding daily load estimation of 284,214.74 ESAL. The findings highlight the significant impact of vehicle loads on road characteristics and demonstrate the effectiveness of YOLOv5 as a real time tool for monitoring and detecting vehicular load.

Keywords: *Computer Vision; YOLOv5; Vehicle detection; Vehicle load; Equivalent Single Axle Load*

Abstrak

Jalan merupakan infrastruktur yang penting dalam menopang berbagai jenis kendaraan, namun beban berlebih menjadi penyebab utama kerusakan permukaan pada jalan. Volume kendaraan yang meningkat dan pembangunan infrastruktur yang tidak seimbang menyebabkan kerusakan pada jalan yang menyebabkan pengurangan umur jalan dan meningkatkan biaya perbaikan. Penelitian ini bertujuan untuk mengatasi permasalahan tersebut yaitu dengan membangun Pendeteksi, Klasifikasi dan menghitung beban kendaraan berbasis Algoritma YOLO (*You Only Look Once*), sebuah algoritma *deep learning* yang mampu mendeteksi dan mengklasifikasikan objek kendaraan secara *real-time* dengan kecepatan dan akurasi yang sangat baik. Data yang digunakan diambil dari rekaman video pengawas CCTV. Hasil penelitian menunjukkan kendaraan yang terdeteksi sebanyak 4.395 unit, kendaraan yang berhasil terdeteksi kemudian dilakukan untuk perhitungan estimasi beban kendaraan menggunakan perhitungan *Equivalent Single Axle Load* (ESAL). Hasil terhitung dengan total lalu lintas harian mencapai 632.880 unit kendaraan dengan estimasi beban harian sebesar 284.214,74 ESAL. Hasil penelitian menegaskan adanya pengaruh signifikan beban kendaraan terhadap karakteristik jalan serta menunjukkan efektivitas YOLOv5 sebagai alat dalam memantau dan mendeteksi beban kendaraan secara *real time*

Kata Kunci: *Computer Vision; YOLOv5; Deteksi kendaraan; Beban kendaraan; Equivalent Single Axle Load*

1. Pendahuluan

Seiring dengan bertambahnya jumlah penduduk, kebutuhan akan mobilitas manusia juga mengalami peningkatan [1]. Peningkatan mobilitas ini mendorong bertambahnya jumlah kendaraan, baik kendaraan pribadi maupun kendaraan umum. Namun pertambahannya jumlah kendaraan tidak seimbang dengan Pembangunan infrastruktur jalan secara optimal yang menyebabkan ketidakseimbangan antara kapasitas jalan dan volume lalu lintas kendaraan [2],

[3], [4]. Ketidakseimbangan ini tidak hanya menghambat kelancaraan lalu lintas, tetapi juga meningkatkan risiko kecelakaan lalu lintas serta mempercepat terjadinya kerusakan dini pada permukaan jalan [5], [6].

Teknologi berbasis *Computer Vision* semakin banyak digunakan untuk menunjang pengumpulan data kendaraan secara otomatis pendekatan yang diterapkan berbasis *deep learning*, yang menawarkan solusi efisien dan akurat dalam mendeteksi kendaraan. Salah satu algoritma yang saat ini banyak digunakan dalam pengolahan citra adalah YOLOv5 (*You Only Look Once version 5*) [7],[8],[1]. Kemampuan YOLOv5 dalam mendeteksi berbagai jenis kendaraan secara cepat dan akurat, bahkan dalam lalu lintas yang padat atau saat kendaraan bergerak dengan kecepatan yang tinggi, menjadikannya sangat ideal untuk kebutuhan analisis transportasi modern [9], [2]. Kemampuan YOLOv5 melakukan deteksi objek secara *real-time* dengan tingkat akurasi yang cukup baik dan mampu bekerja tanpa memerlukan pemrosesan yang rumit menjadikannya pilihan yang sangat baik untuk berbagai tugas deteksi dan klasifikasi objek [2], [8].

Fokus penelitian adalah penggunaan model YOLOv5 dalam deteksi jenis kendaraan serta mengklasifikasikan setiap kelas kendaraan. Penelitian yang dilakukan menggunakan deteksi objek dalam data gambar dan video secara *real time*, gambar yang digunakan diambil dari kamera pengawas, seperti CCTV [10]. Hasil yang telah terdeteksi akan digunakan untuk perhitungan estimasi beban kendaraan sehingga data yang dihasilkan dapat memberikan gambaran awal yang cukup baik tentang beban kendaraan yang melewati ruas jalan tertentu. Penelitian yang dilakukan juga mempertimbangkan aspek jalan seperti jenis jalan (arteri, kolektor, lokal), serta jenis permukaan jalan (aspal) dan intensitas penggunaan jalan oleh kendaraan. Elemen-elemen ini tidak dihitung secara struktural seperti ketebalan atau kualitas material, namun tetap digunakan untuk mendukung interpretasi hasil deteksi kendaraan dan estimasi beban kendaraan. Dengan mempertimbangkan aspek jalan, hasil penelitian ini dapat digunakan untuk mengevaluasi bagaimana beban kendaraan mempengaruhi jenis jalan tertentu, khususnya jalan yang sering dilalui oleh kendaraan berat.

Melalui penelitian yang dilakukan, diharapkan dapat menemukan solusi yang lebih efektif dalam memantau kondisi lalu lintas dan menganalisis apakah beban kendaraan berpengaruh terhadap kondisi jalan. Dengan memanfaatkan teknologi deteksi berbasis YOLOv5, hasil penelitian ini dapat membantu pengambilan keputusan yang lebih tepat dalam perencanaan dan pemeliharaan infrastruktur jalan. Selain itu, penelitian ini diharapkan dapat memberikan kontribusi dalam mengoptimalkan manajemen lalu lintas dan perbaikan jalan, dengan menggunakan data yang lebih akurat dan relevan.

2. Tinjauan Pustaka

Penelitian oleh Iskandar & Rofik [1] menggunakan metode YOLOv5 untuk mendeteksi berbagai jenis kendaraan dengan akurasi mencapai 90% dari dataset 1.332 gambar. Data tersebut digunakan untuk menentukan prioritas pelebaran jalan. Dwiyanto et al. [11] juga mengembangkan sistem deteksi kendaraan berbasis YOLOv5 dan *deep learning* untuk mengatasi kemacetan lalu lintas. Pengujian dilakukan dengan data CCTV dan menghasilkan akurasi sebesar 90% dan 79,8% pada siang hari. Hasil ini menunjukkan efektivitas metode YOLOv5 dalam deteksi kendaraan secara *real-time*.

Penelitian lain [12] menggabungkan metode YOLOv5 dengan CNN dan *easy OCR* untuk mendeteksi kendaraan dan mengenali plat nomor. Sistem diuji menggunakan data gambar dan video dari CCTV, dengan akurasi 90% untuk deteksi kendaraan dan 79,8% untuk pembacaan plat nomor. Data yang diperoleh digunakan sebagai dasar pengawasan manajemen lalu lintas. Sementara itu, penelitian oleh [13] memanfaatkan metode YOLOv5 dan DeepSORT untuk pelacakan objek kendaraan secara otomatis. Hasil model mencapai *precision* 99%, *recall* 97%, dan akurasi 96,8%, yang mendukung pemantauan emisi lalu lintas secara *real-time*.

Penelitian selanjutnya [14] mengembangkan sistem pemantauan kerusakan jalan tol dan pelanggaran lalu lintas yang dapat mengirim notifikasi secara *real-time* melalui website berbasis Flask. Sistem ini mampu mengklasifikasikan objek dengan akurasi 98,04% di siang hari dan 93,29% di malam hari. Selain itu, penelitian pada ruas jalan Palembang–Labangka [15] menganalisis beban berlebih menggunakan data kendaraan per jam berdasarkan metode MKJI. Ditemukan bahwa beban mencapai 69,3 ton dari 300 kendaraan per jam, yang menyebabkan kerusakan jalan. Studi-studi ini memperlihatkan peran penting deteksi kendaraan dalam manajemen lalu lintas dan infrastruktur jalan.

Penelitian lainnya [16] mengevaluasi dampak infrastruktur jalan dan kepadatan penduduk terhadap pendapatan per kapita di 10 provinsi Sumatera selama 2015–2022 menggunakan metode Random Effect Model. Hasilnya menunjukkan bahwa infrastruktur jalan berpengaruh negatif terhadap pendapatan per kapita, sementara kepadatan penduduk memberikan pengaruh positif dan signifikan. Sebagian besar studi terdahulu fokus pada deteksi kendaraan, pelacakan objek, dan pengawasan lalu lintas. Belum banyak yang mengintegrasikan sistem deteksi kendaraan berbasis YOLOv5 dengan analisis teknis beban lalu lintas terhadap kerusakan jalan melalui metode ESAL. Penelitian ini hadir sebagai inovasi dengan pendekatan interdisipliner antara teknologi informasi dan teknik sipil, serta memberikan kontribusi konkret dalam perencanaan pemeliharaan jalan dan manajemen transportasi berbasis data.

3. Metodologi

Pada bagian ini akan dibahas metode yang digunakan dalam penelitian yang dirancang untuk memastikan tercapainya tujuan dari penelitian yang dilakukan, yaitu pengembangan sistem deteksi kendaraan yang akurat dan efisien.



Gambar 3. Flowchart Proses Analisis Beban Kendaraan terhadap Karakteristik Jalan menggunakan Metode YOLOv5

3.1 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini terdiri dari 1.000 citra kendaraan yang diperoleh dari berbagai sumber. Sebagian besar data diambil dari repository daring seperti Kaggle (<https://www.kaggle.com/datasets?search=jenis+kendaraan>), sebagian data dikumpulkan secara langsung melalui proses dokumentasi lapangan. Dataset mencakup berbagai jenis kendaraan untuk memastikan keragaman dari data yang digunakan sebagian pelatihan model deteksi.

3.2. Penlabelan Data

Pelabelan dilakukan menggunakan alat anotasi seperti Labelling serta menggunakan *bounding box* untuk menandai area objek yang akan dideteksi.



Gambar 2. Pendeteksian Jenis Kendaran

3.3. Pembagian Dataset

Untuk Dataset yang telah dilabelling dibagi menjadi tiga bagian yaitu *training* set, *validation* set, dan *testing* set. Pembagian dilakukan dengan rasio 70% untuk *training*, 20% untuk validasi, dan 10% untuk testing, untuk memastikan model dapat belajar dan diuji secara efektif.

3.4. Pelatihan YOLOv5

Model YOLOv5 *pre-trained* (best.pt) dilatih ulang selama 100 *epochs* menggunakan dataset yang telah disiapkan, agar bobot model menyesuaikan dengan data spesifik kendaraan yang digunakan.

3.5. Pelatihan Model YOLOv5

Proses pelatihan model menggunakan YOLOv5 dilakukan dengan Visual Studio Code sebagai *platform*. Model dilatih dengan dataset *training* melalui sejumlah *epoch* secara bertahap untuk mengoptimalkan parameter-parameter internal. Seluruh proses *training* dijalankan menggunakan bahasa pemrograman *Python*.

3.6. Pengujian Sistem

Setelah pelatihan selesai, model diuji menggunakan dataset testing untuk mengevaluasi performanya. Dataset testing digunakan untuk menilai akurasi model dalam mendeteksi jenis kendaraan pada data yang belum pernah dilihat sebelumnya. Proses testing ini juga dilakukan menggunakan *Python* dan dijalankan pada Visual Studio Code.

3.7 Evaluasi dan Pengujian Model

Langkah terakhir adalah evaluasi model, di mana performa model diukur menggunakan metrik evaluasi seperti *Akurasi Precision*, *Recall*, dan *mean Average Precision (mAP)*. Evaluasi ini memberikan gambaran tentang seberapa baik model YOLOv5 dapat mendeteksi kendaraan dengan tingkat akurasi yang baik.

3.8. Estimasi Berat kendaraan

Perhitungan estimasi berat kendaraan yang terdeteksi oleh YOLOv5 akan digunakan untuk menghitung berapa total beban lalu lintas yang melintas pada ruas jalan yang digunakan [17]. Perhitungan yang dilakukan menggunakan rumus:

Tabel 1. Estimasi Berat Kendaraan

Jenis Kendaraan	Berat Standar (Ton)
Bus	0.2
Mobil	1.5
Motor	15.0
Truk	10.0

3.9 Estimasi Beban Lalu Lintas dalam satuan ESAL

Untuk mengetahui seberapa besar dampak lalu lintas terhadap umur rencana perkerasan jalan, diperlukan konversi jumlah kendaraan ke dalam satuan (*Equivalent Single Axle Load*). Konversi yang dilakukan mengacu pada standar bina marga, dimana setiap kendaraan memiliki faktor ESAL yang berbeda tergantung pada besarnya beban yang diberikan terhadap perkerasan jalan [18].

1) Konversi Jumlah Kendaraan Ke Lalu Lintas Harian Rata-rata (LHR)

Lalu Lintas Harian Rata-rata adalah volume lalu lintas dua arah yang melewati suatu titik tertentu secara rata-rata dalam satu hari, biasanya dihitung sepanjang tahun.

Rumus Konversi:

$$LHR_j = \frac{N_j}{t} \quad (1)$$

Keterangan :

LHR_j = Lalu lintas harian rata rata kendaraan jenis -j

t = durasi pengamatan dalam menit

N_j = Jumlah kendaraan jenis ke-j selama periode observasi

2) *Load Equivalency Factor (LEF)*

Load Equivalency Factor (LEF) adalah faktor yang digunakan untuk menyetarakan atau mengkonversi beban sumbu kendaraan tertentu ke dalam beban sumbu standar yang digunakan sebagai acuan dalam perancangan perkerasan jalan. LEF menggambarkan rasio kerusakan yang disebabkan oleh satu lintasan sumbu kendaraan tertentu dibandingkan dengan kerusakan yang disebabkan oleh satu lintasan sumbu standar (biasanya sumbu tunggal dengan beban 18 kip atau sekitar 80 kN)

Rumus:

$$LEF_i = \left(\frac{P_i}{P_{std}}\right)^4 \tag{2}$$

Keterangan:

LEF_i = Faktor kerusakan sumbu ke-i

P_i = Beban sumbu ke-i (dalam ton)

P_{std} = Beban sumbu standar = 8.16 ton

3) Adapun perhitungan ESAL Per Kendaraan

$$ESAL_t = N \times LEF \tag{3}$$

Keterangan :

N= Jumlah Kendaraan dari jenis tertentu.

$ESAL_t$ = Total ekivalen beban sumbu standar per kendaraan

4) Perhitungan Total ESAL harian

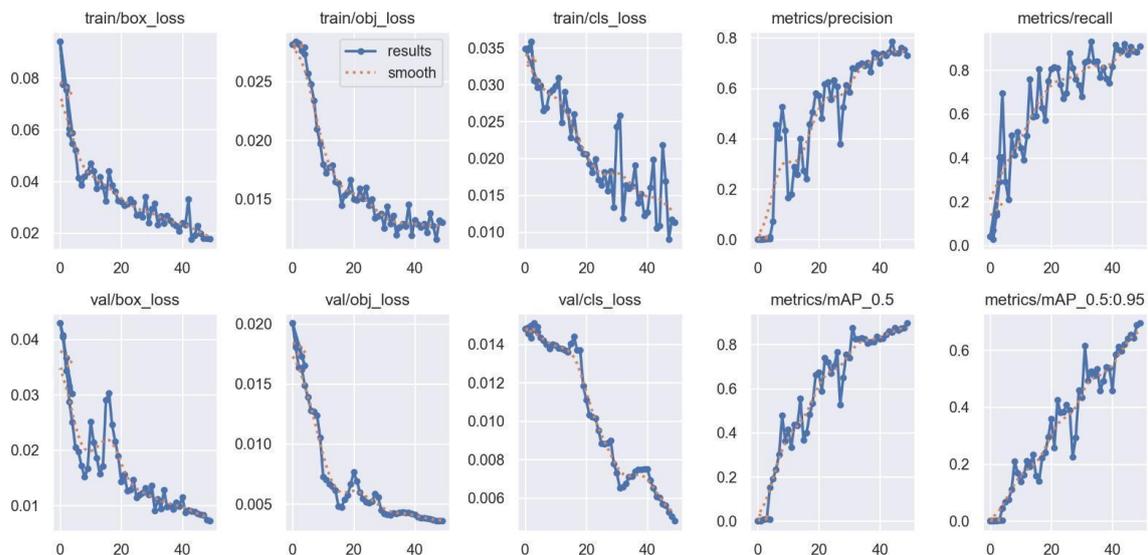
$$ESAL_{\text{harian}} = \frac{ESAL_t}{t} \times 1440 \tag{4}$$

Hasil ini digunakan untuk menghitung total kerusakan harian terhadap perkerasan jalan berdasarkan beban kendaraan yang melintas.

4. Hasil dan Pembahasan

4.1 Hasil Pengujian

Hasil pengujian menunjukkan bahwa model YOLOv5 mampu mendeteksi kendaraan dengan performa yang sangat baik. Nilai *precision* rata-rata mencapai 0,995, mencerminkan akurasi tinggi dalam mendeteksi objek kendaraan.



Gambar 3. Grafik Box Loss

Gambar 3 menunjukkan penurunan nilai loss saat training dilakukan, yang mengidentifikasi model yang dilatih telah belajar mengenali objek dengan baik.

Pada *confidence threshold* 0,734, *precision* mencapai 100%, menandakan seluruh deteksi model benar tanpa adanya kesalahan positif (*false positives*). Selain itu, nilai *recall* juga mencapai 100%, yang berarti model mampu mendeteksi seluruh objek yang relevan tanpa ada yang terlewat (minim *false negatives*). *F1 Score* sebesar 0,95 menunjukkan keseimbangan optimal antara *precision* dan *recall*. Secara keseluruhan, ketiga metrik ini mengindikasikan bahwa model memiliki kinerja deteksi yang sangat baik dan andal.

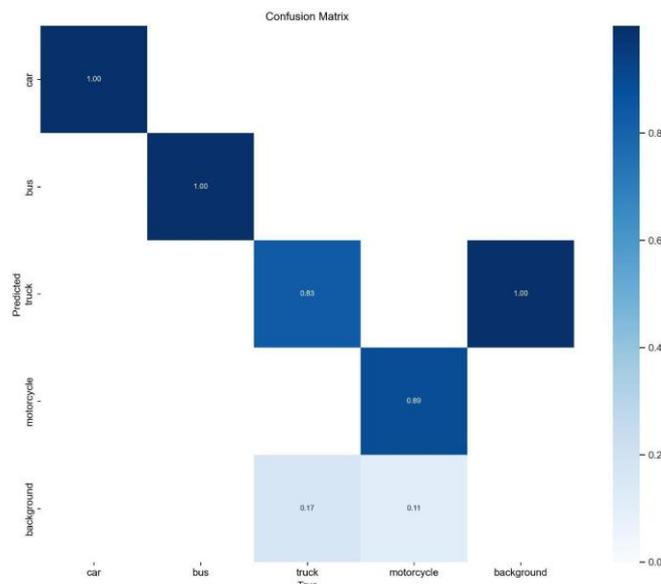
4.2. Evaluasi Model YOLOv5:

Evaluasi model dilakukan untuk dapat mengetahui kinerja model secara keseluruhan dalam melakukan deteksi jenis kendaraan berdasarkan metrik *Precision*, *Recal*, *F1-Score*, *AP* (*Average Precision*)

Tabel 3. Data Training YOLOv5

Class	Precision	Recal	F1-Score	AP (Average Precision)
Car	1.00	1.00	1.00	1.00
Bus	1.00	1.00	1.00	1.0
Truk	1.00	0.83	0.91	0.91
Motor	1.00	0.89	0.94	0.94
mAP	1.00	-	-	0.9625

Berdasarkan Tabel 3. seluruh kelas kendaraan (mobil, bus, truk, dan motor) menunjukkan hasil yang sangat baik, dengan *precision* mencapai 100% untuk semua kelas. Nilai *mAP50* sebesar 96.25% menunjukkan bahwa model memiliki kemampuan generalisasi yang kuat terhadap data uji. Hasil ini menegaskan bahwa YOLOv5 sangat efektif dalam mendeteksi berbagai jenis kendaraan secara akurat dan efisien.



Gambar 4. Matrix Confusion

Gambar di atas ini Menunjukkan distribusi hasil klasifikasi per kelas kendaraan. Dan hampir semua kendaraan diklasifikasikan dengan benar. Kemudian untuk menghitung nilai akurasi dari *matrix confusion* menggunakan rumus di bawah ini:

$$\text{Akurasi} = \frac{TP + TN}{TP + FP + FN + TN} = \frac{3.72 + 0}{3.72 + 0.28} = 0.93 = 93\%$$

Hasil perhitungan akurasi berdasarkan confusion matrix menunjukkan nilai sebesar 93%, yang berarti sebagian besar kendaraan berhasil diklasifikasikan dengan benar. Nilai *True Positive* (TP) sebesar 3.72 mengindikasikan banyaknya prediksi benar terhadap kendaraan yang memang ada. Dengan nilai *False Positive* (FP) dan *False Negative* (FN) yang kecil, akurasi tinggi ini mencerminkan kinerja deteksi kendaraan yang sangat baik.

4.3 Hasil Pengujian Deteksi Video

Pada pengujian pendeteksian berbasis video, model juga menunjukkan tingkat akurasi yang tinggi. Proses deteksi berjalan stabil dan konsisten, di mana jenis-jenis kendaraan berhasil dikenali secara tepat selama durasi video berlangsung. Pengujian ini dilakukan di Jl. Solo Km. 11,1, yang merupakan salah satu ruas jalan dengan lalu lintas cukup padat. Gambar di bawah ini menunjukkan hasil visualisasi pendeteksian kendaraan dari video pengujian yang dilakukan.



Gambar 5. Hasil Deteksi Kendaraan pada Vidio

Gambar di atas menunjukkan hasil pendeteksian kendaraan secara *real-time* menggunakan model berbasis video di ruas jalan yang padat lalu lintas. Setiap kendaraan berhasil dikenali dan diberi label jenis serta estimasi beban dalam satuan ton. Visualisasi ini menunjukkan bahwa sistem deteksi berjalan akurat, stabil, dan mampu mengenali berbagai jenis kendaraan secara simultan.

Tabel 4. Jumlah Kendaraan yang terdeteksi

Jenis Kendaraan	Jumlah Kendaraan _N
Bus	28
Mobil	1846
Motor	2353
Truk	168
Total	4395

Pengujian sistem deteksi kendaraan berbasis YOLOv5 dilakukan di Jl. Solo Km. 11,1 untuk mengevaluasi kemampuan model dalam mendeteksi kendaraan secara *real-time*. Hasil pengujian menunjukkan bahwa model mampu melakukan deteksi dengan tingkat kestabilan yang baik selama durasi pengamatan selama 10 menit. Seluruh hasil deteksi kendaraan dikumpulkan secara otomatis oleh sistem dan disimpan dalam format file CSV, yang mencatat informasi penting seperti waktu deteksi, jenis kendaraan, serta nilai *confidence* dari model. Dari data yang diperoleh, sistem berhasil mendeteksi total 4.395 unit kendaraan yang terdiri dari empat kategori utama, yaitu mobil, motor, truck, dan bus.

4.4 Perhitungan Equivalent Single Axle Load (ESAL)

Perhitungan ESAL (*Equivalent Single Axle Load*) dilakukan berdasarkan data jumlah kendaraan yang terdeteksi, LHR (Lalu Lintas Harian Rata-rata), dan LEF (*Load Equivalency Factor*) masing-masing kendaraan.

1) Konversi Ke LHR (Lalu Lintas Harian Rata -rata)

Tabel 5. Konversi Ke (LHR)

Jenis Kendaraan	Jumlah N_j	$LHR_j \times 144$	Hasil LHR_j
Motorcycle	2353	2,353 x 144	338,832
Car	1846	1,846 x 144	265,824
Truck	168	168 x 144	24,192
Bus	28	28 x 144	4,32
Total			632,880

Dengan persentase nilai LHR sebesar 632.880 kendaraan per hari selama 10 menit, hal ini menunjukkan volume lalu lintas yang sangat tinggi pada aktivitas jalan raya. Jika kondisi tersebut sering terjadi secara terus-menerus, jalan yang dilalui akan mengalami tekanan yang sangat besar dan dapat mempercepat kerusakan permukaan pada jalan, kerusakan yang akan terjadi diantaranya retakan, deformasi. Beban tertinggi terlihat pada kendaraan berat seperti truk dan bus dengan berat yang terus-menerus yang diterima oleh jalan dapat mengurangi sisa umur jalan.

2) Perhitungan (*Load Equivalency Factor*)

Tabel 5. Perhitungan LEF

Jenis Kendaraan	Berat (ton)	Rumus LEF	Hasil
Motorcycle	0.20	$(0.20/8.16)^4$	0.0000362
Car	1.50	$(1.50/8.16)^4$	0.00114
Truck	15.00	$(15.00/8.16)^4$	11.41
Bus	10	$(10.00/8.16)^4$	2.25
Total			13.6611762

Dari tabel diatas menunjukkan nilai *Load Equivalency Factor* (LEF) sebesar 13.6611762, hal tersebut menunjukkan bahwa satu kendaraan berat kendaraan yang melintasi pada jalan yang diteliti setara dengan lebih dari 13 kendaraan ringan dalam hal kerusakan yang ditimbulkan terhadap struktur jalan. Nilai LEF yang tinggi seperti ini menandakan potensi beban berlebih dari kendaraan-kendaraan berat yang melintas, yang secara signifikan dapat mempercepat degradasi jalan, mengurangi umur layan jalan, dan meningkatkan kebutuhan pemeliharaan struktural secara berkala.

3) Data Waktu

Tabel 6. Perhitungan waktu dalam 10 menit

Jenis Kendaraan	Jumlah (N)	LEF	$ESAL_t \times LEF$
Motorcycle	2353	0.0000362	2353 x 0.0000362 = 0.0852
Car	1846	0.00114	1846 x 0.00114 = 2.106
Truck	168	11.41	168 x 11.41 = 1916.88
Bus	28	2.25	28 x 2.25 = 63.00
Total			1982.07

Dari perhitungan tabel diatas diperoleh nilai ESAL (*Equivalent Single Axle Load*) sebesar 1982.07 dalam waktu 10 menit, dalam durasi waktu yang sangat singkat, beban lalu lintas yang melewati jalan setara dengan 2.000 pengaruh beban gandar tunggal standar (8,16 ton). Nilai ini sangat tinggi untuk durasi yang singkat dan menunjukkan intensitas lalu lintas berat yang ekstrem. Jika kondisi ini terjadi secara konsisten, maka umur struktural jalan akan menurun drastis dan potensi kerusakan seperti retak, atau deformasi akan meningkat pesat. Dengan melakukan perhitungan ESAL yang digunakan untuk memperkirakan umur rencana

jalan dan menunjukkan bahwa pemeliharaan rutin serta perencanaan struktur perkerasan jalan harus mempertimbangkan beban lalu lintas.

4) Perhitungan ESAL harian

Jenis Kendaraan	ESAL 10 menit	Total ESAL Harian
Motorcycle	0.0852	$(0.0852 / 10) \times 1440 = 12.28$
Car	2.106	$(2.106 / 10) \times 1440 = 303.26$
Truck	1916.88	$(1916.88 / 10) \times 1440 = 275,827.20$
Bus	63.00	$(63.00 / 10) \times 1440 = 9,072.00$
Total		284,214.74

Berdasar tabel diatas dapat dilihat nilai beban ESAL kendaraan sebesar 284.214,74 menunjukkan bahwa total beban lalu lintas dalam satu hari setara dengan lebih dari 284 ribu kali beban gandar tunggal standar (8,16 ton). Ini merupakan angka yang sangat tinggi, dan mengindikasikan bahwa jalan menerima tekanan berat seperti kendaraan seperti truk dan bus. Jika hal tersebut tidak diimbangi dengan struktur perkerasan jalan yang kuat dan pemeliharaan berkala, kondisi ini dapat menyebabkan kerusakan serius seperti retak.

4.5 Evaluasi Dampak Beban Kendaraan terhadap Jalan – Jl. Solo Km. 11,1

Ruas Jl. Solo Km. 11,1 merupakan jalan beraspal dengan ketebalan umum yang digunakan antara 100 - 200 mm (10 - 20 cm), sesuai standar jalan utama. Berdasarkan hasil pemantauan menggunakan YOLOv5, diperoleh data lalu lintas harian (LHR) sebesar 632.880 kendaraan, LEF sebesar 13,66, ESAL selama 10 menit sebesar 1.982,07, dan ESAL harian mencapai 284.214,74.

1) Perbandingan dengan Kapasitas Desain Jalan

Umumnya, jalan beraspal dirancang untuk menahan total beban antara 10–20 juta ESAL selama 10–20 tahun. Jika dibandingkan dengan nilai ESAL harian yang mencapai 284.214,74, yang bisa dihitung kurang dari dua bulan, beban yang melintas tersebut bisa melampaui kapasitas desain jalan awal. Hal ini menunjukkan bahwa jalan tersebut menerima beban lalu lintas yang sangat tinggi di setiap harinya.

2) Dugaan Dampak yang akan terjadi pada Karakteristik Jalan

Meskipun tidak dilakukan pengamatan secara langsung terhadap kondisi fisik jalan, tingginya nilai ESAL harian dan nilai persentase LEF yang cukup tinggi mengindikasikan bahwa banyaknya kendaraan berat yang melintas pada ruas yang diteliti menyebabkan kerusakan seperti retak, deformasi, atau penurunan kualitas permukaan dalam jangka waktu tertentu, terutama jika tidak ada penanganan struktural yang baik.

4.4 Pembahasan

Metode deteksi kendaraan menggunakan YOLOv5 dalam penelitian ini terbukti efektif dalam mengidentifikasi berbagai jenis kendaraan secara *real-time*. Deteksi dilakukan melalui kamera video yang terintegrasi dengan model YOLOv5, yang telah dilatih untuk mengenali jenis kendaraan seperti motor, mobil, bus, dan truk. Hasil deteksi kemudian digunakan sebagai dasar dalam klasifikasi kendaraan berdasarkan jenis, dan selanjutnya sebagai parameter penting dalam estimasi beban kendaraan. Dengan menggabungkan data klasifikasi kendaraan dan rumus *Load Equivalency Factor* (LEF), dilakukan perhitungan beban lalu lintas terhadap jalan dalam satuan ESAL (*Equivalent Single Axle Load*). Hasil akumulasi selama pengamatan 10 menit menunjukkan bahwa total LHR (Lalu Lintas Harian Rata-rata) mencapai 632.880 kendaraan, dengan nilai total LEF sebesar 13,6611762, dan total beban lalu lintas sebesar 1.982,07 ESAL. Jika nilai harian, diperoleh total ESAL sebesar 284.214,74, yang mencerminkan intensitas beban kendaraan harian yang sangat tinggi. Dengan nilai presentasi ESAL yang tinggi menunjukan indikator penting dalam mengevaluasi karakteristik struktural jalan. Kendaraan yang melintas setiap hari, terutama kendaraan berat seperti truk dan bus, memberikan tekanan yang berlebih terhadap lapisan perkerasan jalan. Beban berlebih tersebut dapat memberikan kerusakan seperti deformasi dan retak. Oleh karena itu, pemantauan secara

langsung dan berkala menjadi sangat penting untuk menjaga kualitas dan umur jalan. Selain itu, data yang diperoleh dari analisis berdasarkan karakteristik jalan.

Penelitian ini juga menunjukkan bahwa penggunaan metode YOLOv5 untuk deteksi kendaraan memberikan efisiensi tinggi dalam akuisisi data lalu lintas. YOLOv5 mampu mengidentifikasi objek dalam waktu nyata dan menghasilkan output yang sesuai dan langsung dapat digunakan untuk perhitungan teknis. Keunggulan ini membuat YOLOv5 sangat relevan sebagai bagian dari sistem monitoring lalu lintas modern, terutama dalam mendukung pengambilan keputusan teknis berbasis data. Hasil penelitian ini sejalan dengan temuan dari penelitian terdahulu mengenai pentingnya analisis beban kendaraan dalam perencanaan dan pemeliharaan jalan. Studi [20] menunjukkan bahwa pemahaman yang akurat tentang distribusi beban kendaraan dan dampaknya terhadap karakteristik jalan sangat krusial untuk pengambilan keputusan yang tepat dalam pengelolaan infrastruktur jalan. Selain itu penelitian oleh [21] juga menyoroti efektivitas metode deteksi kendaraan secara otomatis, seperti YOLOv5, dalam mengumpulkan data lalu lintas yang akurat untuk analisis beban jalan. Kedua penelitian ini menggaris bawahi pengolahan jalan melalui pemanfaatan teknologi dan analisis data yang mendalam. Implikasi Penelitian ini menegaskan bahwa pemantauan beban kendaraan secara *real-time* menggunakan metode YOLOv5 sangat penting untuk memahami dan mengelola dampak beban kendaraan terhadap jalan. Data beban dari semua jenis kendaraan memungkinkan pengelola jalan melakukan evaluasi kondisi jalan secara menyeluruh.

Secara keseluruhan, hasil dari integrasi metode YOLOv5 dan perhitungan ESAL dalam penelitian ini memberikan gambaran nyata bahwa beban kendaraan yang tinggi memberikan dampak besar terhadap kualitas perkerasan jalan. Pemantauan sistem deteksi otomatis bukan hanya efisien, tetapi juga menjadi dasar penting dalam perencanaan pemantauan beban berlebih. Penelitian ini menegaskan bahwa penerapan teknologi pengolahan citra berbasis AI sangat bermanfaat dalam mendukung analisis beban kendaraan terhadap karakteristik jalan secara baik dan akurat.

5. Simpulan

Berdasarkan hasil penelitian menunjukkan bahwa model YOLOv5 efektif dalam mendeteksi berbagai jenis kendaraan dengan akurasi tinggi, serta mampu menyediakan data beban kendaraan yang terdeteksi. Total beban kendaraan yang terdeteksi mencapai 6039,6 ton, dengan jalan arteri primer dan jalan kolektor menyerap lebih dari 92% beban tersebut. Derajat kejenuhan jalan yang melebihi angka 1 dimana nilai ini menunjukkan bahwa kondisi jalan diamati dalam kondisi (*overload*), dan berisiko tinggi terhadap *degradasi* jalan. Analisis distribusi beban memperjelas prioritas perencanaan pemeliharaan jalan, di mana fokus harus diberikan kepada jalan-jalan dengan intensitas beban tertinggi. Dengan demikian, penerapan teknologi *Computer Vision* dalam analisis lalu lintas terbukti menjadi alat yang efektif untuk mendukung keputusan strategis dalam pengelolaan infrastruktur jalan.

Daftar Referensi

- [1] D. I. Mulyana and M. A. Rofik, "Implementasi Deteksi Real Time Klasifikasi Jenis Kendaraan Di Indonesia Menggunakan Metode YOLOV5," *J. Pendidik. Tambusai*, vol. 6, no. 3, pp. 13971–13982, 2022
- [2] M. M. Rana, M. S. Hossain, M. M. Hossain, and M. D. Haque, "Improved vehicle detection: unveiling the potential of modified YOLOv5," *Discov. Appl. Sci.*, vol. 6, no. 7, pp. 1-15, 2024
- [3] L. Dan and F. Lingkungan, "Studi analisis kinerja jalan raya akibat beban lalu lintas dan faktor lingkungan, vol 15, No 2, pp. 90–99. 2020
- [4] D. P. Anggraeni, C. Renatasari, P. April, R. Pakpahan, S. Fitri, and A. Wati, "Analisis Peningkatan Jumlah Transportasi Kota Surabaya Menggunakan Sistem Dinamik," *KOLONI J. Multidisiplin Ilmu*, vol. 3, no. 2, pp. 2828–6863, 2024.
- [5] R. Ji and N. Giriwoyo, "Analisis Penyebab Kerusakan Jalan pada Ruas. Ngadirojo-Giriwoyo," *Sukoharjo*, vol. 2, no. 1, pp. 21–25, 2020.
- [6] K. R. Pelangie, "Pengaruh Jumlah Kendaraan Terhadap Kerusakan Jalan Aspal Kelas Iiia (Studi Kasus: Jalan Hayam Wuruk, Jakarta)," vol. 13, no. 1, pp. 26–37, 2023.
- [7] P. di Indonesia, "Jurnal Kecerdasan Buatan, Komputasi dan Teknologi Informasi," *J. Kecerdasan Buatan*, vol. 4, no. 1, pp. 38–44, 2022
- [8] M. Hariyanto, M. Kholiq, A. Yani, and Narti, "Inti nusa mandiri," *Inti Nusa Mandiri*, vol. 14,

- no. 2, pp. 133–138, 2020.
- [9] I. W. Adi, A. Wiguna, R. R. Huizen, and G. A. Pradipta, “Model Deteksi Objek Menggunakan Yolov5 untuk Pengendalian Pengaturan Lalu Lintas, vol 6, No 1, pp. 840–844, 2024.
- [10] M. J. Alam *et al.*, “An Optimized YOLOv5 Based Approach For *real-time* Vehicle Detection At Road Intersections Using Fisheye Cameras,” 2025
- [11] R. Dwiyanto, D. W. Widodo, and P. Kasih, “Implementasi Metode You Only Look Once (YOLOv5) Untuk Klasifikasi Kendaraan Pada CCTV Kabupaten Tulungagung,” *Semin. Nas. Inov. Teknol.*, vol. 1, no. 1, pp. 102–104, 2022.
- [12] T. Maulana and E. Harahap, “Deteksi Plat Nomor Kendaraan Menggunakan Algoritma YOLOv5 dengan Metode Convolutional Neural Network, vol 12, No 2, pp. 103–112, 2024.
- [13] P. A. Cahyani, M. Mardiana, P. B. Wintoro, and M. A. Muhammad, “Sistem Perhitungan Kendaraan Menggunakan Algoritma YOLOv5 dan DeepSORT,” *J. Tek. Inform. dan Sist. Inf.*, vol. 10, no. 1, pp. 86–99, 2024
- [14] Zhandy, E. Tungadi, and M. Fajri Raharjo, “Aplikasi Monitoring Pelanggaran Lalu Lintas di Area Jalan TolMenggunakan YOLOv5’, vol 5, no 2, pp. 89–93, 2023.
- [15] A. Safitri, D. Najimuddin, and Padusung, “Analisis Beban Kendaraan Terhadap Kerusakan Jalan Lintas Plampang-Labangka,” *J. SainTekA*, vol. 2, no. 1, pp. 1–7, 2021, [Online]. Available: <http://e-journalppmunsa.ac.id/index.php/sainteka/article/view/330>
- [16] C. A. Alvina and M. Triani, “Analisis Pengaruh Infrastruktur Jalan dan Kepadatan Penduduk Terhadap Pendapatan Per Kapita di Pulau Sumatera, vol 1, no 1, pp: 35 - 42, 2022.
- [17] E. Mailoa, “Perbandingan Beberapa Algoritma Machine Learning Dalam Analisis Sentimen Terkait Pemilihan Presiden RI 2024”, vol 13, no 2, pp. 1096 - 1105, 2024.