

Penerapan Metode YOLOv8 untuk Deteksi Jalan Berlubang Berbasis Object Detection

Rafli Muhammad Fauzi*, Ramadhan Putra Al Kariim, Nurul Latifah, Hilda Yulia Novita

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Buana Perjuangan, Karawang, Indonesia

Email: ¹if22.raflifauzi@mhs.ubpkarawang.ac.id, ²if22.ramadhankariim@mhs.ubpkarawang.ac.id,

³if22.nurullatifah@mhs.ubpkarawang.ac.id, ⁴hilda.yulia@ubpkarawang.ac.id

Email Penulis Korespondensi: if22.raflifauzi@mhs.ubpkarawang.ac.id

Submitted 24-12-2025; Accepted 27-01-2026; Published 28-02-2026

Abstrak

Kerusakan infrastruktur jalan, khususnya jalan berlubang, merupakan salah satu permasalahan serius yang berkontribusi terhadap meningkatnya risiko kecelakaan lalu lintas di Indonesia. Kondisi tersebut menuntut adanya sistem pemantauan jalan yang mampu bekerja secara cepat, akurat, dan berkelanjutan. Penelitian ini bertujuan untuk membangun dan mengevaluasi sistem deteksi otomatis jalan berlubang berbasis visi komputer menggunakan metode YOLOv8 (You Only Look Once versi 8), yang merupakan algoritma deep learning untuk deteksi objek secara real-time. Pengumpulan dataset dilakukan melalui dua pendekatan, yaitu pengambilan data dari platform Kaggle serta dokumentasi langsung kondisi jalan berlubang menggunakan kamera smartphone, guna meningkatkan variasi dan representasi kondisi jalan nyata di lapangan. Seluruh data kemudian dianotasi menggunakan platform Roboflow untuk menghasilkan dataset berlabel yang siap digunakan dalam proses pelatihan model. Model YOLOv8 dilatih menggunakan total 345 citra, dengan pembagian 241 citra untuk data pelatihan, 69 citra untuk validasi, dan 35 citra untuk pengujian. Hasil pelatihan menunjukkan bahwa model mencapai nilai mean Average Precision (mAP) sebesar 93%, dengan nilai precision sebesar 88% dan recall sebesar 82%, yang mengindikasikan kemampuan model dalam mengenali dan melokalisasi objek jalan berlubang secara akurat. Selain itu, pengujian secara real-time menggunakan kamera smartphone menunjukkan bahwa sistem mampu mencapai tingkat akurasi deteksi lebih dari 85% pada kondisi nyata di lapangan. Hasil penelitian ini menunjukkan bahwa YOLOv8 memiliki potensi yang tinggi sebagai solusi deteksi otomatis jalan berlubang yang efisien dan andal, serta dapat mendukung upaya pemeliharaan infrastruktur jalan dan peningkatan keselamatan pengguna jalan.

Kata Kunci: YOLOv8; Jalan Berlubang; Deteksi Objek; Roboflow; Keselamatan

Abstract

Road infrastructure damage, particularly potholes, is a critical issue that contributes to an increased risk of traffic accidents in Indonesia. This condition highlights the need for a road monitoring system that is capable of operating quickly, accurately, and continuously. This study aims to develop and evaluate an automated pothole detection system based on computer vision using the YOLOv8 (You Only Look Once version 8) method, a deep learning algorithm designed for real-time object detection. Dataset collection was conducted through two approaches, namely acquiring data from the Kaggle platform and capturing real-world road images directly using a smartphone camera to enhance data diversity and represent actual road conditions. All collected images were annotated using the Roboflow platform to generate labeled data suitable for model training. The YOLOv8 model was trained using a total of 345 images, consisting of 241 training images, 69 validation images, and 35 testing images. The training results indicate that the model achieved a mean Average Precision (mAP) of 93%, with a precision of 88% and a recall of 82%, demonstrating strong detection and localization performance. Furthermore, real-time testing using a smartphone camera showed that the system achieved an accuracy of over 85% under real-world conditions. These findings demonstrate that YOLOv8 has strong potential as an efficient and reliable automated pothole detection system, supporting road infrastructure maintenance and enhancing road user safety.

Keywords: YOLOv8; Potholes; Object Detection; Roboflow; Safety

1. PENDAHULUAN

Jalan merupakan infrastruktur vital dalam mendukung mobilitas masyarakat, pertumbuhan ekonomi, dan akses ke berbagai layanan publik [1][2]. Peningkatan jumlah penduduk dan kendaraan setiap tahunnya memberikan tekanan yang signifikan terhadap kualitas jalan [3]. Berdasarkan Hasil Sensus Penduduk 2020 yang dirilis oleh Badan Pusat Statistik (BPS), jumlah penduduk Indonesia mencapai 270.203.917 jiwa [4], menempatkannya sebagai negara dengan populasi terbesar keempat di dunia setelah Tiongkok, India, dan Amerika Serikat. Pertumbuhan penduduk yang tinggi ini berdampak langsung pada peningkatan mobilitas masyarakat dalam menggunakan kendaraan. Sejalan dengan meningkatnya jumlah penduduk, data dari BPS tahun 2023 menunjukkan bahwa jumlah kendaraan bermotor di Indonesia juga terus bertambah setiap tahunnya [5], sehingga menyebabkan tekanan yang lebih besar terhadap infrastruktur jalan. Akibatnya, kerusakan jalan pun semakin sering terjadi, dan dalam konteks keselamatan lalu lintas, kondisi jalan yang rusak tersebut terbukti berkontribusi terhadap peningkatan jumlah kecelakaan.

Pada ruas Jalan Empunala di Mojokerto, misalnya, ditemukan bahwa dari total 62 kejadian kecelakaan selama periode 2018-2020, sekitar 11% disebabkan oleh faktor kerusakan jalan [6], termasuk lubang jalan dan minimnya rambu keselamatan. Lebih lanjut, korban kecelakaan yang tercatat termasuk 24 korban meninggal dunia, 13 korban luka berat, dan 95 korban luka ringan, menunjukkan urgensi penanganan kondisi infrastruktur jalan demi keselamatan pengguna. Di wilayah lain seperti Tembung, Sumatera Utara, kerusakan jalan mengakibatkan peningkatan biaya transportasi, penurunan produktivitas masyarakat, dan risiko kecelakaan yang tinggi [7].

Berbagai upaya telah dilakukan untuk mengatasi permasalahan ini, namun proses pendeteksian dan pemantauan jalan rusak secara konvensional memerlukan waktu, tenaga, dan biaya yang besar [8]. Pendekatan lain yang telah

dikembangkan dalam pendeteksian kerusakan jalan meliputi survei visual manual, penggunaan sensor getaran, serta pemanfaatan citra satelit dan kendaraan survei khusus. Namun, meskipun metode-metode tersebut mampu memberikan informasi kondisi jalan, penerapannya umumnya memerlukan biaya operasional yang tinggi, waktu pengolahan yang relatif lama, serta ketergantungan pada perangkat khusus, sehingga kurang efisien untuk pemantauan jalan secara berkelanjutan dan real-time.

Oleh karena itu, diperlukan solusi berbasis teknologi untuk mengatasi permasalahan tersebut. Teknologi visi komputer saat ini menyediakan pendekatan yang efisien dalam mendeteksi kondisi jalan secara otomatis. Salah satu algoritma deteksi objek yang banyak digunakan adalah YOLOv8 (You Only Look Once versi 8). Algoritma ini telah terbukti efektif untuk mengenali objek di berbagai kondisi lingkungan, termasuk pada cuaca buruk atau kondisi jalan yang kompleks [9]. Dibandingkan versi sebelumnya, YOLOv8 memiliki struktur yang lebih ringan namun tetap presisi, sehingga sangat cocok diterapkan untuk mendeteksi jalan berlubang pada citra jalan [10].

Berbagai penelitian terkait dengan penggunaan YOLOv8 dalam deteksi kerusakan jalan telah dilakukan dalam beberapa tahun terakhir. Sebagai contoh, studi yang dilakukan oleh Doan Van (2023) menunjukkan bahwa penerapan YOLOv8 untuk mendeteksi anomali permukaan jalan seperti lubang dan retakan dapat menghasilkan performa deteksi yang menjanjikan dalam konteks pemantauan real-time [11]. Selain itu, penelitian lain menunjukkan bahwa modifikasi YOLOv8 seperti YOLOv8n dan YOLOv8-PD mampu meningkatkan akurasi dalam pendeteksian kerusakan jalan multi-skala, dengan tetap mempertahankan efisiensi dan fleksibilitas pada perangkat dengan sumber daya terbatas [12]. Kemampuannya dalam menyesuaikan diri terhadap data pelatihan yang terbatas dan kondisi gambar yang bervariasi menjadikannya solusi tepat untuk aplikasi deteksi visual berbasis real-time di lingkungan terbuka [13].

Selain itu, penelitian yang dilakukan oleh Denaro dan Lim (2025) membahas penerapan YOLO dalam mendeteksi kondisi jalan berlubang pada jalan yang memiliki berbagai tekstur permukaan, seperti jalan aspal dan beton. Penelitian ini menegaskan bahwa algoritma YOLO dapat disesuaikan dengan baik untuk mendeteksi kerusakan jalan pada berbagai jenis permukaan [14]. Penelitian lainnya oleh Zhang et al., (2023) mengungkapkan bahwa kombinasi YOLOv8 dengan teknik pembelajaran transfer dapat meningkatkan akurasi deteksi kerusakan jalan dengan dataset yang terbatas. Teknik ini memungkinkan model untuk lebih cepat beradaptasi pada dataset baru dengan jumlah data yang lebih sedikit, yang sangat berguna dalam situasi di mana data jalan yang rusak sulit diperoleh [15].

Meskipun berbagai penelitian sebelumnya telah menunjukkan potensi algoritma YOLOv8 dalam mendeteksi kerusakan jalan, sebagian besar penelitian tersebut masih terbatas pada penggunaan data yang bersifat terkontrol dan diperoleh melalui perangkat khusus. Selain itu, pemanfaatan kamera smartphone sebagai media pengambilan data langsung di lapangan serta pengujian sistem dalam kondisi nyata masih belum banyak dibahas secara mendalam, sehingga terdapat celah penelitian yang perlu dikaji lebih lanjut.


Namun, penelitian yang ada sebagian besar masih terbatas pada penggunaan data yang bersifat terkontrol, dengan fokus pada kondisi jalan yang lebih sederhana. Sebagian besar penelitian tersebut juga belum mengoptimalkan pengumpulan data yang dapat dilakukan secara real-time dan menggunakan perangkat yang lebih terjangkau, seperti smartphone, yang lebih mudah diakses oleh masyarakat luas dan instansi terkait. Penelitian ini akan mengisi gap tersebut dengan mengaplikasikan YOLOv8 untuk deteksi otomatis jalan berlubang, menggunakan data gambar yang dikumpulkan melalui kamera smartphone dan platform anotasi Roboflow yang efektif untuk meningkatkan akurasi deteksi.

Penelitian ini bertujuan untuk mengembangkan sistem deteksi otomatis jalan berlubang yang berbasis YOLOv8, yang dapat diterapkan di Indonesia dengan menggunakan data gambar yang diperoleh langsung dari lapangan melalui kamera smartphone. Diharapkan, penelitian ini dapat memberikan solusi efisien dan tepat sasaran dalam mengurangi risiko kecelakaan lalu lintas akibat kerusakan jalan serta membantu pemerintah dalam merencanakan program pemeliharaan infrastruktur jalan secara lebih akurat dan real-time. Dengan demikian, kontribusi utama dari penelitian ini adalah pengembangan sistem deteksi jalan berlubang berbasis YOLOv8 yang efisien, real-time, dan berbiaya rendah dengan memanfaatkan perangkat yang mudah diakses, sehingga dapat mendukung pengambilan keputusan dalam pemeliharaan infrastruktur jalan secara lebih efektif.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan penerapan teknologi deep learning untuk mendeteksi jalan berlubang. Alur penelitian mengikuti tahapan sistematis yang dimulai dari identifikasi masalah, pengumpulan data, pre-processing, hingga pelatihan dan pengujian model. Pada Gambar 1 adalah alur penelitian yang menggambarkan setiap tahapan yang dilakukan dalam penelitian ini.



Gambar 1. Alur Penelitian

a. Analisis Masalah

Tahap analisis masalah pada penelitian ini difokuskan pada perumusan kebutuhan sistem deteksi jalan berlubang berbasis citra. Permasalahan utama yang dianalisis meliputi kebutuhan sistem untuk mendeteksi lubang jalan secara real-time, kemampuan model dalam mengenali variasi ukuran lubang, serta ketahanan deteksi terhadap variasi pencahayaan dan sudut pengambilan gambar. Beberapa penelitian terdahulu menunjukkan bahwa algoritma YOLO memiliki keunggulan dalam mendeteksi objek secara real-time dengan akurasi tinggi bahkan pada kondisi pencahayaan yang bervariasi [12][15]. Berdasarkan hasil kajian tersebut, penelitian ini akan menyesuaikan metode YOLOv8 dengan kondisi lingkungan jalan di Indonesia yang memiliki tingkat variasi tekstur dan pencahayaan tinggi. Hasil analisis ini menjadi dasar dalam pemilihan algoritma YOLOv8, penentuan sumber dataset, serta konfigurasi parameter pelatihan model. Pemilihan YOLOv8 dibandingkan versi YOLO sebelumnya, seperti YOLOv5 dan YOLOv7, didasarkan pada keunggulan arsitektur YOLOv8 yang lebih ringan, penggunaan anchor-free detection, serta peningkatan efisiensi pelatihan tanpa mengorbankan akurasi deteksi. Selain itu, dibandingkan metode object detection lain seperti Faster R-CNN atau SSD, YOLOv8 memiliki keunggulan dalam kecepatan inferensi, sehingga lebih sesuai untuk aplikasi pendeteksian jalan berlubang secara real-time.

b. Akuisisi Data

Dataset dalam penelitian ini diperoleh melalui dua metode pengumpulan data, yaitu mengambil sampel dari platform Kaggle melalui tautan <https://www.kaggle.com/datasets/andrewmvd/pothole-detection>, serta mendokumentasikan langsung kondisi jalan berlubang menggunakan kamera smartphone. Pendekatan ini bertujuan untuk meningkatkan variasi data sehingga model tidak hanya belajar dari dataset standar, tetapi juga mampu beradaptasi terhadap kondisi jalan nyata di lapangan. Gambar yang dikumpulkan mencakup berbagai lokasi, tingkat pencahayaan, dan sudut pengambilan untuk memastikan keragaman data. Secara keseluruhan, dataset terdiri dari 241 gambar untuk pelatihan, 69 gambar untuk validasi, dan 35 gambar untuk pengujian. Pemilihan data dilakukan secara selektif guna menjamin kualitas dan keberagaman yang dibutuhkan dalam membangun model deteksi yang akurat dan andal.


Proses anotasi menggunakan platform Roboflow. Setiap gambar dianotasi secara manual dengan menandai lubang pada jalan menggunakan bounding box. Proses pelabelan dataset jalan berlubang menggunakan Roboflow bertujuan untuk melatih komputer dapat mengenali dan mendeteksi jalan berlubang secara otomatis. Pada tahap ini dilakukan labeling image jpg yang diubah ke dalam format txt yang merupakan proses menandai atau memberi anotasi pada image untuk menunjukkan lokasi atau batasan dari objek tertentu di dalamnya. Dalam konteks identifikasi objek, label ini seringkali mencakup informasi mengenai lokasi dan ukuran dari objek yang diidentifikasi. Proses labeling jalan berlubang seperti pada Gambar 2.



Gambar 2. Labeling Jalan Berlubang


c. Pre-Processing

Menerapkan pre-processing data dilakukan untuk meningkatkan kualitas dataset dengan merestore dataset menggunakan roboflow, dengan melakukan perubahan ukuran semua gambar menjadi 640 x 640 piksel. Penyeragaman ukuran citra menjadi 640×640 piksel dilakukan untuk menyesuaikan dengan kebutuhan input model YOLOv8 serta menjaga konsistensi proses pelatihan. Ukuran piksel ini sering digunakan dalam penelitian sebelumnya, seperti oleh Firgiawan (2024) dan Pradana (2024), karena memberikan keseimbangan antara akurasi deteksi dan efisiensi komputasi [16][17]. Proses resize seperti Gambar 3.



Gambar 3. Proses Resize


Proses pembagian data dilakukan menggunakan Roboflow, di mana seluruh dataset dikelompokkan menjadi tiga bagian utama, yaitu 70% untuk data pelatihan (training), 20% untuk data validasi (validation), dan 10% untuk data pengujian (testing). Pembagian dataset ditunjukkan pada Gambar 4.



Gambar 4. Pembagian Dataset

d. Model CNN Dengan Arsitektur YOLOv8

Tahap ini merupakan proses perancangan model Convolutional Neural Network (CNN) dengan arsitektur YOLOv8 yang difokuskan untuk tugas deteksi objek, khususnya dalam mengidentifikasi lubang pada permukaan jalan [18]. YOLOv8 merupakan pengembangan terbaru dari rangkaian arsitektur YOLO yang dirancang untuk mendeteksi objek secara real-time dengan efisiensi dan akurasi tinggi [15]. Untuk memberikan gambaran mengenai struktur dan alur kerja model yang digunakan dalam penelitian ini, arsitektur YOLOv8 yang diterapkan pada sistem deteksi jalan berlubang ditunjukkan pada Gambar 5.



Gambar 5. Arsitektur YOLOv8

Berdasarkan Gambar 5, arsitektur YOLOv8 terdiri atas tiga komponen utama, yaitu backbone, neck, dan head, yang masing-masing memiliki peran penting dalam proses deteksi objek jalan berlubang.

1. Backbone bertugas melakukan ekstraksi fitur dari citra masukan menggunakan modul C2f yang mampu meningkatkan representasi fitur dengan efisiensi komputasi tinggi.
2. Neck menggabungkan fitur dari berbagai skala melalui pendekatan Path Aggregation Network (PANet) dan modul Spatial Pyramid Pooling Fast (SPPF), yang memungkinkan deteksi objek dalam berbagai ukuran.
3. Head menghasilkan prediksi akhir berupa koordinat bounding box, label kelas, dan tingkat keyakinan model terhadap keberadaan objek.

e. Training

Setelah perancangan arsitektur selesai dan data siap digunakan, model dilatih menggunakan data yang telah dianotasi. Pelatihan dilakukan dalam beberapa epoch dengan penyesuaian parameter seperti learning rate, batch size, dan optimizer untuk mencapai performa terbaik [19]. Model dilatih menggunakan GPU (Graphics Processing Unit) untuk mempercepat proses komputasi, mengingat GPU lebih efisien dalam menangani perhitungan matriks yang kompleks dan volume data besar [20]. Selama proses training, dilakukan pemantauan terhadap nilai loss dan performa validasi untuk menghindari overfitting serta memastikan kestabilan model. Pada penelitian ini, parameter pelatihan utama yang digunakan meliputi learning rate awal sebesar 0,001, batch size yang disesuaikan dengan kapasitas GPU, serta optimizer bawaan YOLOv8. Jumlah epoch ditentukan berdasarkan konvergensi nilai loss pada data pelatihan dan validasi, sehingga model tidak mengalami overfitting maupun underfitting.

f. Hasil

Evaluasi performa model dilakukan menggunakan metrik evaluasi object detection, yaitu *precision*, *recall*, dan *mean Average Precision* (mAP). Metrik *precision* digunakan untuk mengukur tingkat ketepatan model dalam mendeteksi lubang jalan, sementara *recall* menunjukkan kemampuan model dalam menemukan seluruh objek lubang yang terdapat pada data pengujian. Nilai mAP digunakan sebagai indikator kinerja keseluruhan model dalam mendeteksi dan mengklasifikasikan objek secara akurat. Analisis berbasis metrik ini memberikan gambaran kuantitatif mengenai performa model YOLOv8 sebelum dilakukan evaluasi secara visual.

Tahap akhir dalam penelitian ini adalah evaluasi performa model. Model CNN dengan arsitektur YOLOv8 diuji terhadap dataset citra jalan yang telah dianotasi, dan hasilnya dievaluasi berdasarkan kemampuan model dalam mendeteksi keberadaan lubang pada permukaan jalan. Keluaran model berupa prediksi lokasi lubang divisualisasikan melalui bounding box pada citra uji. Efektivitas model dalam melakukan deteksi objek menjadi dasar dalam menyimpulkan keberhasilan penerapan metode YOLOv8 pada sistem pendeteksian jalan berlubang secara otomatis. Skenario pengujian dilakukan dengan mengevaluasi hasil deteksi pada berbagai kondisi pencahayaan dan sudut pengambilan gambar untuk mensimulasikan kondisi nyata di lapangan. Pengujian ini bertujuan untuk mengetahui tingkat kestabilan dan keandalan model ketika diterapkan pada lingkungan yang dinamis dan tidak terkontrol.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pelatihan, pengujian, serta analisis kinerja model deteksi jalan berlubang berbasis YOLOv8 yang telah dikembangkan. Pembahasan difokuskan pada performa model berdasarkan metrik evaluasi kuantitatif serta pengujian real-time menggunakan kamera smartphone.

3.1 Implementasi/Pengujian

Secara umum, tahapan penerapan algoritma YOLOv8 dalam penelitian ini meliputi beberapa langkah utama, yaitu: (1) pengumpulan dan pelabelan dataset citra jalan berlubang, (2) pembagian data menjadi data pelatihan, validasi, dan pengujian, (3) proses pelatihan model menggunakan arsitektur YOLOv8 pretrained, (4) evaluasi performa model menggunakan metrik kuantitatif, serta (5) pengujian real-time menggunakan kamera smartphone. Urutan tahapan ini dirancang untuk memastikan bahwa model yang dihasilkan tidak hanya memiliki performa yang baik secara teoritis, tetapi juga mampu diterapkan pada kondisi nyata di lapangan.

a. Hasil Pelatihan Model YOLOv8.

Model YOLOv8 dilatih menggunakan dataset citra jalan berlubang yang terdiri dari 345 gambar, dengan pembagian 241 gambar untuk data pelatihan, 69 gambar untuk validasi, dan 35 gambar untuk pengujian. Proses pelatihan dilakukan selama 50 epoch menggunakan model pretrained YOLOv8.


Selama proses training, performa model dipantau melalui nilai loss, precision, recall, serta mean Average Precision (mAP). Hasil pelatihan menunjukkan bahwa model mengalami penurunan nilai loss secara konsisten pada data training dan validation, yang mengindikasikan proses pembelajaran berjalan dengan baik tanpa indikasi overfitting. Untuk menggambarkan proses pelatihan serta perkembangan performa model YOLOv8 selama proses training, visualisasi hasil pelatihan ditunjukkan pada Gambar 6 dan Gambar 7.

Epoch	GPU mem	box loss	cls loss	dfl loss	Instances	Size	31/31	00:04:00:00	6.991t/s
41/50	1.35G	1.413	1.34	1.554	1	640: 100%	31/31	00:04:00:00	6.991t/s
Class		Images	Instances	Box(P	R	mAP50	mAP50-95)	100%	10.651t/s
all	69	76	0.765	0.813	0.839	0.458	5/5	00:00:00:00	10.651t/s
Epoch	GPU mem	box loss	cls loss	dfl loss	Instances	Size	31/31	00:03:00:00	9.091t/s
42/50	1.35G	1.414	1.332	1.571	1	640: 100%	31/31	00:03:00:00	9.091t/s
Class		Images	Instances	Box(P	R	mAP50	mAP50-95)	100%	10.991t/s
all	69	76	0.837	0.724	0.831	0.479	5/5	00:00:00:00	10.991t/s
Epoch	GPU mem	box loss	cls loss	dfl loss	Instances	Size	31/31	00:03:00:00	8.171t/s
43/50	1.35G	1.31	1.2	1.49	1	640: 100%	31/31	00:03:00:00	8.171t/s
Class		Images	Instances	Box(P	R	mAP50	mAP50-95)	100%	11.471t/s
all	69	76	0.803	0.749	0.874	0.513	5/5	00:00:00:00	11.471t/s
Epoch	GPU mem	box loss	cls loss	dfl loss	Instances	Size	31/31	00:03:00:00	8.191t/s
44/50	1.34G	1.313	1.201	1.513	1	640: 100%	31/31	00:03:00:00	8.191t/s
Class		Images	Instances	Box(P	R	mAP50	mAP50-95)	100%	11.881t/s
all	69	76	0.824	0.738	0.86	0.505	5/5	00:00:00:00	11.881t/s
Epoch	GPU mem	box loss	cls loss	dfl loss	Instances	Size	31/31	00:03:00:00	8.821t/s
45/50	1.35G	1.307	1.153	1.495	3	640: 100%	31/31	00:03:00:00	8.821t/s
Class		Images	Instances	Box(P	R	mAP50	mAP50-95)	100%	9.991t/s
all	69	76	0.791	0.790	0.881	0.492	5/5	00:00:00:00	9.991t/s
Epoch	GPU mem	box loss	cls loss	dfl loss	Instances	Size	31/31	00:03:00:00	8.751t/s
46/50	1.35G	1.267	1.137	1.501	1	640: 100%	31/31	00:03:00:00	8.751t/s
Class		Images	Instances	Box(P	R	mAP50	mAP50-95)	100%	11.591t/s
all	69	76	0.852	0.83	0.905	0.508	5/5	00:00:00:00	11.591t/s
Epoch	GPU mem	box loss	cls loss	dfl loss	Instances	Size	31/31	00:03:00:00	9.291t/s
47/50	1.35G	1.296	1.112	1.493	1	640: 100%	31/31	00:03:00:00	9.291t/s
Class		Images	Instances	Box(P	R	mAP50	mAP50-95)	100%	11.291t/s
all	69	76	0.874	0.819	0.93	0.537	5/5	00:00:00:00	11.291t/s
Epoch	GPU mem	box loss	cls loss	dfl loss	Instances	Size	31/31	00:03:00:00	9.541t/s
48/50	1.35G	1.257	1.089	1.474	1	640: 100%	31/31	00:03:00:00	9.541t/s
Class		Images	Instances	Box(P	R	mAP50	mAP50-95)	100%	11.201t/s
all	69	76	0.874	0.816	0.925	0.544	5/5	00:00:00:00	11.201t/s
Epoch	GPU mem	box loss	cls loss	dfl loss	Instances	Size	31/31	00:03:00:00	9.561t/s
49/50	1.35G	1.257	1.012	1.448	1	640: 100%	31/31	00:03:00:00	9.561t/s
Class		Images	Instances	Box(P	R	mAP50	mAP50-95)	100%	10.351t/s
all	69	76	0.858	0.868	0.934	0.54	5/5	00:00:00:00	10.351t/s
Epoch	GPU mem	box loss	cls loss	dfl loss	Instances	Size	31/31	00:03:00:00	8.691t/s
50/50	1.35G	1.241	1.074	1.468	1	640: 100%	31/31	00:03:00:00	8.691t/s
Class		Images	Instances	Box(P	R	mAP50	mAP50-95)	100%	10.481t/s
all	69	76	0.887	0.827	0.933	0.555	5/5	00:00:00:00	10.481t/s

50 epochs completed in 0.885 hours.
Optimizer stripped from runs/detect/train45/weights/last.pt, 6.3MB
Optimizer stripped from runs/detect/train45/weights/best.pt, 6.3MB

Gambar 6. Proses Pelatihan Model YOLOv8

Berdasarkan Gambar 6, terlihat bahwa proses pelatihan model berlangsung secara stabil, ditunjukkan dengan penurunan nilai loss pada data pelatihan dan validasi seiring bertambahnya jumlah epoch. Pola ini menunjukkan bahwa model mampu mempelajari karakteristik data dengan baik tanpa mengalami overfitting yang signifikan.




Gambar 7. Hasil Pelatihan Model YOLOv8

Gambar 7 menunjukkan hasil evaluasi performa model berdasarkan metrik precision, recall, dan mean Average Precision (mAP). Berdasarkan hasil pelatihan, model mencapai nilai mAP sebesar 93%, dengan precision sebesar 88% dan recall sebesar 82%. Nilai mAP yang tinggi menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mengenali dan melokalisasi objek jalan berlubang pada citra uji. Capaian nilai mAP, precision, dan recall tersebut menunjukkan bahwa model YOLOv8 mampu menyeimbangkan kemampuan klasifikasi dan lokalisasi objek. Hal ini mengindikasikan bahwa arsitektur YOLOv8 yang digunakan efektif dalam mengekstraksi fitur visual jalan berlubang yang memiliki variasi bentuk dan ukuran.

b. Evaluasi Kinerja Model Menggunakan Confusion Matrix

Evaluasi lanjutan dilakukan menggunakan confusion matrix untuk melihat kemampuan model dalam mengklasifikasikan objek secara benar dan salah. Confusion matrix memberikan gambaran mengenai jumlah prediksi benar (true positive), kesalahan deteksi (false positive), serta objek yang tidak terdeteksi (false negative). Untuk memvisualisasikan hasil klasifikasi model YOLOv8 pada data pengujian, confusion matrix hasil pengujian model ditunjukkan pada Gambar 8.




Gambar 8. Confusion Matrix Hasil Pengujian Model

Berdasarkan Gambar 8, terlihat bahwa sebagian besar data uji berhasil diklasifikasikan dengan benar oleh model. Nilai false positive relatif rendah, yang menunjukkan bahwa model tidak banyak mendeteksi objek non-lubang sebagai lubang jalan. Namun, masih terdapat sejumlah false negative yang mengindikasikan bahwa beberapa lubang jalan tidak terdeteksi, terutama pada kondisi pencahayaan yang kurang optimal atau posisi objek yang tidak berada di area tengah citra. Hasil evaluasi confusion matrix ini menunjukkan bahwa pada tahap inferensi, model masih memiliki keterbatasan dalam mendeteksi objek dengan karakteristik visual yang kurang jelas. Temuan ini menjadi dasar untuk analisis lebih lanjut pada tahap pembahasan terkait faktor lingkungan dan kualitas citra.

c. Analisis Precision, Recall dan mAP

Grafik precision dan recall digunakan untuk mengevaluasi kestabilan performa model selama proses pelatihan. Grafik ini menunjukkan bahwa nilai precision dan recall cenderung stabil dan meningkat seiring bertambahnya epoch. Grafik perubahan nilai precision dan recall selama proses pelatihan model ditunjukkan pada Gambar 9.



Gambar 9. Grafik Precision dan Recall Model YOLOv8

Berdasarkan Gambar 9, dapat dilihat bahwa nilai precision dan recall cenderung stabil serta mengalami peningkatan seiring bertambahnya epoch. Nilai precision yang lebih tinggi dibandingkan recall menunjukkan bahwa model bersifat lebih selektif dalam mendeteksi jalan berlubang, sehingga prediksi yang dihasilkan umumnya memiliki tingkat kebenaran yang tinggi. Namun, nilai recall yang relatif lebih rendah mengindikasikan bahwa masih terdapat beberapa objek lubang jalan yang belum berhasil terdeteksi oleh model. Meskipun demikian, kombinasi nilai precision, recall, dan mAP yang tinggi menunjukkan bahwa model memiliki performa deteksi yang baik serta mampu digeneralisasi dengan baik pada data baru.

d. Hasil Pengujian Real-Time Menggunakan Kamera Smartphone

Selain pengujian menggunakan dataset primer, model YOLOv8 juga diuji secara real-time menggunakan kamera smartphone. Pengujian ini bertujuan untuk mengevaluasi kemampuan model dalam mendeteksi jalan berlubang pada kondisi nyata di lapangan. Contoh hasil deteksi jalan berlubang secara real-time menggunakan kamera smartphone ditunjukkan pada Gambar 10.



Gambar 10. Hasil Deteksi Jalan Berlubang Menggunakan Kamera Smartphone

Berdasarkan Gambar 10, hasil pengujian menunjukkan bahwa model mampu mendeteksi jalan berlubang secara real-time dengan tingkat akurasi lebih dari 85%. Deteksi berjalan optimal ketika kondisi pencahayaan memadai dan posisi lubang berada di area tengah citra. Pada kondisi pencahayaan rendah atau gambar yang kurang jelas, performa model cenderung menurun, yang ditandai dengan berkurangnya confidence score dan meningkatnya kemungkinan objek tidak terdeteksi. Hasil ini menunjukkan bahwa model YOLOv8 tidak hanya efektif pada data statis, tetapi juga memiliki potensi untuk diimplementasikan pada sistem pemantauan jalan berbasis perangkat bergerak secara real-time.

3.2 Pembahasan

Hasil penelitian ini menunjukkan bahwa penerapan YOLOv8 untuk deteksi jalan berlubang memberikan performa yang lebih baik dibandingkan beberapa penelitian terdahulu yang menggunakan versi YOLO sebelumnya. Dibandingkan dengan YOLOv5 yang dilaporkan memiliki akurasi sekitar 82%, model YOLOv8 dalam penelitian ini mampu mencapai mAP sebesar 93%. Peningkatan performa ini dipengaruhi oleh arsitektur YOLOv8 yang lebih efisien dalam mengekstraksi fitur serta kemampuannya dalam mendeteksi objek multi-skala. Jika dibandingkan dengan penelitian sejenis yang menggunakan YOLOv5 dan YOLOv7 untuk deteksi kerusakan jalan, model YOLOv8 dalam penelitian ini menunjukkan peningkatan nilai mAP dan kestabilan deteksi, khususnya pada objek dengan ukuran kecil hingga

menengah. Hal ini memperkuat kontribusi ilmiah penelitian ini dalam menunjukkan keunggulan YOLOv8 untuk aplikasi deteksi jalan berlubang. Penggunaan dataset gabungan dari Kaggle dan data lokal hasil pengambilan langsung menggunakan smartphone juga berkontribusi dalam meningkatkan kemampuan generalisasi model terhadap kondisi jalan di Indonesia.

Kelebihan utama sistem yang dikembangkan terletak pada kemampuannya melakukan deteksi secara real-time dengan akurasi tinggi dan arsitektur yang relatif ringan. Namun, sistem masih memiliki keterbatasan pada kondisi pencahayaan ekstrem dan sudut pengambilan gambar yang tidak ideal. Oleh karena itu, pengembangan lebih lanjut dapat dilakukan dengan menambah variasi dataset, menerapkan augmentasi data yang lebih kompleks, serta mengintegrasikan model dengan sistem pemantauan jalan berbasis kendaraan atau kamera statis. Secara keseluruhan, hasil dan pembahasan ini menunjukkan bahwa model YOLOv8 memiliki potensi yang kuat untuk diterapkan sebagai sistem deteksi otomatis jalan berlubang secara real-time dan dapat mendukung upaya pemeliharaan infrastruktur serta peningkatan keselamatan lalu lintas.

4. KESIMPULAN

Penelitian ini berhasil membangun dan mengevaluasi sistem deteksi otomatis jalan berlubang berbasis deep learning menggunakan arsitektur YOLOv8 sebagai solusi terhadap permasalahan kerusakan jalan yang berpotensi meningkatkan risiko kecelakaan lalu lintas. Hasil pelatihan dan pengujian menunjukkan bahwa model YOLOv8 mencapai performa deteksi yang sangat baik dengan nilai mean Average Precision (mAP) sebesar 93%, precision sebesar 88%, dan recall sebesar 82%, yang menegaskan kemampuan model dalam mengenali dan melokalisasi objek jalan berlubang secara akurat. Selain itu, pengujian secara real-time menggunakan kamera smartphone menghasilkan tingkat akurasi deteksi lebih dari 85%, yang menunjukkan bahwa sistem mampu bekerja secara efektif pada kondisi nyata di lapangan. Temuan ini membuktikan bahwa penerapan YOLOv8 dapat menjadi pendekatan yang andal dan efisien untuk sistem pendeteksian jalan berlubang secara real-time, khususnya pada kondisi jalan di Indonesia yang memiliki variasi pencahayaan dan sudut pengambilan gambar. Meskipun demikian, penelitian ini masih memiliki keterbatasan pada kondisi pencahayaan ekstrem, sudut pengambilan gambar yang tidak ideal, serta keterbatasan jumlah dan variasi dataset yang digunakan. Oleh karena itu, penelitian selanjutnya disarankan untuk memperluas dan memperkaya dataset, menerapkan teknik augmentasi data yang lebih beragam, mengembangkan sistem untuk mendeteksi berbagai jenis kerusakan jalan lainnya, serta mengintegrasikan modul berbasis GPS guna mendukung pemetaan lokasi kerusakan dan penentuan prioritas perbaikan secara lebih terukur.

REFERENCES

- [1] J.-P. Rodrigue, *The Geography of Transport Systems*, 6th Editio. 2024. doi: <https://doi.org/10.4324/9781003343196>.
- [2] S. A. Rosyidah, A. Z. Z. Ismanafi, A. Putra, S. Khoirudin, W. P. Soeprapto, and U. T. Madura, "Pentingnya infrastruktur jalan bagi aksesibilitas ekonomi dan sosial terhadap warga desa sambongrejo dan desa sendangagung bojonegoro," vol. 2, no. 10, 2024.
- [3] E. M. A.T. Papagiannakis, *Pavement Design and Materials*. Canada, 2024. doi: <https://lcn.loc.gov/2024007662>.
- [4] Statistik B P, "Hasil Sensus Penduduk 2020," *Badan Pus. Stat.*, 2020.
- [5] BPS, "Badan Pusat Statistik (Statistik Transportasi Darat 2023)," 2023.
- [6] A. W. Hidayat and S. R. L. Utami, "Analisis Penyebab Kecelakaan Lalu Lintas Di Kota Semarang," *J. Kaji. Tek. Sipil*, vol. 5, no. 1, pp. 28–35, 2020, doi: 10.52447/jkts.v5i1.4111.
- [7] Suhardi Aras, "Deteksi Jalan Berlubang Menggunakan Algoritma YOLOv5," *J. Digit. Bus. Inf. Technol. Deteksi*, vol. 01, no. 1, pp. 1–8, 2024, doi: 10.23971/jobit.v1i1.198.
- [8] E. Setiadi *et al.*, "Klasifikasi dan Deteksi Keretakan Pada Trotoar Menggunakan Metode Convolutional Neural Network Keywords : Road Crack Detection ; CNN ; Web Deep Learning Jalan merupakan prasarana transportasi darat yang meliputi segala bagian jalan dari badan jalan , term," pp. 411–425, 2024.
- [9] and Y. Z. Long Cheng, Dan Zhang, "Road Object Detection in Foggy Complex Scenes Based on Improved YOLOv8," *IEEE Access*, vol. 12, no. August, pp. 107420–107430, 2024, doi: 10.1109/ACCESS.2024.3438612.
- [10] X. Liu, Y. Chu, Y. Hu, and N. Zhao, "Enhancing Intelligent Road Target Monitoring: A Novel BGS YOLO Approach Based on the YOLOv8 Algorithm," *IEEE Open J. Intell. Transp. Syst.*, vol. 5, no. August, pp. 509–519, 2024, doi: 10.1109/OJITS.2024.3449698.
- [11] D. D. Van, "Application of Advanced Deep Convolutional Neural Networks for the Recognition of Road Surface Anomalies," *Eng. Technol. Appl. Sci. Res.*, vol. 13, no. 3, pp. 10765–10768, 2023, doi: 10.48084/etasr.5890.
- [12] J. Zeng and H. Zhong, "YOLOv8-PD: an improved road damage detection algorithm based on YOLOv8n model," *Sci. Rep.*, vol. 14, no. 1, pp. 1–14, 2024, doi: 10.1038/s41598-024-62933-z.
- [13] Y. T. Penangsang and I. A. Muntaha, "Mendeteksi Jalan Berlubang Menggunakan Deep Learning," vol. 03, no. 01, pp. 1–6, 2025.
- [14] L. G. Denaro and R. Lim, "Analisis Deteksi Kerusakan pada Jalan Aspal menggunakan Deep Learning untuk Mendukung Efisiensi Biaya dan Waktu dalam Pemantauan Berkelanjutan," *J. Dimens. Ins. Prof.*, vol. 3, no. 1, pp. 16–25, 2025, doi: 10.9744/jdip.3.1.16-25.
- [15] S. Zhang, Z. Liu, K. Wang, W. Huang, and P. Li, "OBC-YOLOv8 : an improved road damage detection model based on YOLOv8," no. 2010, 2025, doi: 10.7717/peerj-cs.2593.
- [16] P. R. Gustyanto Firgiawan, Nazwa Lintang Seina, "Implementasi Metode You Only Look Once (YOLO) untuk Pendeteksi Objek dengan Tools OpenCV," *J. Artif. Intel. dan Sist. Penunjang Keputusan*, vol. 2, no. 2, pp. 137–141, 2024, [Online]. Available: <https://jurnalmahasiswa.com/index.php/aidanspk>

- [17] A. I. Pradana, “Deteksi Rambu Lalu Lintas Real-Time di Indonesia dengan Penerapan YOLOv11 : Solusi Untuk Keamanan Berkendara,” pp. 145–155, 2024, doi: 10.33364/algorithm/v.21-2.2106.
- [18] N. Khairunisa *et al.*, “Analisis perbandingan algoritma cnn dan yolo dalam mengidentifikasi kerusakan jalan,” vol. 12, no. 3, 2024.
- [19] N. Untuk, K. Penyakit, T. Padi, C. Of, and R. Plant, “Optimasi hyperparameter convolutional neural network untuk klasifikasi penyakit tanaman padi,” 2022.
- [20] H. Yugaswara, H. Wicaksono, and F. T. Informasi, “Sistem komputasi paralel menggunakan gpu berbasis nvidia cuda,” vol. 17, no. 2, pp. 158–164, 2021.