

YOLOV11 APPLICATION IN WEB-BASED ROAD DAMAGE REPORTING SYSTEM

APLIKASI YOLOV11 PADA SISTEM PELAPORAN KERUSAKAN JALAN BERBASIS WEB

Arya Maulana Suryakartadireja^{1‡}, Arie Qur'ania², and Yusma Yanti³

^{1,2,3}Department of Computer Science, Universitas Pakuan, Indonesia

[‡]corresponding author: 065122081@student.unpak.ac.id

Copyright © 2026 Arya Maulana Suryakartadireja, Arie Qur'ania, and Yusma Yanti. This is an open-access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Abstract

Road damage remains a significant infrastructure issue in Indonesia, while existing reporting systems are still largely conventional and lack integration with automated monitoring technologies. This study implements the YOLOv11n deep learning model for automatic road damage detection from digital images integrated into a web-based reporting system. The system focuses on three categories of road damage: pothole, linear crack, and alligator crack. A dataset of 3,768 images with 6,947 bounding box annotations was used and divided into training, validation, and testing sets. The YOLOv11n model was trained for 200 epochs using the AdamW optimizer with an input size of 640×640 pixels. Detection results were processed using a rule-based Road Damage Score (RDS) approach to determine repair priority levels. The developed system supports real-time community reporting through GPS-based web monitoring integrated with automatic object detection. Experimental results showed overall precision, recall, mAP50, and F1-score values of 0.6753, 0.6169, 0.6374, and 0.6448, respectively. The pothole class achieved the best performance with an mAP50 of 0.8323, while linear crack obtained the lowest score at 0.5031. The results indicate that integrating YOLOv11n with a web-based reporting system can support more efficient and data-driven road infrastructure monitoring.

Keywords: Deep Learning, Road Damage Detection, Road Damage Score, Web Monitoring System, YOLOv11.

Abstrak

Kerusakan jalan masih menjadi permasalahan infrastruktur yang signifikan di Indonesia, sementara sistem pelaporan yang tersedia umumnya masih bersifat konvensional dan belum terintegrasi dengan teknologi monitoring otomatis. Penelitian ini menerapkan model *deep learning* YOLOv11n untuk mendeteksi kerusakan jalan secara otomatis dari citra digital yang diintegrasikan ke dalam sistem pelaporan berbasis *web*. Penelitian berfokus pada tiga kategori kerusakan jalan, yaitu *pothole*, *linear crack*, dan *alligator crack*. *Dataset* yang digunakan terdiri dari 3.768 citra dengan 6.947 anotasi *bounding box* yang dibagi ke dalam data *training*, *validation*, dan *testing*. Model YOLOv11n dilatih selama 200 epoch menggunakan *optimizer* AdamW dengan ukuran input 640×640 piksel. Hasil deteksi diolah menggunakan pendekatan *Road Damage Score* (RDS) berbasis aturan untuk menentukan prioritas penanganan kerusakan jalan. Sistem yang dikembangkan mendukung pelaporan kerusakan jalan secara *real-time* melalui platform *web* berbasis GPS yang terintegrasi dengan deteksi objek otomatis. Hasil pengujian menunjukkan nilai *precision* sebesar 0,6753, *recall* sebesar 0,6169, mAP50 sebesar 0,6374, dan F1-score sebesar 0,6448. Kelas *pothole* menghasilkan performa terbaik dengan mAP50 sebesar 0,8323, sedangkan *linear crack* memperoleh performa terendah sebesar 0,5031. Hasil penelitian menunjukkan bahwa integrasi YOLOv11n dengan sistem pelaporan berbasis *web* mampu mendukung monitoring kondisi jalan yang lebih efisien dan berbasis data.

Kata Kunci: *Deep Learning*, Deteksi Kerusakan Jalan, *Road Damage Score*, Sistem Monitoring Web, YOLOv11.

1. Pendahuluan

Infrastruktur jalan merupakan komponen kritis yang menopang mobilitas masyarakat dan pertumbuhan ekonomi nasional (Agustin *et al.*, 2025). Namun, kondisi jalan yang rusak, seperti jalan berlubang dan tidak rata, dapat meningkatkan risiko kecelakaan lalu lintas (Ariani *et al.*, 2019). Bentuk kerusakan jalan yang umum dijumpai meliputi *pothole*, *linear crack*, dan *alligator crack* yang dapat menurunkan kualitas pelayanan jalan. Data Badan Pusat Statistik (2025) mencatat 150.906 kasus kecelakaan lalu lintas di Indonesia pada tahun 2024 dengan 26.839 korban meninggal dunia. Kondisi tersebut menunjukkan pentingnya pemantauan dan penanganan kerusakan jalan secara efektif. Namun, pelaporan dan pengelolaan data kerusakan jalan masih menghadapi kendala berupa pencatatan yang belum terpusat, pemantauan yang kurang optimal, serta sistem pelaporan yang belum terstruktur sehingga menghambat proses dokumentasi dan penanganan kerusakan jalan (Ardita *et al.*, 2026; Azza *et al.*, 2025).

Perkembangan teknologi *deep learning* dalam bidang *computer vision*

membuka peluang untuk mendeteksi kerusakan jalan secara otomatis melalui analisis citra digital (Sasmito *et al.*, 2023). Salah satu algoritma yang banyak digunakan adalah *You Only Look Once* (YOLO), yang mampu melakukan deteksi objek secara *real-time* dengan kecepatan dan akurasi yang tinggi (Surahmanto *et al.*, 2024). Namun, YOLO masih menghadapi tantangan dalam mendeteksi objek berukuran kecil atau memiliki karakteristik visual yang kompleks, seperti retakan jalan yang tipis dan memanjang (Ma *et al.*, 2025). Untuk mengatasinya, YOLOv11 menawarkan peningkatan kecepatan dan akurasi deteksi sehingga lebih efektif untuk mendukung proses deteksi objek secara *real-time* (Ismail & Rahmadewi, 2025).

Beberapa penelitian telah menerapkan *deep learning* dan YOLO untuk mendeteksi kerusakan jalan secara otomatis (Sasmito *et al.*, 2023; Surahmanto *et al.*, 2024). Selain itu, teknologi deteksi kerusakan jalan berbasis kecerdasan artifisial juga telah mulai diterapkan untuk mendukung identifikasi kerusakan jalan (Direktorat Jenderal Bina Marga, 2024). Di sisi lain, berbagai penelitian telah mengembangkan sistem pelaporan kerusakan infrastruktur berbasis web yang membantu masyarakat menyampaikan laporan secara terstruktur dan terdokumentasi (Nuha & Yulianto, 2026). Berangkat dari perkembangan tersebut, penelitian ini mengusulkan pengembangan sistem yang mengintegrasikan deteksi kerusakan jalan secara otomatis dengan mekanisme pelaporan berbasis web guna mendukung proses pelaporan, pemantauan, dan pengelolaan informasi kerusakan jalan secara lebih efektif.

Selain itu, kurangnya sistem informasi yang terintegrasi mengenai kondisi jalan dapat menghambat proses identifikasi dan penanganan kerusakan jalan (Hamzah *et al.*, 2025). Penelitian oleh Urbiztondo *et al.*, (2025) menunjukkan bahwa platform monitoring berbasis *web* yang terintegrasi dengan *Artificial Intelligence* (AI) dapat meningkatkan efektivitas pengambilan keputusan terkait kondisi jalan. Berdasarkan kebutuhan tersebut, sistem yang diusulkan menerapkan model YOLOv11n untuk mendeteksi tiga jenis kerusakan jalan, yaitu *pothole*, *linear crack*, dan *alligator crack*. Hasil deteksi kemudian diolah menggunakan metode *Road Damage Score* (RDS) untuk menentukan prioritas penanganan kerusakan. Penelitian ini bertujuan untuk: (1) menerapkan model YOLOv11 dalam mendeteksi kerusakan jalan secara otomatis dari citra digital; (2) mengimplementasikan sistem pelaporan berbasis *web* yang mengintegrasikan deteksi otomatis dan perhitungan RDS; serta (3) mengevaluasi performa model YOLOv11 menggunakan metrik *precision*, *recall*, mAP50, dan *F1-score*.


2. Metodologi

2.1 Bahan dan Data

Dataset yang digunakan terdiri dari 3.768 citra kerusakan jalan dengan total 6.947 anotasi *bounding box* yang terbagi ke dalam tiga kategori kerusakan, yaitu *pothole*, *linear crack*, dan *alligator crack*. *Dataset* diperoleh dari dua sumber, yaitu data primer sebanyak 869 citra yang diambil langsung oleh peneliti menggunakan kamera *smartphone* di wilayah Kabupaten Bogor, serta data sekunder sebanyak 2.899 citra yang diperoleh dari platform Roboflow. *Dataset* dibagi menjadi data *training* sebanyak 2.883 citra, *validation* sebanyak 485 citra, dan *testing* sebanyak 400 citra. Distribusi anotasi *dataset* ditunjukkan pada Tabel 1.

Tabel 1: Distribusi anotasi *Dataset*.

Kelas Kerusakan	Jumlah Anotasi	Persentase (%)
<i>Pothole</i>	3.063	44,1
<i>Linear Crack</i>	2.354	33,9
<i>Alligator Crack</i>	1.530	22,0
Total	6.947	100%

a. *Pothole*b. *Linear crack*c. *Alligator crack*Gambar 1: *Dataset* Kerusakan Jalan.


Gambar 1 menunjukkan contoh anotasi *dataset* kerusakan jalan menggunakan *bounding box* pada masing-masing kelas kerusakan.

2.2 Metode Penelitian

Penelitian ini menggunakan pendekatan *AI Software Development Lifecycle* (AI-SDLC) yang mengintegrasikan *pipeline* pengembangan model kecerdasan buatan dengan pengembangan sistem berbasis web secara *end-to-end*. Pendekatan ini dipilih karena model YOLOv11 berfungsi sebagai detektor objek berbasis *deep learning*, bukan sebagai metode ekstraksi pola atau *rule* dari data terstruktur, sehingga lebih sesuai dimodelkan dalam kerangka AI-SDLC.

Tahap pertama adalah *problem definition & data collection*, yaitu mendefinisikan tiga kelas kerusakan jalan yang dideteksi (*pothole*, *linear crack*, *alligator crack*) serta mengumpulkan *dataset* dari dua sumber.

Tahap kedua adalah data *preparation*, mencakup pemilihan dan pemahaman karakteristik *dataset* yang digunakan. Tahap ketiga adalah data *preprocessing & augmentation*, meliputi penyeragaman kualitas citra dan penerapan teknik augmentasi untuk meningkatkan variasi data pelatihan. Tahap keempat adalah model development, yaitu pelatihan model YOLOv11n selama 200 epoch menggunakan optimizer AdamW dengan input size 640×640 piksel. Tahap kelima adalah model *evaluation*, menggunakan metrik *precision*, *recall*, F1-score, dan mAP50 pada data pengujian. Tahap keenam adalah *system integration & deployment*, mencakup analisis kebutuhan sistem, perancangan antarmuka dan basis data PostgreSQL melalui Supabase, implementasi *backend* menggunakan Python dengan *framework* Flask dan Leaflet JS untuk visualisasi peta, serta pengujian fungsional sistem pelaporan. Gambar 2 menyajikan diagram alur penelitian secara keseluruhan.



Gambar 2: Diagram Alur Penelitian 1.

2.2.1. Data Preparation, Preprocessing, & Augmentation

Tahap data preparation dilakukan dengan memilih dan memvalidasi dataset kerusakan jalan yang terdiri atas tiga kelas, yaitu pothole, linear crack, dan alligator crack. Selanjutnya dilakukan *preprocessing* untuk menyeragamkan kualitas dan format citra sebelum proses pelatihan model. Proses preprocessing meliputi *resize* citra menjadi 640 × 640 piksel, *auto-orientation*, serta *filtering* terhadap data yang tidak sesuai. Untuk meningkatkan kemampuan generalisasi model, dilakukan teknik augmentasi data, parameter augmentasi yang digunakan ditunjukkan pada Tabel 2.


Tabel 2: Parameter Augmentasi Data.

Jenis Augmentasi	Nilai/Parameter
<i>Horizontal Flip</i>	50%
<i>Mosaic</i>	100%
<i>Mixup</i>	10%
<i>Translate</i>	±10%
<i>Scale</i>	±50%
Penyesuaian <i>Hue</i>	±1,5%

Penyesuaian Saturasi	$\pm 70\%$
Penyesuaian Kecerahan	40%
<i>RandAugment</i>	Aktif
<i>Random Erasing</i>	40%

2.2.2. Pengembangan Model YOLOv11

Model yang digunakan dalam aplikasi ini adalah YOLOv11n karena memiliki arsitektur yang ringan dan efisien sehingga sesuai untuk kebutuhan *object detection* berbasis *web*. *Dataset* dibagi ke dalam data *training*, *validation*, dan *testing* untuk mendukung proses pengembangan model secara terstruktur, pelatihan model dilakukan selama 200 epoch menggunakan *optimizer* AdamW dengan *input image size* 640×640 piksel dan *batch size* sebesar 8. Model menghasilkan *output* berupa *bounding box*, label kelas, dan *confidence score* pada setiap objek kerusakan jalan yang terdeteksi. Arsitektur model YOLOv11 bisa dilihat pada gambar 3.



Gambar 3: Arsitektur YOLOv11.

Tabel 3: Spesifikasi Model YOLOv11n.

Parameter	Nilai
Arsitektur Model	YOLOv11n
Total Layer	181
Total Parameter	2.624.080
Kompleksitas Komputasi	6,6 GFLOPs
<i>Input Size</i>	640×640 piksel

2.2.3. Road Damage Score (RDS)

Road Damage Score (RDS) digunakan sebagai indikator berbasis aturan (*rule-based*) untuk menentukan tingkat prioritas penanganan

kerusakan jalan berdasarkan hasil deteksi objek oleh model YOLOv11n. Pendekatan ini merupakan bentuk penyederhanaan dari konsep evaluasi kondisi jalan pada metode Indeks Kondisi Perkerasan (IKP) dan *Pavement Condition Index* (PCI), di mana penilaian kondisi jalan dilakukan berdasarkan jenis dan tingkat kerusakan yang diamati secara visual.

Penilaian kondisi jalan pada penelitian ini disederhanakan berdasarkan jumlah objek kerusakan yang terdeteksi tanpa mempertimbangkan luas area maupun kedalaman kerusakan. Setiap jenis kerusakan diberikan bobot berbeda sesuai tingkat dampaknya terhadap kondisi jalan dan keselamatan pengguna jalan, yaitu *pothole* sebesar 10, *alligator crack* sebesar 7, dan *linear crack* sebesar 5. Pendekatan pembobotan tersebut mengacu pada prinsip *Pavement Condition Index* (PCI), di mana setiap jenis kerusakan memiliki tingkat pengaruh berbeda terhadap kualitas jalan. Kerusakan seperti *pothole* dan *alligator crack* memiliki *deduct value* lebih tinggi karena termasuk kerusakan struktural berat dan berisiko meningkatkan kecelakaan lalu lintas (Jiang, 2024; Ranyal et al., 2022; Ulya et al., 2023). Tingginya tingkat kerusakan jalan di Indonesia juga dipengaruhi oleh faktor lingkungan, seperti curah hujan yang tinggi, serta tingginya volume dan beban kendaraan yang melintas sehingga mempercepat penurunan kondisi jalan (Bachtiar et al., 2024; Wati et al., 2025). Rumus *Road Damage Score* (RDS) dinyatakan sebagai berikut:

$$RDS = 100 - (N_{pothole} \times 10 + N_{linear} \times 5 + N_{alligator} \times 7) \quad (1)$$

$N_{pothole}$ = Jumlah *pothole* yang terdeteksi

N_{linear} = Jumlah *linear crack* yang terdeteksi

$N_{alligator}$ = Jumlah *alligator crack* yang terdeteksi

Nilai RDS berada pada rentang 0-100, di mana nilai yang lebih rendah menunjukkan kondisi jalan yang lebih buruk dan membutuhkan prioritas penanganan yang lebih tinggi.

2.2.4. Data Preparation, Preprocessing, & Augmentation

Evaluasi performa model dilakukan menggunakan beberapa metrik standar pada *object detection*, yaitu *precision*, *recall*, *F1-score*, dan *mean Average Precision* pada *threshold Intersection over Union* (IoU) sebesar 0,50 atau mAP50. Selain itu, *confusion matrix* digunakan untuk menganalisis pola kesalahan klasifikasi antar kelas kerusakan jalan, *precision* digunakan untuk mengukur tingkat ketepatan model dalam menghasilkan prediksi positif dan dihitung menggunakan Persamaan (2).

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

Recall digunakan untuk mengukur kemampuan model dalam

mendeteksi seluruh objek aktual pada citra dan dihitung menggunakan Persamaan (3).

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

F1-score merupakan rata-rata harmonik antara *precision* dan *recall* yang digunakan untuk menunjukkan keseimbangan performa model dan dihitung menggunakan Persamaan (4).

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

mAP50 digunakan sebagai metrik utama untuk mengevaluasi performa keseluruhan model *object detection* berdasarkan rata-rata *Average Precision* pada *threshold* IoU sebesar 0,50.

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (5)$$

dengan:

N = jumlah kelas

AP_i = *Average Precision* pada setiap kelas

Selain evaluasi kuantitatif, *confusion matrix* digunakan untuk menganalisis pola kesalahan deteksi model, khususnya pada objek kerusakan jalan yang memiliki karakteristik visual yang mirip dengan permukaan aspal.

3. Hasil dan Pembahasan

3.1 Evaluasi Model YOLOv11n

Pengujian dilakukan menggunakan beberapa citra jalan data validasi untuk melihat kemampuan model secara visual. Gambar 4 menunjukkan contoh hasil deteksi kerusakan jalan menggunakan model YOLOv11n. Model mampu mendeteksi objek *pothole*, *linear crack*, dan *alligator crack* secara otomatis beserta *bounding box* pada setiap objek yang terdeteksi. Hasil deteksi menunjukkan bahwa model mampu melakukan lokalisasi objek kerusakan dengan cukup baik pada berbagai kondisi permukaan jalan dan pencahayaan.



Gambar 4: Hasil Deteksi Kerusakan Jalan pada YOLOv11n.

Tabel 4: Hasil Evaluasi YOLOv11n per Kelas pada Data Pengujian.

Kelas	Precision	Recall	mAP50	F-1-Score
All (Rata-rata)	0,6753	0,6169	0,6374	0,6448
<i>Pothole</i>	0,7708	0,7795	0,8323	0,7751
<i>Alligator Crack</i>	0,6539	0,5668	0,5766	0,6072
<i>Linear Crack</i>	0,6010	0,5046	0,5031	0,5486

Tabel 4 menunjukkan kelas *pothole* memperoleh performa terbaik dengan mAP50 sebesar 0,8323 dan F1-score sebesar 0,7751. Tingginya performa pada kelas ini disebabkan oleh karakteristik visual *pothole* yang relatif memiliki ciri khas berupa cekungan pada permukaan jalan sehingga lebih mudah dilokalisasi oleh model. Sebaliknya, kelas *linear crack* menunjukkan performa terendah dengan mAP50 sebesar 0,5031, yang disebabkan oleh karakteristik visual *linear crack* yang tipis dan memanjang sehingga sulit dibedakan dari tekstur aspal. Secara keseluruhan, *precision* rata-rata sebesar 0,6753 menunjukkan bahwa hasil deteksi merupakan prediksi yang benar, sementara *recall* sebesar 0,6169 mengindikasikan bahwa model berhasil mendeteksi sebagian besar objek kerusakan pada data pengujian. Nilai *F1-score* sebesar 0,6448 mencerminkan keseimbangan antara *precision* dan *recall*, dengan nilai mAP50 keseluruhan sebesar 0,6374.

Tabel 5: *Confusion matrix*.

Predicted\True	<i>Alligator Crack</i>	<i>Linear Crack</i>	<i>Pothole</i>	<i>Background</i>
<i>Alligator Crack</i>	77	1	1	40
<i>Linear Crack</i>	0	105	0	91
<i>Pothole</i>	0	0	215	77
<i>Background</i>	51	68	53	0


Analisis *confusion matrix* pada Tabel 5 menunjukkan bahwa model menghasilkan jumlah prediksi benar tertinggi pada kelas *pothole* dengan 215 prediksi benar dari 268 *instance*. Kelas *linear crack* menghasilkan 105 prediksi benar dari 239 *instance*, sedangkan *alligator crack* menghasilkan 77 prediksi benar dari 119 *instance*. Kesalahan deteksi paling dominan terjadi akibat kemiripan karakteristik visual antara objek kerusakan dan tekstur permukaan aspal, khususnya pada kelas *linear crack* yang memiliki bentuk tipis dan memanjang.

3.2 Implementasi Sistem Pelaporan Berbasis Web

Sistem pelaporan kerusakan jalan berhasil diimplementasikan sebagai *platform web* yang dapat diakses oleh dua peran pengguna. Pertama, masyarakat dapat mengunggah foto kondisi jalan beserta lokasi GPS secara *real-time* melalui halaman pelaporan pada Gambar 5 (a). Foto tersebut diproses otomatis oleh model YOLOv11n untuk mendeteksi jenis dan jumlah kerusakan jalan, lalu dihitung nilai *Road Damage Score* (RDS)

sebagai indikator kondisi jalan. Hasil deteksi, *confidence score*, lokasi laporan, dan informasi RDS ditampilkan pada halaman detail laporan seperti pada Gambar 5 (b). Sistem juga menyediakan *timeline monitoring* untuk memantau status tindak lanjut laporan secara transparan oleh masyarakat dan pihak kecamatan.

Seluruh laporan yang masuk ditampilkan pada *dashboard monitoring* berbasis peta digital menggunakan *Leaflet JS* seperti pada Gambar 5 (c). *Dashboard* digunakan oleh pihak kecamatan sebagai administrator untuk memantau persebaran kerusakan jalan, aktivitas laporan terbaru, serta prioritas penanganan berdasarkan nilai RDS. Implementasi sistem menggunakan *framework Flask* pada sisi *backend* dan menunjukkan bahwa integrasi model *deep learning* dengan sistem pelaporan berbasis *web* dapat diterapkan secara langsung untuk mendukung *monitoring* infrastruktur jalan secara *real-time*.



a. Halaman lapor kerusakan

b. Halaman deteksi objek

c. Halaman monitoring kerusakan jalan

Gambar 5: Tampilan Aplikasi berbasis website.

4. Simpulan dan Saran

Model YOLOv11n memperoleh performa keseluruhan dengan *precision* sebesar 0,6753, *recall* sebesar 0,6169, mAP50 sebesar 0,6374, dan F1-score sebesar 0,6448. Evaluasi pada data pengujian menunjukkan bahwa kelas *pothole* mencapai performa terbaik dengan mAP50 sebesar 0,8323, sedangkan *linear crack* menunjukkan performa terendah dengan mAP50 sebesar 0,5031.

Metode *Road Damage Score* (RDS) berhasil diterapkan untuk menentukan prioritas penanganan kerusakan jalan secara cepat dan terstruktur. Sistem yang dikembangkan menunjukkan bahwa integrasi deteksi objek otomatis dan pelaporan berbasis web dapat mendukung pemantauan infrastruktur jalan secara lebih efisien. Penelitian selanjutnya disarankan menerapkan model YOLO terbaru atau model *deep learning* lainnya guna meningkatkan akurasi deteksi, serta menambahkan estimasi tingkat keparahan kerusakan berdasarkan luas *bouding box* sebagai

parameter tambahan dalam perhitungan RDS.

Daftar Pustaka

- Agustin, N., Mulyadi, A., & Amirulloh, M. R. (2025). Peran Dinas Pekerjaan Umum dalam Pemeliharaan dan Perbaikan Infrastruktur Jalan di Ruas Jalan Pangleseran-Cibatu Kabupaten Sukabumi. *Journal Of Social Science Research*, 5(1), 6606–6617. <https://doi.org/10.31004/innovative.v5i1.17922>.
- Ardita, S. P., Al-Ikhsan, S. H., & Wulandari, B. (2026). Pengembangan Sistem Monitoring dan Evaluasi Kecelakaan Lalu Lintas Berbasis Website Untuk Mendukung Pengambilan Keputusan di Kota Bogor. *Jurnal Mahasiswa Teknik Informatika*, 10(2), 2423–2428. <https://doi.org/10.36040/jati.v10i2.17429>.
- Ariani, M., Priyanto, S., & Malkhamah, S. (2019). Analisis tingkat kemungkinan faktor penyebab terjadinya kecelakaan lalu lintas pada anak usia sekolah dasar di Kota Yogyakarta. *Prosiding Seminar Nasional Pascasarjana Departemen Teknik Sipil FT-UI*, 63–71.
- Azza, Z., Aprianto, R., & Ayu, P. (2025). Sistem Informasi Pelaporan Kerusakan Infrastruktur Jalan Berbasis Website. *Jurnal Sistem Informasi TGD*, 4(September), 1130–1139. <https://doi.org/10.53513/jursi.v4i5.11764>.
- Bachtiar, W., Badaron, F., & Massara, A. (2024). Kajian tingkat kerusakan jalan menggunakan metode International Roughness Index (IRI) dan Surfaces Distress Index (SDI) (Ruas Jalan Bai-Idumun di Kabupaten Bolang Mongondow Timur). *Jurnal Teslink: Teknik Sipil dan Lingkungan*, 6(2), 430–437. <https://doi.org/10.52005/teslink.v6i2.420>.
- Badan Pusat Statistik. (2025, Desember 8). *Jumlah Kecelakaan, Korban Mati, Luka Berat, Luka Ringan, dan Kerugian Materi, 2024*. Badan Pusat Statistik. <https://www.bps.go.id/id/statistics-table/2/NTEzIzI=/jumlah-kecelakaan--korban-mati--luka-berat--luka-ringan--dan-kerugian-materi.html>.
- Direktorat Jenderal Bina Marga. (2024). *Pemanfaatan Kecerdasan Artifisial dalam Mendeteksi Kerusakan Jalan Indonesia*. Direktorat Jenderal Bina Marga. <https://binamarga.pu.go.id/index.php/article/pemanfaatan-kecerdasan-artifisial-dalam-mendeteksi-kerusakan-jalan-indonesia>.
- Hamzah, A., Haryadi, I., Rizkyandra, K., & Supriadi, I. (2025). Sistem Monitoring Kerusakan Jalan Di Kota Bandung Berbasis Sistem Informasi Geografis (Studi Kasus: Kota Bandung). *Jurnal Ilmiah ILKOMINFO-Ilmu Komputer & Informatika*, 8(1), 48–59. <https://doi.org/10.47324/ilkominfo.v8i1.315>.
- Ismail, D. R., & Rahmadewi, R. (2025). Sistem Deteksi Jalan Berlubang Secara Real-Time Menggunakan Yolov11: Integrasi Data Dan Lokasi

- Melalui Website. *Jurnal JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(3), 3953–3961. <https://doi.org/10.36040/jati.v9i3.13436>.
- Jiang, Y. (2024). Road damage detection and classification using deep neural networks. *Discover Applied Sciences*, 6(8), 421. <https://doi.org/10.1007/s42452-024-06129-0>.
- Nuha, F. S., & Yulianto, D. (2026). Rancang Bangun Sistem Informasi Pelaporan Kerusakan Infrastruktur Berbasis Web dengan Metode Prototyping Program Studi Informatika , Fakultas Teknologi Industri , Universitas Ahmad Dahlan , Indonesia Design and Development of a Web-Based Infrastructure Da. *Jurnal Pendidikan dan Teknologi Indonesia.*, 6(3), 542–557. <https://doi.org/10.52436/1.jpti.1487>.
- Ranyal, E., Sadhu, A., & Jain, K. (2022). Road Condition Monitoring Using Smart Sensing and Artificial Intelligence: A Review. *Sensors*, 22(8), 1–27. <https://doi.org/10.3390/s22083044>.
- Sasmito, B., Setiadi, B. H., & Isnanto, R. (2023). Deteksi Kerusakan Jalan Menggunakan Pengolahan Citra Deep Learning di Kota Semarang. *Jurnal Ilmiah Bidang Ilmu Kerekayasaan*, 44(1), 7–14. <https://doi.org/10.14710/teknik.v44i1.51908>.
- Surahmanto, M., Aras, S., Adhim, M. R. I., & Ussalama, P. (2024). Deteksi jalan berlubang menggunakan algoritma YOLOv5. *Journal of Digital Business and Information Technology*, 1(1), 1–8. <https://doi.org/10.23971/jobit.v1i1.198>.
- Ulya, A. ., Rita, E., & Ayu, E. S. (2023). Studi penilaian kondisi kerusakan jalan dengan menggunakan metode Pavement Condition Index (PCI) dan International Roughness Index (IRI) (Studi kasus: Ruas Jalan Sungai Hangat - Pulau Sangkar, Kerinci STA 10+500-15+500). *Jurnal Teknik Sipil Universitas Bung Hatta, Cdv*, 31–32.
- Urbiztondo, M., Wu, M., & Kwon, T. J. (2025). Transportation Research Interdisciplinary Perspectives Advancing winter road maintenance : An AI-driven web platform for real-time road condition monitoring and spatial analysis. *Transportation Research Interdisciplinary Perspectives*, 33, 101575. <https://doi.org/10.1016/j.trip.2025.101575>.
- Wati, Y., Pramanda, H., Kamalia, K., Mubarak, A., & Muhajir, M. (2025). Pengaruh Volume Kendaraan Terhadap Tingkat Kerusakan Jalan di Daerah Lamreung. *Journal of Planning and Research in Civil Engineering*, 4(November), 662–669. <https://doi.org/10.55616/prince.v4i3.1041>.