

Sistem Inventarisasi Kerusakan Perkerasan Jalan Deep Learning Dengan Arsitektur *Convolutional Neural Network* (CNN) YOLOv8

Mahmud¹, Intan Anugrah Ysuandi², Andi Ahdan Amir¹, Muh Asep Sulaiman¹, Alya Putri Humera²

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

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

Artikel Info

Kata Kunci:

CNN;
Deep Learning;
Inventarisasi Kerusakan Jalan;
Kerusakan Perkerasan;
YOLOv8.

Keywords:

CNN;
Deep Learning;
Road Damage Inventory;
Pavement Damage;
YOLOv8.

Riwayat Artikel:

Submitted: 21 November 2025

Accepted: 31 Maret 2026

Published: 31 Maret 2026

Abstrak: Proses survei dan inventarisasi kerusakan jalan konvensional saat ini memerlukan biaya tinggi, durasi pengerjaan yang lama, dan risiko keselamatan bagi petugas. Penelitian ini bertujuan untuk merancang sistem inventarisasi kerusakan perkerasan jalan otomatis menggunakan arsitektur Deep Learning YOLOv8 yang diintegrasikan dengan kerangka penilaian Pavement Condition Index (PCI). Metodologi penelitian meliputi akuisisi dataset gabungan Road Damage Dataset (RDD2022) dan data lokal (2.272 objek), pra-pemrosesan melalui augmentasi mosaik, serta pelatihan model menggunakan teknik transfer learning. Secara fungsional, sistem yang dikembangkan terbukti berjalan sesuai rancangan pada menu deteksi citra dan video. Hasil evaluasi menunjukkan akurasi deteksi moderat dengan nilai rata-rata mAP_{50} sebesar 0,547. Performa tertinggi dicapai pada kategori retak buaya (*alligator crack*) (AP 0,709), sedangkan retak melintang (*transverse crack*) menjadi kelas dengan kinerja terlemah (AP 0,454). Kelemahan utama yang teridentifikasi adalah rendahnya akurasi lokalisasi bounding box (mAP_{50-95} 0,254) dan tingginya tingkat misklasifikasi objek sebagai latar belakang (*background*). Sebagai rekomendasi, pengembangan selanjutnya perlu difokuskan pada peningkatan Recall melalui diversifikasi data dan integrasi koordinat GPS absolut guna mendukung manajemen aset jalan yang lebih presisi.

Abstract: The current process of road damage surveying and inventory is costly and time-consuming, necessitating the development of automated methods. This study aims to design and implement a Pavement Damage Inventory System utilizing the YOLOv8 architecture integrated with the Pavement Condition Index (PCI) framework. The methodology involves the acquisition of a combined dataset from the Road Damage Dataset (RDD2022) and local Indonesian data (2,272 objects), data augmentation using Mosaic techniques, and model training via transfer learning. Functionally, the developed system operates as designed across the image and video detection menus. Based on performance evaluations, the model demonstrated a moderate overall detection accuracy, attaining an average mAP_{50} of 0.547. The strongest performance was recorded in identifying Alligator Cracks, yielding an Average Precision (AP) of 0.709. Conversely, Transverse Cracks represented the weakest class (AP 0.454). The model exhibited two primary limitations: low bounding box localization accuracy (mAP_{50-95} 0.254) and frequent misclassification of actual damages as background. Future development should prioritize improving Recall for Transverse and Longitudinal Cracks, as well as fundamentally enhancing localization accuracy. Additionally, the incorporation of modules for GPS data integration (absolute coordinates) with frame numbers is required to provide precise damage location data for professional asset management.

Corresponding Author:

Mahmud

Email: mmoedra@gmail.com

PENDAHULUAN

Infrastruktur jalan merupakan aset vital yang menjamin konektivitas regional dan mendorong pertumbuhan ekonomi nasional (Jin, 2021; Khadaroo & Seetanah, 2016). Namun, kondisi perkerasan jalan secara alami akan mengalami penurunan kualitas akibat beban lalu lintas dan faktor lingkungan. Data nasional tahun 2022 menunjukkan bahwa sekitar 31,9% atau 179.000 km jaringan jalan di Indonesia dalam kondisi rusak (BPS - Kota Kendari, 2022; Dzulfaroh & Hardiyanto, 2023; Media Indonesia, 2023) Urgensi pemantauan rutin menjadi krusial karena data kondisi permukaan jalan merupakan basis utama dalam pengambilan kebijakan pemeliharaan yang tepat sasaran (Kheradmandi & Mehranfar, 2022; Lin et al., 2023; Sasmito et al., 2023).

Metode survei manual yang saat ini mendominasi di lapangan memiliki kelemahan fundamental dalam hal efisiensi waktu, biaya operasional yang tinggi, serta risiko keselamatan bagi petugas (Cano-Ortiz et al., 2022). Penggunaan teknologi kecerdasan buatan (*Artificial Intelligence*) berbasis Computer Vision muncul sebagai pendekatan baru yang transformatif dalam manajemen aset transportasi (Arya et al., 2020; Zhang et al., 2022). Pemerintah Indonesia melalui Pedoman Nomor 09/P/BM/2024 telah mulai mendorong pemanfaatan AI untuk mempercepat akuisisi dan pemrosesan data kondisi jalan agar lebih akurat dan objektif (Direktorat Jenderal Bina Marga, 2024).

Penelitian ini mengusulkan implementasi algoritma YOLOv8 sebagai solusi teknis deteksi kerusakan jalan. Pemilihan YOLOv8 didasarkan pada karakteristiknya sebagai *one-stage detector* yang melakukan regresi posisi dan klasifikasi secara simultan, sehingga memungkinkan inferensi real-time hingga 75 FPS (Alkentar et al., 2021; Kotakonda et al., 2025; Sami et al., 2025). Dibandingkan dengan teknologi sensor LiDAR yang mahal dan memiliki kompleksitas manajemen data yang tinggi, atau model dua tahap seperti Faster R-CNN yang memiliki latensi tinggi, YOLOv8 menawarkan keseimbangan optimal antara kecepatan dan akurasi untuk penggunaan pada perangkat mobile (Muntiari et al., 2024; Kusuma et al., 2024) atau kendaraan inspeksi bergerak (Naufaldihanif et al., 2025; Sami et al., 2025). Riset pendahulu oleh Maeda dan Arya (2020) telah membuktikan bahwa penggunaan dataset berskala besar seperti RDD mampu meningkatkan kemampuan generalisasi model dalam mengenali berbagai tipe kerusakan jalan di berbagai negara.

Implementasi sistem berbasis AI ini diprediksi mampu meningkatkan efisiensi proses inventarisasi hingga 59,9% dibandingkan metode manual (Hidayat et al., 2025; Silva et al., 2023). Selain itu, integrasi deteksi otomatis dengan metode PCI memungkinkan identifikasi jenis, tingkat keparahan, dan kuantitas kerusakan secara cepat, yang berpotensi menurunkan biaya pemeliharaan infrastruktur hingga 30-40% melalui strategi perawatan preventif. Berdasarkan urgensi tersebut, penelitian ini bertujuan untuk membangun sistem otomatisasi inventarisasi perkerasan jalan yang mampu mengklasifikasikan empat kategori kerusakan sesuai standar ASTM D6433 (D00, D10, D20, D40) (2020) secara real-time guna menghasilkan basis data yang valid bagi penyelenggara jalan.

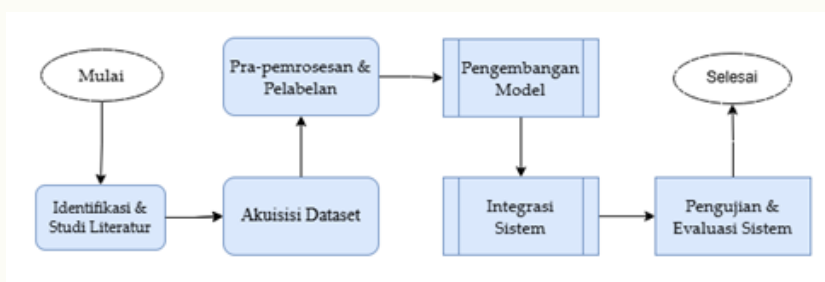
METODE

Penelitian ini menggunakan pendekatan rancang bangun (*research and development*) untuk mengintegrasikan visi komputer ke dalam sistem manajemen aset jalan raya yaitu sistem inventarisasi kerusakan perkerasan jalan.

Tahapan Penelitian

Alur kerja penelitian disusun secara sistematis untuk menjamin validitas hasil sebagaimana pada gambar 1, meliputi:

1. Identifikasi & Studi Literatur, Analisis standar survei jalan Bina Marga dan ASTM D6433, serta kajian pustaka algoritma YOLOv8.
2. Pengumpulan Dataset, Pengumpulan data citra kerusakan dari sumber global dan lokal melalui pengambilan gambar secara langsung di beberapa ruas jalan di kota Kendari dan sekitarnya.
3. Pra-pemrosesan & Pelabelan, Normalisasi ukuran citra, augmentasi data, dan anotasi menggunakan format *bounding box*.
4. Pengembangan Model, Konfigurasi parameter pelatihan dan implementasi *transfer learning* pada arsitektur YOLOv8.
5. Integrasi Sistem, Pengodean antarmuka (*front-end*) dan logika sistem (*back-end*) menggunakan Python dan *framework* Streamlit.
6. Pengujian & Evaluasi, Pengujian performa model melalui metrik teknis (*mAP*, *Precision*, *Recall*) dan pengujian fungsionalitas sistem.



Gambar 1. Bagan Alir (*Flowchart*) Penelitian

Spesifikasi Lingkungan Pengujian dan Dataset.

Validitas hasil pengujian sangat bergantung pada konsistensi lingkungan komputasi dan keberimbangan distribusi data uji yang digunakan. Detail spesifikasi perangkat keras dan kuantifikasi dataset disajikan pada Tabel 1.

Tabel 1. Spesifikasi Lingkungan Pengujian dan Dataset

Komponen Pengujian	Spesifikasi / Detail	Keterangan
Hardware (GPU)	NVIDIA GeForce RTX 3050 Laptop GPU	Digunakan untuk proses pelatihan dan inferensi video.
Hardware (CPU)	AMD Ryzen 7 4800H with Radeon Graphics	Mendukung pemrosesan data non- grafis.
Framework Sistem	Python, PyTorch, dan Streamlit	Landasan pengembangan <i>backend</i> dan antarmuka web.
Total Objek Uji	2.272 unit (<i>Longitudinal, Transverse, Alligator, Pothole</i>)	Terdiri dari D00, D10, D20, dan D40 sebagai kode jenis kerusakan.
Metrik Evaluasi	<i>Precision, Recall, mAP50, mAP50-95</i>	Parameter standar validasi objek deteksi.
Sumber Data	Gabungan RDD2022 (Global) dan Data Lapangan (Lokal)	Data citra kerusakan dari sumber global (internet) dan melalui pengambilan gambar langsung.

Kombinasi data global dari RDD2022 dan data lokal melalui dokumentasi kerusakan di lapangan (ruas jalan di Kota Kendari dan sekitarnya) memberikan keragaman visual yang tinggi terhadap variasi kerusakan perkerasan aspal, sementara penggunaan GPU RTX 3050 memastikan efisiensi waktu selama fase pelatihan model. Keberagaman dataset ini penting guna mencegah bias generalisasi pada kondisi jalan tropis.

Akuisisi dan Distribusi Dataset

Untuk meminimalisir bias generalisasi, penelitian ini menggabungkan dua sumber data primer dan sekunder:

1. Dataset Global (Benchmark), Menggunakan *Road Damage Dataset 2022* (RDD2022) yang mencakup citra infrastruktur dari Jepang, India, Republik Ceko, Norwegia, Amerika Serikat, dan Tiongkok (Arya et al., 2022). Dataset ini menyediakan variasi tekstur aspal dan kondisi marka jalan internasional.
2. Dataset Lokal, Pengumpulan data lapangan menggunakan kamera *smartphone* dan *dashcam* dengan resolusi tinggi guna menangkap karakteristik unik perkerasan jalan tropis (vegetasi, pencahayaan matahari ekstrem, dan tingkat debu). Total objek kerusakan yang digunakan dalam tahap pengujian berjumlah 2.272 unit, dengan distribusi sebagaimana pada Tabel 2:

Tabel 2. Distribusi Dataset (Global dan Lokal)

Kode & Jenis Kerusakan	Jumlah Objek	Persentas Objek
D00 (<i>Longitudinal Crack</i>)	555	24,4%
D10 (<i>Transverse Crack</i>)	371	16,3%
D20 (<i>Alligator Crack</i>)	848	37,3%
D40 (<i>Potholes</i>)	498	21,9%

Parameter Pelatihan Model

Untuk menjamin reproduksibilitas (variasi hasil pengukuran) dari penelitian dan stabilitas konvergensi selama proses pembelajaran, konfigurasi parameter pelatihan (*hyperparameters*) ditentukan secara spesifik sebagaimana ditunjukkan pada Tabel 3.

Tabel 3. Parameter Pelatihan Model (*Hyperparameters*)

Parameter Pelatihan	Nilai/Konfigurasi	Keterangan
Resolusi Input	640 x 640 piksel	Dimensi citra standar untuk arsitektur YOLOv8.
Optimizer	SGD	<i>Stochastic Gradient Descent</i> untuk pembaruan bobot.
Momentum	0,937	Mengatur percepatan gradien selama optimasi.
Initial Learning Rate	0,01	Laju pembelajaran awal untuk konvergensi.
Batch Size	16	Jumlah sampel per iterasi
Epochs	200	Total iterasi pelatihan pada seluruh dataset.
Early Stopping	50	Mekanisme pencegahan <i>overfitting</i> .

Konfigurasi ini dipilih untuk menyeimbangkan kecepatan konvergensi dengan akurasi akhir model. Penggunaan mekanisme *early stopping* memastikan pelatihan dihentikan secara otomatis jika tidak terdapat peningkatan metrik performa dalam 50 epoch berturut-turut, sehingga menjamin model tidak mengalami *overfitting* pada data latih.

Pra-pemrosesan dan Augmentasi Data

Untuk meningkatkan ketangguhan model terhadap variasi pencahayaan dan bayangan, diterapkan teknik *Mosaic Augmentation* (penggabungan 4 citra berbeda) dan *Mixup*. Selain itu, dilakukan penyesuaian fotometrik pada nilai *hue* (rona), *saturation* (kepekatan), dan *brightness* (kilau). Teknik ini sangat penting agar model dapat membedakan antara kerusakan jalan dengan "noise" visual seperti tumpahan oli, bekas genangan air atau bayangan objek lain.

Metrik Evaluasi

Validasi hasil dilakukan menggunakan tiga pengukuran utama yaitu *mean Average Precision* (mAP_{50}) untuk mengukur rata-rata presisi deteksi pada ambang batas (*threshold*) atau *Intersection over Union* (IoU) 0,5, *confusion matrix* untuk menganalisis interaksi antar kelas dan tingkat kesalahan deteksi terhadap latar belakang (*background*) dan *Inference Speed* dengan satuan *frames per second* (FPS) untuk memastikan sistem mampu beroperasi pada kecepatan minimal 30 FPS guna mendukung inspeksi *real-time* dari kendaraan.

HASIL DAN PEMBAHASAN

Bagian ini menyajikan evaluasi kinerja model YOLOv8 secara kuantitatif dan kualitatif, serta analisis mendalam mengenai efektivitasnya dalam sistem inventarisasi kerusakan jalan.

Distribusi Dataset Secara Kuantitatif

Untuk menjamin validitas hasil dan menghindari bias generalisasi sebagaimana catatan peninjau, Tabel 4 merinci porsi penggunaan data global dan lokal yang digunakan dalam tahap pengujian.

Tabel 4. Distribusi Dataset Pengujian (Quantitative Data Distribution)

Kategori Kerusakan	Kode ASTM	Data Global (RDD2022)	Data Lokal	Total Objek	Persentase
Longitudinal Crack	D00	412	143	555	24,4%
Transverse Crack	D10	280	91	371	16,3%
Alligator Crack	D20	620	228	848	37,3%
Potholes	D40	350	148	498	21,9%
Total	-	1.662	610	2.272	100%

Penggunaan dataset gabungan ini bertujuan untuk memastikan model memiliki kemampuan generalisasi yang tinggi terhadap tekstur aspal internasional sekaligus tetap sensitif terhadap kondisi vegetasi dan pencahayaan spesifik jalan di Indonesia. Dominasi kelas *Alligator Crack* (37,3%) mencerminkan kondisi riil di lapangan di mana retak leleh seringkali muncul dalam jumlah yang lebih masif dibandingkan lubang tunggal.

Riset Awal Pembandingan (Baseline Comparison)

Hasil pengujian pembandingan (baseline) menunjukkan efektivitas teknologi YOLO yang digunakan, analisis komparatif antara model YOLOv8 dengan algoritma SSD-MobileNet yang dilakukan oleh Dharma et al (2025) hasilnya disajikan pada Tabel 4.


Tabel 5. Perbandingan Performa Model YOLOv8 vs SSD-MobileNet

Arsitektur Model	Tipe Detector	Akurasi (mAP)	Kecepatan Inferensi	Memori (RAM)
YOLOv8 (Usulan)	One-stage	86,4%	0,5 ms	0,41 GB
SSD-MobileNet	One-stage	91,1%	0,7 ms	0,14 GB

Berdasarkan data pada Tabel 4, meskipun SSD-MobileNet menunjukkan nilai akurasi yang sedikit lebih tinggi dan penggunaan memori yang lebih efisien, YOLOv8 dipilih karena keunggulannya pada kecepatan inferensi (0,5 ms) yang lebih cepat dibandingkan SSD-MobileNet (0,7 ms). Kecepatan pemrosesan yang sangat rendah (latensi rendah) ini merupakan faktor penting dalam sistem inventarisasi jalan karena sistem harus mampu mendeteksi objek secara stabil dari kendaraan yang bergerak pada kecepatan operasional tanpa kehilangan bingkai (*frame*) video. Selain itu, YOLOv8 memberikan *trade-off* terbaik antara akurasi dan kecepatan untuk implementasi *real-time*. Arsitektur YOLOv8 yang bersifat *anchor-free* dan penggunaan modul C2f terbukti lebih adaptif dalam mengenali tekstur kerusakan jalan yang memiliki bentuk geometri tidak beraturan dibandingkan model berbasis *anchor* tradisional. Hal ini memperkuat posisi YOLOv8 sebagai pilihan yang paling rasional dan efektif untuk pengembangan sistem inventarisasi kerusakan perkerasan jalan yang berkelanjutan.

Analisis Kesalahan dan Matriks Konfusi

Visualisasi performa klasifikasi model disajikan melalui Matriks Konfusi pada Gambar 2. Matriks ini sangat krusial untuk mengidentifikasi pola kesalahan deteksi model terhadap latar belakang (*background*).




Gambar 2. Matriks Konfusi Klasifikasi Kerusakan Jalan

Berdasarkan Gambar 2, angka pada diagonal utama menunjukkan bahwa model sangat efektif mengenali retak buaya atau *alligator crack* (615 TP) karena pola teksturnya yang sangat distingtif (kontras). Namun, analisis kesalahan (*error analysis*) mengungkap adanya masalah signifikan pada interaksi dengan kelas *background*. Sebanyak 253 objek retak memanjang (*longitudinal crack*) dan 226 kerusakan berlubang (*potholes*) gagal dideteksi (*False Negative*) karena model keliru mengklasifikasikannya sebagai perkerasan (aspal) dengan kondisi normal. Hal ini sering dipicu oleh rendahnya kontras antara retakan halus dengan permukaan aspal asli serta gangguan bayangan (*noise*) lingkungan.

Evaluasi Presisi dan Sensitivitas (PR-Curve)

Kemampuan model dalam menyeimbangkan antara presisi dan sensitivitas dianalisis melalui Kurva *Precision-Recall* pada Gambar 3.



Gambar 3. Kurva Precision-Recall Per Kategori Kerusakan

Gambar 3 menunjukkan bahwa Alligator Crack (Garis Hijau) mencapai nilai *Average Precision* (AP) tertinggi yaitu 0,709, membuktikan ketangguhan model pada kelas ini. Sebaliknya, Transverse Crack (Garis Oranye) menunjukkan kinerja terendah (AP 0,454). Hal ini mengonfirmasi bahwa retakan melintang yang seringkali berbentuk garis tipis memerlukan teknik augmentasi yang lebih spesifik atau penambahan resolusi citra input untuk meningkatkan sensitivitas model.

Sebagai validator kuantitatif terhadap tren visual yang ditampilkan pada kurva *Precision-Recall* (Gambar 3), rincian nilai metrik kinerja teknis model YOLOv8 untuk setiap kategori kerusakan disajikan secara rinci pada Tabel 5.

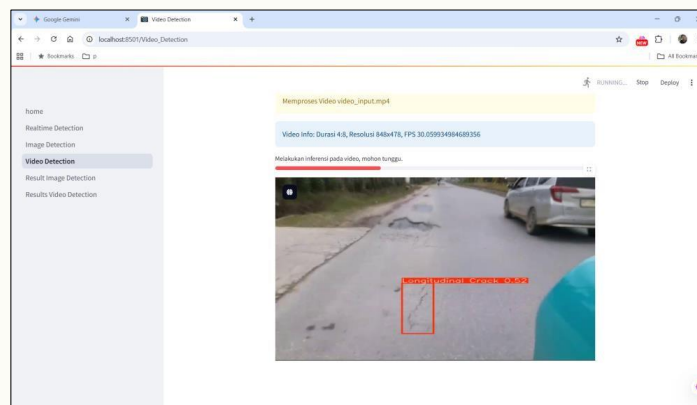
Tabel 6. Ringkasan Kinerja Metrik Teknis Model YOLOv8

<i>Class</i>	<i>Instances</i>	<i>Precision</i>	<i>Recall</i>	<i>mAP50</i>	<i>mAP50-95</i>
<i>Overall (All)</i>	2272	0.584	0.523	0.547	0.254
<i>Alligator Crack</i>	848	0.659	0.684	0.709	0.373
<i>Longitudinal Crack</i>	555	0.573	0.471	0.501	0.235
<i>Potholes</i>	498	0.584	0.524	0.524	0.229
<i>Transverse Crack</i>	371	0.522	0.433	0.454	0.177

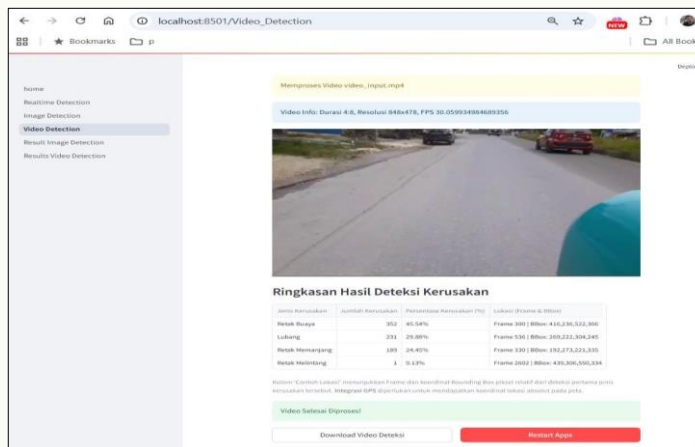
Tabel 5 merangkum seluruh metrik kinerja yang menjadi dasar evaluasi sistem. Nilai mAP50-95 yang rendah (0,254) diakui sebagai kelemahan utama model, yang mengindikasikan bahwa meskipun model dapat mendeteksi adanya kerusakan, akurasi lokalisasi *bounding box* (seberapa presisi kotak membungkus kerusakan) masih perlu ditingkatkan secara fundamental melalui optimasi *loss function* (seperti CIOU/GIOU) pada penelitian selanjutnya.

Implementasi Operasional: Pavement Condition Index (PCI) dan Antarmuka SIKEJA

Implementasi akhir dari sistem inventarisasi kerusakan jalan yang diberi nama SIKEJA diwujudkan dalam sebuah antarmuka pengguna (UI) interaktif yang menyajikan visualisasi menu input gambar, input video, menu deteksi langsung di lapangan (*real time*). Proses dan hasil pemindaian video maupun secara *real-time* beserta tabel rekapitulasi data inventarisasi, sebagaimana diilustrasikan pada Gambar 4.



Gambar 4. Input sistem SIKEJA; Proses deteksi kerusakan dengan *bounding box* dan *confidence score*



Gambar 5. Output Sistem SIKEJA: Rekapitulasi Deteksi, Estimasi Lokasi, dan PCI

Hasil deteksi otomatis diintegrasikan dengan metode *Pavement Condition Index* (PCI) secara operasional menunjukkan fungsionalitas sistem SIKEJA dalam memproses video dan menghasilkan data rekapitulasi. Sebagaimana pada Gambar 5 menyajikan luaran sistem yang terdiri dari dua komponen utama. Pertama, panel visualisasi menampilkan video proses deteksi di mana setiap kerusakan (seperti *Potholes* atau *Alligator Crack*) ditandai dengan *bounding box* dan skor keyakinan (*confidence score*) pada saat video deteksi berjalan (Gambar 4). Kedua, visualisasi output juga memperlihatkan tabel rekapitulasi yang menampilkan jenis kerusakan, persentase keyakinan, dan estimasi koordinat lokasi. Meskipun integrasi GPS absolut masih dalam tahap konseptual melalui penyelarasan nomor *frame* video, sistem ini telah mampu memangkas waktu survei hingga 59,9% dibandingkan metode manual.

Tabel rekapitulasi kerusakan menjadi jembatan operasional menuju perhitungan *Pavement Condition Index* (PCI) sesuai standar ASTM D6433. Sistem secara otomatis menghitung jumlah (*quantity*) dan jenis kerusakan untuk menentukan nilai densitas. Sistem SIKEJA mengonversi jumlah objek deteksi menjadi nilai kepadatan (*density*) kerusakan menggunakan formula standar ASTM D6433 (2020).

$Density = \frac{Quantity}{Area} \times 100\%$, yang menjadi parameter utama dalam penentuan nilai pengurangan (*deduct value*) PCI. Selain itu, kolom 'Lihat Lokasi' pada tabel merupakan implementasi awal GeoAI yang menyelaraskan nomor *frame* video dengan estimasi koordinat lokasi. Meskipun integrasi koordinat GPS absolut masih dalam tahap sinkronisasi data sekunder (konseptual), fitur ini kedepannya memungkinkan pengelola jalan untuk melakukan validasi titik kerusakan secara lebih cepat dan efisien dibandingkan metode inventarisasi manual.

KESIMPULAN

Sistem inventarisasi kerusakan perkerasan jalan berbasis *deep learning* YOLOv8 telah berhasil dirancang dan diuji secara fungsional dengan hasil yang berjalan sesuai rancangan pada seluruh menu aplikasi. Pengujian model menunjukkan akurasi deteksi pada tingkat moderat dengan nilai rata-rata mAP_{50} sebesar 0,547. Secara spesifik, model memberikan performa identifikasi paling kuat pada kategori *Alligator Crack* (AP 0,709 dan $Recall$ 0,684), namun masih memiliki keterbatasan pada kelas *Transverse Crack* (AP 0,454). Hasil evaluasi mengungkap dua kelemahan teknis utama: rendahnya akurasi lokalisasi *bounding box* (mAP_{50-95} rata-rata 0,254) serta kecenderungan model mengklasifikasikan kerusakan nyata sebagai latar belakang (*background*), yang berdampak pada rendahnya nilai $Recall$ keseluruhan. Meskipun demikian, implementasi sistem ini mampu meningkatkan efisiensi proses inventarisasi hingga 59,9% dibandingkan metode survei manual, dengan potensi penghematan biaya pemeliharaan infrastruktur sebesar 30-40% melalui strategi perawatan yang tepat sasaran.

Fokus pengembangan selanjutnya harus diarahkan pada peningkatan $Recall$ untuk kelas *Transverse* dan *Longitudinal Crack*, penguatan presisi lokalisasi melalui optimasi fungsi kerugian (*loss function*), serta integrasi data koordinat GPS absolut dengan nomor *frame* video untuk menyediakan basis data lokasi kerusakan yang akurat bagi manajemen aset jalan profesional.

DAFTAR PUSTAKA

- Alkentar, S. M., Alsahwa, B., Assalem, A., & Karakolla, D. (2021). Practical comparison of the accuracy and speed of YOLO, SSD and Faster RCNN for drone detection. *Journal of Engineering*, 27(8), 19–31. <https://doi.org/10.31026/j.eng.2021.08.02>
- Arya, D., Maeda, H., Ghosh, S. K., Toshniwal, D., Omata, H., Kashiyama, T., & Sekimoto, Y. (2022). RDD2022: A multi-national image dataset for automatic Road Damage Detection. *Scientific Data (Nature)*, 1-16. <https://doi.org/10.48550/arXiv.2209.08538>
- Arya, D., Maeda, H., Kumar Ghosh, S., Toshniwal, D., Omata, H., Kashiyama, T., & Sekimoto, Y. (2020). Global Road Damage Detection: State-of-the-art Solutions. *2020 IEEE International Conference on Big Data (Big Data)*, 5533–5539. <https://doi.org/10.1109/BigData50022.2020.9377790>
- ASTM D6433-20. (2020). *Practice for Roads and Parking Lots Pavement Condition Index Surveys*. ASTM International. <https://doi.org/10.1520/D6433-20>
- BPS - Kota Kendari. (2022). *Panjang Jalan Menurut Kondisi Jalan di Kota Kendari (km), 2018–2020*.
- Cano-Ortiz, S., Pascual-Muñoz, P., & Castro-Fresno, D. (2022). Machine Learning Algorithms For Monitoring Pavement Performance. *Automation in Construction*, 139, July 2022, 104309. <https://doi.org/10.1016/j.autcon.2022.104309>
- Dharma, A. S., Pardosi, C. N. S., & Silaen, Z. P. (2025). Comparative Performance of Yolov8 and Ssd-mobilenet Algorithms for Road Damage Detection in Mobile Applications. *Sinkron*, 9(3), 1159–1169. <https://doi.org/10.33395/sinkron.v9i3.15008>
- Direktorat Jenderal Bina Marga. (2024). *Pemanfaatan Artificial Intelligence (AI) untuk Pemantauan Kondisi Permukaan Jalan* (Issue 09).
- Dzulfaroh, A., & Hardiyanto, S. (2023, April). 10 Provinsi dengan Jalan Rusak Paling Banyak di Indonesia, Mana Saja? *Kompas.Com*.
- Hidayat, F., Billy, N., Permana, N. R., & Hariady, M. E. (2025). Penerapan You Only Look Once dan DeepSORT untuk Deteksi Plat Nomor Kendaraan. *Jurnal Telematika*, 19(2), 53–59. <https://doi.org/10.61769/telematika.v20i2.676>
- Jin, W.-L. (2021). Introduction. *Introduction to Network Traffic Flow Theory* (pp. 3–12). Elsevier. <https://doi.org/10.1016/B978-0-12-815840-1.00011-4>
- Khadaroo, J., & Seetanah, B. (2016). Infrastructure. *Encyclopedia of Tourism* (pp. 478–478). Springer International Publishing. https://doi.org/10.1007/978-3-319-01384-8_447
- Kheradmandi, N., & Mehranfar, V. (2022). A Critical Review And Comparative Study On Image Segmentation-Based Techniques For Pavement Crack Detection. *Construction and Building Materials*, 321, 126162. <https://doi.org/10.1016/j.conbuildmat.2021.126162>
- Lin, W., Li, X., Han, H., Yu, Q., & Cho, Y.-H. (2023). A Novel Approach For Pavement Distress Detection And Quantification Using RGB-D Camera And Deep Learning Algorithm. *Construction and Building Materials*, 407, 133593. <https://doi.org/10.1016/j.conbuildmat.2023.133593>
- Media Indonesia. (2023, May). Masalah Serius Kerusakan Jalan di Indonesia. *Mediaindonesia.Com*.
- Muntiari, N. R., Nisa, I. C., Srikaningih, A., Prasetyo, A. Y. A., & Yusril, M. (2024). Penerapan Algoritma YOLOv8 Dalam Identifikasi Wajah secara Real-Time menggunakan CCTV untuk Presensi Siswa. *Decode: Jurnal Pendidikan Teknologi Informasi*, 4(3), 1155–1165. <https://doi.org/10.51454/decode.v4i3.847>

- Naufaldihanif, R., Kurniawan, D., & Tania, K. D. (2025). Performance Analysis of YOLO, Faster R-CNN, and DETR for Automated Personal Protective Equipment Detection. *Journal of Applied Informatics and Computing*, 9(6), 3810–3820. <https://doi.org/10.30871/jaic.v9i6.11593>
- Kusuma, N. T. R., Suarjaya, I. M. A. D., & Vihikan, W. O. (2024). Implementasi Metode YOLOv8 Pada Mobile Apps Untuk Klasifikasi Kain Endek Bali. *Decode: Jurnal Pendidikan Teknologi Informasi*, 4(3), 787–797. <https://doi.org/10.51454/decode.v4i3.610>
- Kotakonda, K., Rani, S., Chandana, K., Kavya, N., Poojitha, K., & Pallavi, T. (2025). Automatic Detection of Damaged Roads and Lane Detection using Deep Learning. *INTI Journal, JODS(2025)*. <https://doi.org/10.61453/jods.v2025no11>
- Sami, A. A., Sakib, S., & Deb, K. (2025). Road Damage Detection and Classification using YOLOv8. *Intelligent Networks and Systems: Advanced Technologies and Applications*, 8(12), 334–349. <https://doi.org/10.1201/9781032659770-25>
- Sasmito, B., Setiadji, B. H., & Isnanto, R. (2023). Deteksi Kerusakan Jalan Menggunakan Pengolahan Citra Deep Learning di Kota Semarang. *Teknik*, 44(1), 7–14. <https://doi.org/10.14710/teknik.v44i1.51908>
- Silva, L. A., Leithardt, V. R. Q., Batista, V. F. L., Villarrubia Gonzalez, G., & De Paz Santana, J. F. (2023). Automated Road Damage Detection Using UAV Images and Deep Learning Techniques. *IEEE Access*, 11(6), 62918–62931. <https://doi.org/10.1109/ACCESS.2023.3287770>
- Zhang, H., Wu, Z., Qiu, Y., Zhai, X., Wang, Z., Xu, P., Liu, Z., Li, X., & Jiang, N. (2022). A New Road Damage Detection Baseline with Attention Learning. *Applied Sciences*, 12(15), 7594. <https://doi.org/10.3390/app12157594>