

# IMPLEMENTASI MODEL DEEP LEARNING UNTUK DETEKSI DAN KLASIFIKASI JENIS KERUSAKAN JALAN DI KOTA PALANGKARAYA

Ricard Jonathan<sup>1</sup>, Nova Noor Kamala Sari<sup>\*2</sup>, Efrans Christian<sup>3</sup>

<sup>1-3</sup>Jurusan Teknik Informatika, Universitas Palangka Raya

E-mail: [ricardjonathan36@gmail.com](mailto:ricardjonathan36@gmail.com)<sup>1</sup>, [novanoorks@it.upr.ac.id](mailto:novanoorks@it.upr.ac.id)<sup>\*2</sup>,  
[efrans@it.upr.ac.id](mailto:efrans@it.upr.ac.id)<sup>3</sup>

**Abstrak.** Jalan merupakan infrastruktur penting yang mendukung aktivitas masyarakat, sehingga kerusakan yang tidak segera diperbaiki dapat menghambat mobilitas dan meningkatkan risiko kecelakaan. Penelitian ini mengembangkan aplikasi mobile pelaporan kondisi jalan yang terintegrasi dengan model deep learning YOLOv8 untuk mendeteksi dan mengklasifikasikan tingkat kerusakan. Dataset terdiri dari 2.296 citra untuk klasifikasi kondisi jalan (baik, sedang, rusak ringan, rusak berat) dan 2.245 citra untuk mendeteksi tujuh jenis kerusakan, termasuk amblas, bergelombang, lubang besar, lubang kecil, serta berbagai jenis retak. Evaluasi pada 420 citra menunjukkan performa deteksi dengan Precision 62,4%, Recall 62,0%, dan mAP 62,9%. Kelas Amblas memberikan hasil terbaik, sedangkan Retak Buaya memiliki performa terendah. Pada klasifikasi kondisi jalan, YOLOv8 menunjukkan akurasi sangat baik, mencapai hingga 100% pada kategori rusak berat. Hasil ini menunjukkan bahwa YOLOv8 efektif dalam menganalisis kondisi jalan meskipun tingkat kepastian deteksi berbeda pada setiap jenis kerusakan.

**Kata kunci:** YOLOv8, deep learning, deteksi kerusakan jalan, klasifikasi kondisi jalan, aplikasi mobile

**Abstract.** Roads are vital infrastructure that support community mobility, and unaddressed damage can hinder transportation and increase accident risk. This study develops a mobile reporting application integrated with the YOLOv8 deep learning model to detect and classify road damage. The dataset consists of 2,296 images for road-condition classification (good, moderate, minor damage, severe damage) and 2,245 images for detecting seven types of road defects, including subsidence, bumps, large potholes, small potholes, alligator cracks, transverse cracks, and longitudinal cracks. Evaluation on 420 images achieved a detection performance of 62.4% Precision, 62.0% Recall, and 62.9% mAP. The best performance was obtained for the Subsidence class, while Alligator Cracks had the lowest results. For road-condition classification, YOLOv8 performed very well, reaching up to 100% accuracy for severe-damage cases. These findings demonstrate that YOLOv8 is effective in analyzing road conditions, although detection confidence varies across damage types.

**Keywords:** YOLOv8, deep learning, road damage detection, road condition classification, mobile application.

## **1. Pendahuluan**

Jalan sebagai sarana transportasi memiliki peran penting dalam mempermudah berbagai aktivitas masyarakat, termasuk di bidang ekonomi, kesehatan, pendidikan, dan sosial. Secara khusus, pada sektor ekonomi, infrastruktur jalan berkontribusi terhadap pemerataan pembangunan dan peningkatan aksesibilitas di berbagai wilayah Indonesia. Jalan yang baik dapat memperlancar distribusi barang dan jasa, sehingga mendorong pertumbuhan perdagangan di tingkat lokal, regional, maupun nasional[1]. Jalan merupakan kebutuhan vital bagi masyarakat, terutama dalam mendukung mobilitas dari satu daerah ke daerah lainnya [2]. Tujuan utama pembangunan infrastruktur jalan adalah untuk mencapai pemerataan pembangunan antarwilayah serta meningkatkan pengembangan ekonomi secara berkelanjutan[3].

Dengan kemajuan teknologi, khususnya pada bidang kecerdasan buatan (Artificial Intelligence), metode deep learning kini banyak dimanfaatkan untuk mengotomatisasi berbagai proses, termasuk dalam pengolahan citra digital. Salah satu pendekatan terkini yang menunjukkan performa tinggi dalam akurasi dan kecepatan deteksi objek adalah You Only Look Once versi 8 (YOLOv8) yang dikembangkan oleh Ultralytics. Algoritma YOLO sangat baik digunakan pada proyek yang bersifat real-time, seperti deteksi objek pada citra maupun video. Seiring dengan pesatnya perkembangan penelitian di bidang computer vision, algoritma deteksi objek YOLO terus mengalami peningkatan hingga versi terbarunya, YOLOv8[4].

Pemanfaatan YOLOv8 dalam aplikasi mobile membuka peluang bagi masyarakat untuk secara langsung melaporkan kondisi jalan melalui pengambilan gambar menggunakan ponsel. Gambar tersebut kemudian diproses oleh model YOLOv8 untuk mendeteksi serta mengklasifikasikan jenis kerusakan, seperti retakan, lubang, maupun permukaan bergelombang. Hasil klasifikasi dapat dikirimkan secara otomatis ke Dinas Pekerjaan Umum dan Penataan Ruang Kota Palangka Raya untuk ditindaklanjuti dengan cepat dan tepat.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk merancang dan mengimplementasikan aplikasi mobile yang mampu melakukan klasifikasi, deteksi, sekaligus pelaporan kerusakan jalan secara otomatis menggunakan metode YOLOv8. Melalui pendekatan ini, diharapkan proses pengelolaan dan penanganan infrastruktur jalan di Kota Palangka Raya dapat dilakukan secara lebih efisien, terarah, dan mendukung pengambilan keputusan yang lebih baik dalam perencanaan perbaikan jalan.

## **2. Landasan Teori**

### **2.1 Artificial Intelligence**

Kecerdasan buatan atau Artificial Intelligence (AI) merupakan teknologi yang menggambarkan kecerdasan layaknya manusia dan mencakup beberapa teknologi saling berkaitan, seperti pembelajaran mesin, ekstraksi data, pengolahan bahasa alami, identifikasi gambar, identifikasi suara, serta analisis sentimen. AI juga merupakan salah satu cabang ilmu komputer yang dirancang untuk meniru kemampuan manusia dalam mengenali pola, belajar, dan membuat keputusan[5].

Selain itu, AI memiliki peran penting dalam proses deteksi dan analisis terhadap kumpulan data berukuran besar, sehingga memudahkan dalam menemukan pola maupun anomali, termasuk dalam konteks transaksi keuangan[6]. Dengan kemampuan tersebut, AI menjadi alat yang sangat potensial untuk meningkatkan efisiensi, akurasi, dan keandalan dalam berbagai proses pengambilan keputusan berbasis data.

### **2.2 Deep Learning**

Deep Learning merupakan bagian dari kecerdasan buatan (Artificial Intelligence) dan Machine Learning yang dikembangkan dari konsep neural network dengan banyak lapisan (multiple layers) untuk meningkatkan ketepatan dalam menyelesaikan berbagai tugas seperti deteksi objek, pengenalan suara, penerjemahan bahasa, dan lain-lain. Berbeda dengan teknik machine learning tradisional, deep learning mampu secara otomatis melakukan representasi terhadap data seperti gambar, video, atau teks tanpa memerlukan aturan kode atau pengetahuan domain secara eksplisit dari manusia [7].

Deep Learning (DL) merupakan salah satu subdivisi dari Machine Learning (ML) yang mengandalkan jaringan saraf tiruan (Artificial Neural Network/ANN), atau dapat dianggap sebagai bentuk

pengembangan lanjut dari ANN. Topik ini dalam beberapa tahun terakhir mendapat perhatian yang signifikan di kalangan peneliti dan praktisi di bidang teknologi informasi. Deep Learning berbeda dari jaringan saraf tiruan (JST) tradisional karena menggabungkan beberapa lapisan tersembunyi (hidden layers) yang dirancang untuk meningkatkan tingkat keakuratan keluaran. Metodologi Deep Learning telah menjadi salah satu pendekatan utama dalam penerapan Machine Learning modern, terutama untuk permasalahan yang melibatkan data berukuran besar dan kompleks[8].

### 2.3 YOLOv8

YOLOv8 merupakan versi terbaru dari seri You Only Look Once (YOLO) yang menghadirkan peningkatan signifikan dalam hal akurasi, kecepatan, dan efisiensi untuk deteksi objek secara real-time. Dengan menggunakan arsitektur backbone dan neck yang canggih serta head Ultralytics Split Anchor-Free, YOLOv8 mampu meningkatkan kemampuan ekstraksi fitur dan proses deteksi objek secara lebih efisien. Model ini menawarkan keseimbangan optimal antara akurasi dan kecepatan, sehingga cocok digunakan dalam berbagai aplikasi seperti sistem pengawasan video, kendaraan otonom, dan aplikasi berbasis web tanpa memerlukan instalasi tambahan.

Selain itu, YOLOv8 mendukung berbagai tugas visi komputer, termasuk deteksi objek, segmentasi instansi, deteksi pose, dan klasifikasi. Model ini juga menyediakan pre-trained model serta dukungan untuk pembuatan model kustom guna menghasilkan deteksi yang lebih presisi. Dengan kemampuan dan fleksibilitas yang dimilikinya, YOLOv8 dapat diterapkan pada berbagai tahap pengembangan maupun aplikasi dunia nyata, seperti robotika dan sistem deteksi objek real-time. Oleh karena itu, YOLOv8 menjadi salah satu algoritma yang efektif dalam melakukan deteksi objek[9][10].

### 2.4 Klasifikasi

Klasifikasi merupakan metode analisis yang bertujuan untuk mengelompokkan data ke dalam kategori atau kelas tertentu berdasarkan sifat maupun karakteristik yang dimilikinya[11]. Metode ini sering digunakan untuk membangun model prediktif yang dapat membantu proses pengambilan keputusan. Secara umum, klasifikasi adalah proses penentuan kelas atau kategori suatu data berdasarkan aturan, pola, atau model yang telah ditetapkan sebelumnya[12].

### 2.5 Deteksi

Deteksi objek merupakan salah satu tugas penting dalam bidang visi komputer yang bertujuan untuk mengidentifikasi serta menentukan lokasi objek pada citra maupun video. Metode YOLO (You Only Look Once) telah menjadi salah satu pendekatan yang populer dalam deteksi objek karena mampu melakukan proses deteksi secara real-time dengan tingkat akurasi yang tinggi. Penelitian ini bertujuan untuk menyajikan tinjauan literatur secara sistematis mengenai penerapan metode YOLO dalam tugas deteksi objek[13].

### 2.6 Confusion Matrix

Confusion matrix adalah tabel berukuran  $m \times m$  yang digunakan untuk menggambarkan kinerja suatu pengklasifikasi dengan membandingkan label prediksi dengan label aktual. Pengklasifikasi yang baik memiliki nilai yang tinggi pada diagonal utama, yaitu True Positives (TP) dan True Negatives (TN), serta nilai nol atau mendekati nol pada elemen di luar diagonal. Pada confusion matrix  $2 \times 2$ , beberapa istilah penting yang digunakan antara lain: P sebagai jumlah data positif aktual, N sebagai jumlah data negatif aktual, P' sebagai jumlah data positif hasil prediksi, dan N' sebagai jumlah data negatif hasil prediksi. Adapun TP (True Positives) merupakan prediksi positif yang benar, TN (True Negatives) merupakan prediksi negatif yang benar, FP (False Positives) adalah prediksi positif yang salah (seharusnya negatif), dan FN (False Negatives) adalah prediksi negatif yang salah (seharusnya positif). Tiga metrik evaluasi penting yang dihitung dari confusion matrix adalah:

- Accuracy: Seberapa baik klasifikasi secara keseluruhan.  $\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN)$
- Precision: Seberapa tepat prediksi positif.  $\text{Precision} = TP / (TP + FP)$
- Recall: Seberapa baik model menemukan semua data positif yang sebenarnya.  $\text{Recall} = TP / (TP + FN)$


Nilai accuracy, precision, dan recall biasanya dinyatakan dalam persentase (0-100%). Sistem dianggap baik jika ketiga metrik ini bernilai tinggi[14].

### 2.7 mAP mean Average Precision

Mean Average Precision (mAP) adalah salah satu metrik evaluasi yang paling umum digunakan untuk menilai kinerja model deteksi objek, termasuk pada dataset COCO (Common Objects in Context). Metrik ini menghitung rata-rata nilai presisi pada berbagai tingkat recall, sehingga memberikan gambaran seberapa baik model mampu mendeteksi objek secara konsisten di seluruh rentang recall. Makin tinggi nilai mAP, makin baik kualitas deteksi yang dihasilkan oleh model.

## 3. Metode Penelitian

Pada penelitian ini, metode pengembangan perangkat lunak yang digunakan untuk "Implementasi Model Deep Learning untuk Deteksi dan Klasifikasi Jenis Kerusakan Jalan di Kota Palangka Raya" adalah metode Agile. Metode ini dipilih agar sistem yang dikembangkan dapat menyesuaikan dengan kebutuhan pengguna serta berfungsi secara optimal. Agile memungkinkan proses pengembangan dilakukan secara bertahap dan fleksibel, sehingga setiap perubahan atau perbaikan dapat diterapkan dengan cepat dan efisien. Tahapan dalam metode Agile yang diterapkan pada penelitian ini sebagaimana diperlihatkan pada Gambar 1. Metode Agile[15].



**Gambar 1** Metode Agile

### 3.1. Requirements

Pada tahap ini, dilakukan analisis dan perancangan untuk pengembangan aplikasi mobile yang digunakan dalam proses klasifikasi, deteksi, dan pelaporan kerusakan jalan menggunakan YOLOv8 di Dinas Pekerjaan Umum dan Penataan Ruang Kota Palangka Raya. Tujuan dari tahap ini adalah mengevaluasi sistem yang sedang berjalan (sistem lama) serta merancang sistem baru yang lebih sesuai dengan kebutuhan pengguna. Berdasarkan hasil evaluasi tersebut, sistem baru dirancang untuk meningkatkan kemudahan dan kenyamanan penggunaan. Tahap ini juga menghasilkan flowchart atau diagram alir yang menggambarkan alur proses bisnis, baik pada sistem lama maupun sistem yang akan dikembangkan. Selain itu, tahap ini bertujuan untuk mengidentifikasi dan merumuskan kebutuhan sistem agar aplikasi yang dibangun dapat berjalan dengan baik.

### 3.2. Design

Setelah melakukan komunikasi dan perencanaan, selanjutnya melakukan perancangan aplikasi pelaporan jalan rusak dengan menggunakan Unified Modeling Language (UML). UML sendiri adalah suatu cara dalam permodelan secara visual untuk sarana perancangan sistem, konsep UML disini meliputi Use Case Diagram, Class Diagram serta Activity Diagram.

### 3.3. Develop


Pada tahap ini dilakukan implementasi dan pengujian unit terhadap sistem yang telah dikembangkan. Implementasi dilakukan dengan menerjemahkan desain sistem menjadi kode program menggunakan teknologi seperti Flutter (Dart) untuk antarmuka pengguna aplikasi mobile, Golang untuk backend API utama, FastAPI (Python) untuk layanan klasifikasi jalan berbasis YOLOv8, Laravel (PHP) untuk panel web admin, serta basis data MySQL sebagai media penyimpanan data. Setiap unit program yang telah dibuat, baik pada sisi mobile, backend, web admin, maupun layanan klasifikasi, diuji secara terpisah untuk memastikan bahwa masing-masing unit berjalan sesuai dengan fungsi yang telah dirancang. Pengujian ini mencakup validasi antarmuka pengguna, pengolahan data di backend, pengelolaan laporan di panel admin, serta akurasi deteksi dan klasifikasi dari layanan FastAPI. Seluruh pengujian dilakukan oleh pengembang sebelum proses integrasi sistem secara menyeluruh, guna menjamin stabilitas dan keandalan aplikasi secara keseluruhan.

### 3.4. Test

Pada tahap test, penulis memilih menggunakan metode Black-Box Testing. Black-Box Testing adalah metode pengujian perangkat lunak di mana sistem diuji tanpa pengetahuan terperinci mengenai desain atau implementasi internalnya. Tujuan pengujian ini adalah untuk memastikan bahwa sistem telah berfungsi sesuai dengan kebutuhan pengguna dan spesifikasi fungsional yang telah ditentukan. Pengujian dilakukan berdasarkan input dan output sistem, tanpa memeriksa struktur internal kode program. Uji coba dilakukan pada berbagai fitur sistem dengan beberapa skenario untuk memastikan seluruh fungsionalitas berjalan sebagaimana mestinya.

## 4. Alur Penelitian

Berikut adalah pengembangan alur penelitian Yolov8 untuk Klasifikasi dan deteksi Kerusakan kondisi Jalan dengan penjelasan yang lebih rinci dan mendalam:



Gambar 2. Alur Penelitian

Penelitian ini diawali dengan pengumpulan gambar kondisi jalan dari berbagai sumber, seperti dokumentasi lapangan, data Dinas PUPR Kota Palangka Raya, dan dataset publik dari Roboflow. Data yang terkumpul diseleksi dan diklasifikasikan berdasarkan jenis kerusakan jalan (baik, rusak ringan, rusak sedang, rusak berat) serta jenis objek spesifik (ambblas, retak, lubang).

Selanjutnya dilakukan pelabelan data secara manual menggunakan Roboflow untuk memberi anotasi pada setiap gambar sesuai jenis kerusakan. Data berlabel kemudian diproses melalui tahap

*preprocessing*, meliputi auto-orientasi, *resize* ke 640×640 piksel, dan pembagian dataset menjadi *training* (70%), *validation* (20%), dan *testing* (10%).

Model YOLOv8 dilatih menggunakan optimizer AdamW selama 100 *epoch*. Optimizer ini mempercepat konvergensi sekaligus mencegah *overfitting*. Selama pelatihan, sistem menghitung *class loss*, *box loss*, dan *Distribution Focal Loss (DFL)* untuk meningkatkan akurasi deteksi. Evaluasi model dilakukan menggunakan metrik *Precision*, *Recall*, dan *mAP* untuk menilai performa deteksi.

Model yang telah terlatih diintegrasikan ke dalam sistem melalui REST API agar dapat digunakan oleh aplikasi mobile. Pengguna dapat mengunggah foto kondisi jalan untuk dideteksi dan diklasifikasikan secara otomatis, lalu menambahkan deskripsi dan lokasi sebelum mengirim laporan. Laporan diverifikasi oleh admin melalui sistem web sebelum disimpan ke database sebagai data pendukung perencanaan pemeliharaan jalan.

## **5. Hasil dan Pembahasan**

### *5.1. Implementasi Model Deep Learning (YOLOv8)*

Implementasi model ini melibatkan dua tugas utama: klasifikasi kondisi jalan (Baik, Sedang, Rusak Ringan, Rusak Berat) dan deteksi objek kerusakan spesifik (Lubang Besar, Lubang Kecil, Ambblas, Retak Panjang, Retak Buaya, Bergelombang, Retak Melintang) menggunakan arsitektur YOLOv8.

#### **1. Pengambilan dan Persiapan Dataset**

Dataset diperoleh dari gabungan gambar kamera ponsel, data dari PUPR Kota Palangka Raya, dan data dari Roboflow.

- a. Dataset Klasifikasi berjumlah total gambar, dibagi menjadi empat kategori: Baik, Sedang, Rusak Ringan, dan Rusak Berat. Distribusi ini dianggap cukup seimbang. Pembagian data untuk pelatihan menggunakan proporsi train, validation, dan test. Pra-pemrosesan meliputi auto-orient dan resize ke piksel tanpa augmentasi.
- b. Dataset Deteksi Objek berjumlah total instance objek dari gambar, yang setelah augmentasi menjadi gambar. Tujuh kelas kerusakan yang dilabeli mencakup Lubang Kecil, Retak Panjang, Retak Buaya, Lubang Besar, Retak Melintang, Ambblas, dan Bergelombang. Pembagian data otomatis oleh Roboflow menggunakan proporsi train, validation, dan test setelah augmentasi. Pra-pemrosesan mencakup auto-orient, resize ke piksel, dan augmentasi data (grayscale, perubahan saturasi, kecerahan, dan efek blur).
- c. Pelabelan dilakukan menggunakan aplikasi Roboflow dengan menambahkan *bounding box* di sekitar objek untuk deteksi dan melabeli kondisi jalan untuk klasifikasi.

#### **2. Pelatihan Model (*Training*)**


Pelatihan model YOLOv8 dilakukan di Google Colab menggunakan dataset yang telah diekspor dari Roboflow, lengkap dengan anotasi yang diperlukan untuk kedua tugas, yaitu klasifikasi dan deteksi objek.

#### **3. Hasil Evaluasi Model YOLOv8**

Setelah pelatihan, model dievaluasi menggunakan data uji yang belum pernah dilihat model sebelumnya, dengan metrik yang berbeda untuk klasifikasi dan deteksi objek.

### *5.2. Evaluasi Model Klasifikasi*


#### *a. Evaluasi Model Precision, Recall, F1-score per Class*



Gambar 3. Evaluasi Model Precision, Recall, F1-score per Class

b. Evaluasi Model Confusion matrix

Confusion Matrix dari hasil klasifikasi model untuk mendeteksi kondisi jalan dengan empat kategori utama, yaitu Baik, Rusak Berat, Rusak Ringan, dan Sedang. Matriks ini menampilkan perbandingan antara prediksi model dan label sebenarnya, di mana setiap baris merepresentasikan kelas sebenarnya (actual) dan setiap kolom merepresentasikan prediksi model. Nilai pada diagonal utama menunjukkan jumlah prediksi yang benar untuk masing-masing kelas, sedangkan nilai di luar diagonal menunjukkan jumlah kesalahan prediksi (misclassification) ketika model mengklasifikasikan suatu kelas sebagai kelas lain. Melalui confusion matrix ini, dapat diketahui seberapa baik model mengenali setiap kategori, sekaligus mengidentifikasi kelas mana yang sering keliru terdeteksi.

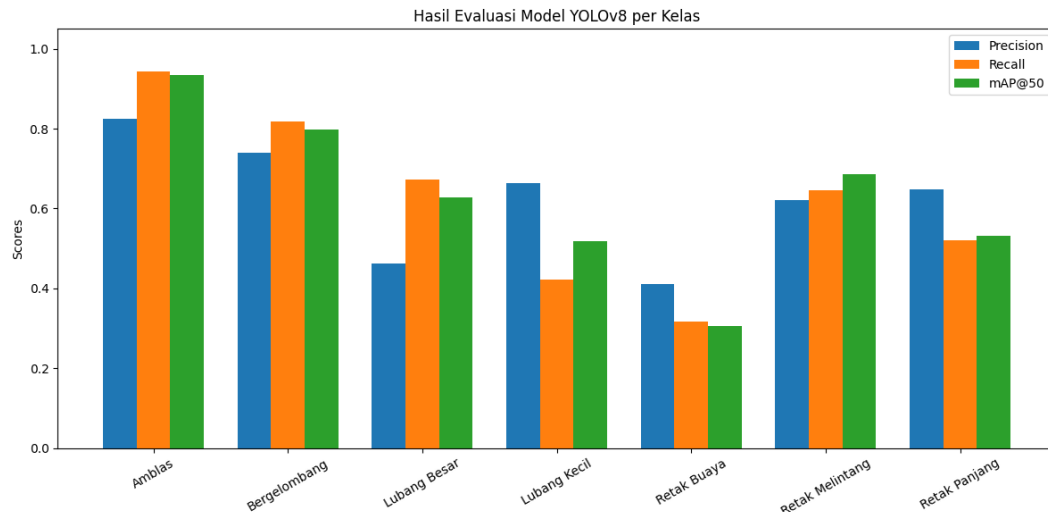


Gambar 4. Evaluasi Model Confusion Matrix

Berdasarkan hasil evaluasi pada Confusion Matrix, terlihat bahwa model klasifikasi kerusakan jalan mampu mengenali sebagian besar kelas dengan baik. Pada kelas Baik, model berhasil mengklasifikasikan dengan benar sebesar 93% dari total data, dengan kesalahan prediksi terbesar terjadi ke kelas “Rusak Ringan” dan “Sedang” masing-masing sebesar 3%. Kelas Rusak Berat memiliki akurasi tertinggi yaitu 96%, menunjukkan bahwa model hampir selalu tepat dalam mengidentifikasi kondisi jalan rusak berat. Sementara itu, kelas Sedang juga menunjukkan kinerja tinggi dengan akurasi sebesar 93%, meskipun terdapat kesalahan prediksi sebesar 6% ke kelas “Rusak Berat”. Di sisi lain, kelas Rusak Ringan menjadi kategori dengan akurasi terendah yaitu 84%, yang mengindikasikan bahwa model masih cukup sering keliru membedakannya dengan kelas “Baik” maupun “Sedang”. Secara umum, model menunjukkan performa yang baik untuk sebagian besar kategori, namun memerlukan peningkatan pada perbedaan kelas yang memiliki kemiripan visual, khususnya antara “Rusak Ringan” dengan kelas lain.

### 5.3. Evaluasi Model Deteksi Objek

#### a. Evaluasi Model Precision, Recall, dan mAP

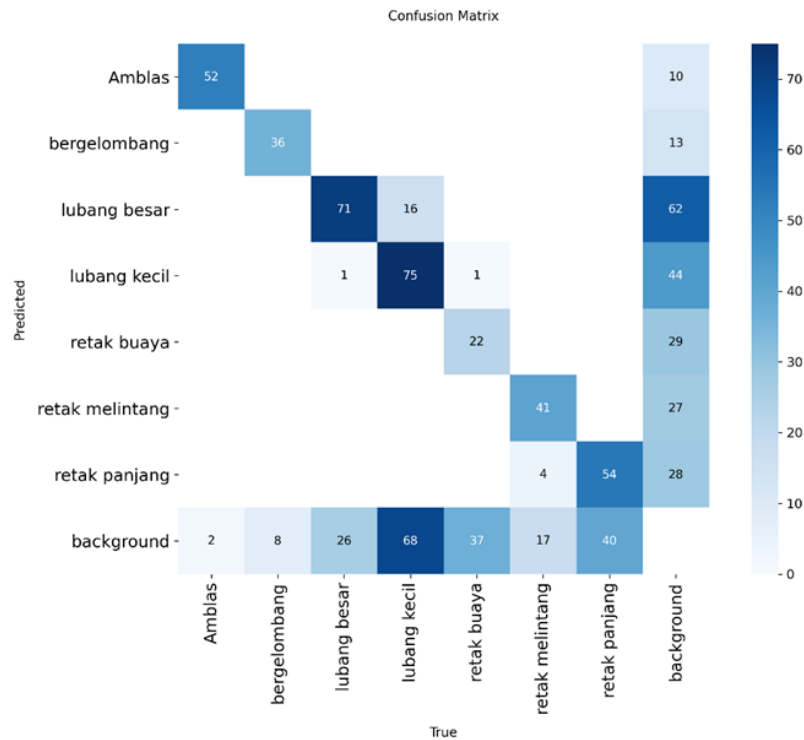


Gambar 5. Evaluasi Model Precision, Recall, dan mAP

Kinerja terbaik ditunjukkan oleh kelas Amblas dengan nilai mAP50 tertinggi sebesar 0.93, menandakan kemampuan deteksi yang sangat baik. Sebaliknya, kelas Retak Buaya memiliki kinerja terendah dengan mAP50 sebesar 0.30. Berdasarkan analisis *Confusion Matrix*, tantangan utama terletak pada tingginya jumlah *false negative*, yaitu objek yang keliru terklasifikasi sebagai *background*, terutama pada kelas Retakan, Amblas, dan Bergelombang. Untuk kelas Lubang Kecil, terdapat 44 instance yang salah terklasifikasi sebagai *background* dan 1 instance sebagai Lubang Besar, sedangkan kelas Lubang Besar mengalami kesalahan klasifikasi ke Lubang Kecil sebanyak 16 instance dan ke *background* sebanyak 62 instance.

#### b. Evaluasi Model Confusion matrix





Gambar 6. Evaluasi Model Confusion matrix

Berdasarkan confusion matrix hasil evaluasi model YOLOv8, model sudah mampu mengenali sebagian besar kelas dengan cukup baik, meskipun masih terdapat kesalahan klasifikasi pada beberapa kelas tertentu. Kelas Amblas sebagian besar berhasil diprediksi dengan benar sebanyak 52 instance, namun masih terdapat 10 instance yang salah terklasifikasi sebagai background. Kelas Bergelombang dikenali dengan baik sebanyak 36 instance, tetapi masih terjadi kesalahan ke background sebanyak 13 instance. Kelas Lubang Besar menunjukkan performa yang cukup baik dengan 71 instance terklasifikasi benar, meskipun masih terdapat kesalahan ke kelas Lubang Kecil sebanyak 16 instance dan ke background sebanyak 62 instance. Sementara itu, kelas Lubang Kecil juga memiliki hasil yang cukup baik dengan 75 instance terklasifikasi benar, namun masih terdapat kesalahan prediksi ke Lubang Besar sebanyak 1 instance dan ke background sebanyak 44 instance. Pada kelas Retak Buaya, hanya 22 instance yang berhasil diprediksi dengan benar, sedangkan 29 instance lainnya salah diklasifikasikan sebagai background. Kelas Retak Melintang memiliki 41 instance terklasifikasi dengan benar, tetapi masih terdapat 27 instance yang salah ke background. Adapun kelas Retak Panjang diprediksi dengan benar sebanyak 54 instance, meskipun masih terdapat 28 instance yang salah diklasifikasikan ke background. Selain itu, kelas Background juga menjadi sumber kesalahan terbesar karena banyak objek dari hampir semua kelas lain yang masih terklasifikasi sebagai background, seperti 68 instance dari kelas Lubang Kecil dan 40 instance dari kelas Retak Panjang. Secara umum, meskipun model cukup baik dalam mengenali kelas Lubang Besar dan Lubang Kecil, namun kelas Retakan, Amblas, dan Bergelombang masih rawan mengalami salah klasifikasi menjadi background. Hal ini menunjukkan bahwa permasalahan utama model terletak pada tingginya nilai false negative terhadap background. Oleh karena itu, diperlukan upaya perbaikan melalui penyeimbangan jumlah data antar kelas serta penerapan teknik augmentasi data pada kelas dengan jumlah sampel yang sedikit atau yang sering mengalami kesalahan klasifikasi.

#### 5.4. Hasil Pengujian Pada Aplikasi Mobile

Pengujian aplikasi mobile dilakukan untuk memastikan seluruh fitur berfungsi dengan baik sesuai kebutuhan pengguna. Pengujian menggunakan perangkat berbasis Android berfokus pada proses

pelaporan kerusakan jalan, meliputi input data, unggah foto, deteksi kerusakan, dan pengiriman laporan ke server. Hasil pengujian menunjukkan bahwa aplikasi menampilkan antarmuka yang responsif dan seluruh komponen dapat diakses tanpa kendala. Proses pelaporan berjalan lancar mulai dari pengisian form (username, deskripsi, lokasi, dan foto) hingga pengiriman data ke server. Integrasi model YOLOv8 pada backend juga berfungsi dengan baik, menampilkan hasil deteksi kerusakan secara real-time dalam bentuk kategori dan tingkat kepercayaan. Dengan demikian, aplikasi mobile ini terbukti efektif dan akurat untuk membantu masyarakat melaporkan kerusakan jalan secara cepat, serta mendukung pihak Dinas PUPR dalam proses tindak lanjut perbaikan.



Gambar 7. Halaman Lapor

## 6. Kesimpulan

Berdasarkan hasil penelitian dan pengujian, telah dikembangkan sistem pelaporan kerusakan jalan yang terdiri dari aplikasi mobile dan website admin. Aplikasi mobile dibangun menggunakan bahasa pemrograman Dart untuk antarmuka pengguna, sedangkan proses klasifikasi dan deteksi kerusakan dijalankan menggunakan Python dengan metode YOLOv8. Website admin dikembangkan menggunakan framework Laravel untuk memudahkan pengelolaan data laporan, sementara backend sistem menggunakan bahasa pemrograman Golang. Penerapan metode YOLOv8 terbukti mampu memberikan kinerja yang sangat baik dalam mengklasifikasikan kondisi jalan serta mendeteksi objek kerusakan secara real-time. Model yang digunakan berhasil mengenali empat kategori kondisi jalan (baik, sedang, rusak ringan, dan rusak berat) dengan akurasi sangat tinggi, serta mendeteksi berbagai jenis kerusakan spesifik seperti amblas, berlubang, retak panjang, retak buaya, dan retak pinggir. Hasil pengujian menunjukkan bahwa kondisi jalan baik dapat terklasifikasi dengan akurasi 99,96% tanpa adanya deteksi palsu. Kondisi jalan sedang berhasil diidentifikasi dengan akurasi 99,98% dan mampu mendeteksi kelas Bergelombang dengan tingkat kepastian 84%. Untuk kondisi jalan rusak ringan, klasifikasi mencapai 97,33% dengan deteksi pada kelas Lubang Kecil sebesar 70%. Sementara itu, kondisi jalan rusak berat dikenali dengan akurasi 100,00% serta mampu mendeteksi kombinasi Lubang Besar dan Lubang Kecil, dengan tingkat kepastian deteksi tertinggi mencapai 94% dan terendah 62%. Dengan capaian ini, sistem yang dikembangkan tidak hanya mempermudah masyarakat

dalam melaporkan kerusakan jalan melalui perangkat ponsel, tetapi juga membantu pemerintah, khususnya Dinas PUPR Kota Palangka Raya, dalam mengidentifikasi dan menangani kerusakan jalan secara cepat, tepat, dan terukur. Penerapan teknologi ini berpotensi meningkatkan efisiensi perencanaan perbaikan infrastruktur jalan serta memberikan kontribusi signifikan terhadap pemerataan pembangunan wilayah.

## 7. Referensi

- [1] O.: Silviana *et al.*, “PT. Media Akademik Publisher PENTINGNYA INFRASTRUKTUR JALAN BAGI AKSESIBILITAS EKONOMI DAN SOSIAL TERHADAP WARGA DESA SAMBONGREJO DAN DESA SENDANGAGUNG BOJONEGORO Wahjoe Poernomo Soeprapto 6,” *JMA*), vol. 2, no. 10, pp. 3031–5220, 2024, doi: 10.62281.
- [2] B. Sasmito, B. H. Setiadj, and R. Isnanto, “Deteksi Kerusakan Jalan Menggunakan Pengolahan Citra Deep Learning di Kota Semarang,” *TEKNIK*, vol. 44, no. 1, pp. 7–14, May 2023, doi: 10.14710/teknik.v44i1.51908.
- [3] Y. Yulianto and A. Wibowo, “DETEKSI KERETAKAN JALAN ASPAL MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK,” 2023.
- [4] A. Yolov8 *et al.*, “Analisa Kemampuan Algoritma YOLOv8 Dalam Deteksi Objek Manusia Dengan Metode Modifikasi Arsitektur,” 2023.
- [5] E. Wahyudinarti, P. A. Rachmatika, R. N. Ain, S. Informasi, G. Anyar, and K. Artificial, “MENINGKATKAN EFEKTIVITAS PEMBELAJARAN MAHASISWA DENGAN AI: TINJAUAN LITERATUR DI ERA DIGITAL,” vol. 9, no. 1, pp. 488–491, 2025.
- [6] S. Dewi, H. Ilyana, C. Hashim, and K. Tanujaya, “The Moderating Effect of Artificial Intelligence and ICT Adoption on Tax Evasion,” vol. 29, no. 01, pp. 88–106, 2025.
- [7] A. Raup, W. Ridwan, Y. Khoeriyah, Q. Yuliati Zaqiah, and U. Islam Negeri Sunan Gunung Djati Bandung, “Deep Learning dan Penerapannya dalam Pembelajaran.” [Online]. Available: <http://jiip.stkipyapisdmpu.ac.id>
- [8] Y. Nurhakiki, J., & Yahfizham, “Studi Kepustakaan: Pengenalan 4 Algoritma Pada Pembelajaran Deep Learning Beserta Implikasinya,” *Data Eng. Mach. Learn. Pipelines From Python Libr. to ML Pipelines Cloud Platforms*, no. 1, pp. 1–636, 2024.
- [9] M. Fathurahman and Hana Fauziah Hanum, “Analisa Realisasi Sistem Identifikasi Tingkat Kematangan Buah Tomat Ceri dengan Model YOLOv8 di BBPP Lembang,” *Spektral*, vol. 6, no. 1, pp. 311–316, 2025, doi: 10.32722/spektral.v6i1.7544.
- [10] M. Ibrahim and U. Latifa, “Penerapan Algoritma Yolov8 Dalam Deteksi Waktu Panen Tanaman Pakcoy Berbasis Website,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 7, no. 4, pp. 2489–2495, 2024, doi: 10.36040/jati.v7i4.7154.
- [11] Marlina Haiza, Elmayati, Zulus Antoni, and Wijaya Harma Oktafia Lingga, “Penerapan Algoritma Random Forest Dalam Klasifikasi Penjurusan Di SMA Negeri Tugumulyo,” *Penerapan Kecerdasan Buatan*, vol. 4, no. 2, pp. 138–143, 2023.
- [12] A. Putra Argadinata, D. Abdul Fatah, and H. Sukri, “Klasifikasi Kualitas Buah Apel Menggunakan Metode Random Forest,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 2, pp. 2016–2022, 2025, doi: 10.36040/jati.v9i2.12854.
- [13] D. Nafis Alfarizi, R. Agung Pangestu, D. Aditya, M. Adi Setiawan, and P. Rosyani, “Penggunaan Metode YOLO Pada Deteksi Objek: Sebuah Tinjauan Literatur Sistematis,” *J. Artif. Intel. dan Sist. Penunjang Keputusan*, vol. 1, no. 1, pp. 54–63, 2023, [Online]. Available: <https://jurnalmahasiswa.com/index.php/aidanspk>
- [14] N. A. Fadhlurrohman, A. Primajaya, A. N. Dimiyati, U. S. Karawang, T. Timur, and J. Barat, “ANALISIS SENTIMEN TERHADAP SKEMA STUDENT LOAN UNTUK BIAYA PERGURUAN TINGGI PADA TWITTER,” vol. 9, no. 2, pp. 2115–2123, 2025.
- [15] F. Paramudita and M. I. Zulfa, “Aplikasi Android Pendeteksi Kualitas Beras Berbasis Machine Learning Menggunakan Metode Convolutional Neural Network,” *J. Pendidik. dan Teknol. Indones.*, vol. 3, no. 7, pp. 297–305, Aug. 2023, doi: 10.52436/1.jpti.310.