

DETEKSI KERUSAKAN JALAN MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK* (CNN)

Muhammad Haikal Abidin¹⁾, Iman Febriansya Putra²⁾, Sumanto³⁾, Ade Christian⁴⁾,
Jefina Tri Kumalasari⁵⁾, Ghofar Taufiq⁶⁾

Prodi Informatika, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika

Correspondence author: MH Abidin, haikalabdn00@gmail.com, Jakarta, Indonesia

Abstract

Road surface damage is a critical issue that can impact road user safety, transportation efficiency, and infrastructure maintenance costs. Manual road inspection methods are still widely used, but they suffer from subjective assessments that can result in inconsistent data. Therefore, an automated approach using artificial intelligence technology is needed to improve the accuracy and efficiency of road damage detection. This research aims to develop a road damage detection system using a deep learning approach based on Convolutional Neural Networks (CNN). The detection model was trained using an annotated road image dataset covering various types of road surface damage. The training and evaluation processes were conducted using an object detection architecture that included mean average precision (mAP), precision, and recall. Test results show that the CNN model can automatically detect road damage with fairly good performance. However, system performance is still affected by the limited dataset size, class imbalance, and variations in environmental conditions. The developed system has the potential to be a decision-support tool for more effective and data-driven road infrastructure maintenance.

Keyword : *detection system, road damage, deep learning, Convolutional Neural Network*

Abstrak

Kerusakan permukaan jalan merupakan masalah penting yang dapat memengaruhi keselamatan pengguna jalan, efisiensi transportasi, dan biaya pemeliharaan infrastruktur. Metode inspeksi jalan secara manual masih banyak dipakai, memiliki kelemahan adanya subjektivitas penilaian, yang dapat menghasilkan data yang tidak konsisten. Oleh karena itu, dibutuhkan pendekatan otomatis menggunakan teknologi kecerdasan buatan untuk meningkatkan akurasi dan efisiensi deteksi kerusakan jalan. Penelitian ini bertujuan mengembangkan sistem deteksi kerusakan jalan dengan pendekatan *deep learning* berbasis *Convolutional Neural Network* (CNN). Model deteksi dilatih menggunakan *dataset* citra jalan yang mencakup berbagai jenis kerusakan permukaan jalan. Proses pelatihan dan evaluasi dilakukan dengan arsitektur deteksi objek seperti *mean average precision* (mAP), *precision*, dan *recall*. Hasil pengujian menunjukkan bahwa model CNN dapat mendeteksi kerusakan jalan secara otomatis dengan kinerja yang cukup baik. Namun, performa sistem masih dipengaruhi oleh keterbatasan jumlah *dataset*, ketidakseimbangan kelas, dan

variasi kondisi lingkungan. Sistem yang dikembangkan berpotensi menjadi alat pendukung pengambilan keputusan untuk pemeliharaan infrastruktur jalan yang lebih efektif dan berbasis data.

Kata Kunci : sistem deteksi, kerusakan jalan, *deep learning*, *convolutional neural network*

A. PENDAHULUAN

Jalan raya merupakan salah satu infrastruktur transportasi yang memegang peran strategis untuk mendukung pertumbuhan ekonomi, mobilitas sosial, serta distribusi barang dan jasa (Zahra et al., 2024). Kondisi jalan raya sangat mempengaruhi tingkat keamanan transportasi jalan maupun efisiensi transportasi. Kerusakan jalan raya, seperti keretakan, lubang, maupun deformasi aspal, dapat mempengaruhi kenyamanan berkendara, meningkatkan risiko kecelakaan lalu lintas, maupun menghadapi kerugian ekonomi akibat meningkatnya biaya perawatan jasa kendaraan maupun perawatan jalan raya (Mulyana & Wahyudi, 2025).

Secara global, kapasitas dan alat transportasi serta beban lalu lintas yang berlimpah menyebabkan proses degradasi jalan berlangsung lebih cepat dibandingkan siklus perawatan (Juanda et al., 2025). Keadaan ini membutuhkan adanya sistem pelacak jalan yang mampu mengenali kerusakan jalan lebih dahulu dan akurat agar proses perbaikan jalan dapat tepat waktu (Zain, 2024). Akan tetapi saat ini proses pendeteksian kerusakan jalan masih berlangsung dengan cara tradisional melalui proses survei visual oleh petugas lapangan. Metode ini membutuhkan waktu yang cukup lama dan biaya operasional yang tinggi. Hasilnya sangat bergantung pada pengamatan petugas dan bisa cukup subjektif (Zuhri et al., 2025).

Di Indonesia, masalah kerusakan jalan juga telah menjadi isu nasional yang cukup signifikan, mengingat luas dan kelangkaan sumber daya yang diperlukan dalam proses pemeliharaan jalan. Inspeksi manual yang

dilakukan secara berkala tidak bisa menggambarkan secara *real-time* kerusakan tersebut, sehingga beberapa kerusakannya baru bisa terdeteksi setelah mencapai tingkat kerusakan yang cukup parah. Berdampak pada semakin meningkatnya biaya perbaikan maupun penurunan tingkat keselamatan pengguna jalan (Denaro & Lim, 2025). Hal ini menunjukkan bahwa masih diperlukan sebuah metode yang cukup efisien dan objektif dalam pemeliharaan jalan.

Kehadiran teknologi *computer vision* dan *deep learning* memberikan peluang besar dalam otomatisasi proses deteksi kerusakan jalan berbasis citra digital. Salah satu algoritma *deep learning* yang banyak digunakan dalam pengolahan citra adalah *Convolutional Neural Network* (CNN), yang memiliki kemampuan unggul dalam mengekstraksi fitur visual serta mengenali pola kompleks dari struktur citra (Nasution et al., 2025). Penerapan CNN dalam deteksi kerusakan jalan telah banyak dilaporkan dalam penelitian sebelumnya dan menunjukkan kinerja yang menjanjikan, baik dalam mendeteksi lubang jalan (*pothole*) maupun dalam mengklasifikasikan berbagai jenis kerusakan permukaan jalan lainnya (Jiang, 2024).

(Lakshminarayanan & Konidhala, 2024) melakukan pengembangan sistem deteksi lubang jalan berbasis CNN yang diterapkan pada berbagai kondisi kebersamaan cahaya di lingkungan perkotaan. Namun, hasilnya menunjukkan konklusi bahwa CNN mampu mendeteksi lubang jalan secara otomatis dengan tingkat keakuratan yang cukup tinggi untuk dikategorikan relatif atas trend konvensional.

Selain CNN konvensional, ada juga beberapa penelitian lainnya yang mengembangkan model turunan CNN dengan menggunakan teknologi CNN untuk meningkatkan kinerja deteksi kerusakan jalan. (Khairunisa et al., 2024) mengukur kinerja algoritma CNN dan YOLO pada pengenalan kerusakan jalan dan mendapatkan hasil bahwa kedua metode tersebut memiliki keunggulan masing-masing berupa kinerja akurasi dan kinerja proses pemrosesan. Penelitian lainnya oleh (Azhari et al., 2025), adalah analisis dan pengembangan deteksi kerusakan jalan menggunakan teknologi YOLOv9 melalui CNN dengan mendapatkan kinerja optimal pada proses deteksi benda pada citra jalan.

Meskipun berbagai penelitian di atas menunjukkan adanya potensi besar pada penggunaan *deep learning* pada deteksi kerusakan jalan, keterbatasan-keterbatasannya pun masih dapat diamati. Faktor seperti kekurangan *dataset*, imbang tidaknya jumlah pengamatan kelas di klasifikasi kerusakan, hingga keanekaragaman kondisi pengamatan di waktu foto berpotensi berpengaruh nyata pada hasil pengamatan (Ghofur et al., 2025; Zuhri et al., 2025). (Zanevych et al., 2024) pun menegaskan bahwa keanekaragaman foto berpotensi mengecilkan fungsi pengamatan.

Selain itu, (Denaro & Lim, 2025) telah menunjukkan bahwa aplikasi arsitektur berbasis jaringan lebih dalam, seperti kombinasi analisis CNN dengan ResNet, dapat meningkatkan akurasi analisis klasifikasi kerusakan jalan aspal, serta berfungsi sebagai landasan untuk label efisiensi biaya dan waktu dalam aplikasi pemantauan infrastruktur berkelanjutan. Namun, pentingnya difokuskan pengamatan lanjutan untuk dapat mengoptimalkan aplikasi sistem deteksi kerusakan yang.

Berdasarkan penjelasan di atas dan penelitian sebelumnya tersebut dapat disimpulkan bahwa pengembangan sistem deteksi kerusakan jalan berbasis *deep*

learning memiliki potensi peningkatan untuk kedepannya terutama dalam hal kekonvergenan model menyesuaikan kondisi lingkungan dan ketersediaan data. Sehingga berdasarkan hal tersebut maka pada penelitian ini dapat disampaikan tujuan penelitian yaitu mengembangkan sistem deteksi kerusakan permukaan jalan menggunakan pendekatan *deep learning* berbasis *Convolutional Neural Network* dengan menggunakan sumber data berupa citra digital. Sehingga penelitian ini dapat memberikan manfaat penelitian yaitu dapat memberikan karakteristik sistem deteksi kerusakan jalan berbasis *deep learning* yang tepat waktu.

B. METODE PENELITIAN

Penelitian ini adalah penelitian kuantitatif dengan pendekatan eksperimen. Tujuan utamanya adalah mengembangkan dan mengevaluasi sistem deteksi kerusakan jalan berbasis *deep learning* menggunakan metode *Convolutional Neural Network* (CNN). Pendekatan kuantitatif diperlukan karena penelitian ini melibatkan pengukuran kinerja model secara numerik menggunakan metrik tertentu, seperti *precision*, *recall*, dan *mean average precision* (mAP).

Penelitian dilaksanakan di lingkungan laboratorium dengan memanfaatkan *dataset* citra jalan. Waktu penelitian mencakup pengembangan dan pengujian model, termasuk tahap pengumpulan data, pra-proses data, pelatihan model, evaluasi, dan analisis hasil. Lokasi penelitian tidak dibatasi secara geografis karena data yang digunakan adalah citra digital dari *dataset* yang tersedia.

Populasi penelitian ini mencakup semua citra permukaan jalan yang menunjukkan berbagai jenis kerusakan. Sampel terdiri dari citra jalan yang telah dianotasi dan dibagi menjadi data latih, data validasi, dan data uji. Teknik sampling yang digunakan adalah *purposive sampling*, yang berarti pemilihan citra berdasarkan kriteria tertentu, seperti

anotasi yang jelas dan representasi jenis kerusakan yang diteliti.

Pengumpulan data dilakukan dengan menggunakan *dataset* citra jalan dari sumber sekunder. Pengumpulan data dalam penelitian ini dilakukan menggunakan *dataset* citra jalan dari sumber sekunder, yaitu *Road Damage Dataset* yang disediakan oleh (Arya et al., 2022). *Dataset* ini merupakan *dataset* terbuka yang berisi citra permukaan jalan dari berbagai negara dan telah banyak digunakan dalam penelitian deteksi kerusakan jalan berbasis *computer vision* dan *deep learning*.

Dari keseluruhan *dataset* RDD2022, penelitian ini menarik sejumlah 1.455 citra jalan yang merepresentasikan berbagai kondisi kerusakan jalan, seperti lubang jalan (*pothole*), retakan memanjang, retakan melintang, dan kerusakan permukaan lainnya. Citra yang dipilih kemudian diseleksi dan disesuaikan dengan kebutuhan penelitian agar relevan dengan tujuan pengembangan sistem deteksi kerusakan jalan berbasis *Convolutional Neural Network* (CNN).

Sebelum digunakan dalam proses pelatihan dan pengujian model, seluruh citra melalui tahap praproses data yang meliputi penyesuaian ukuran citra (*image resizing*), normalisasi nilai piksel, serta augmentasi data. Proses augmentasi dilakukan untuk meningkatkan variasi data latih dan mengurangi risiko *overfitting* selama proses pelatihan model.

Data yang telah dipraproses selanjutnya dibagi ke dalam data latih dan data uji, kemudian digunakan untuk melatih dan mengevaluasi kinerja model CNN dalam mendeteksi dan mengklasifikasikan kerusakan jalan secara otomatis.

Setelah itu, citra melalui tahap praproses yang mencakup penyesuaian ukuran citra, normalisasi, dan augmentasi data. Proses ini meningkatkan variasi data latih dan mengurangi risiko *overfitting*. Data yang sudah diproses kemudian digunakan dalam pelatihan dan pengujian model CNN.

Alat dan bahan dalam penelitian ini mencakup perangkat keras dan perangkat lunak. Perangkat keras terdiri dari komputer atau laptop dengan spesifikasi prosesor minimal Intel Core i5, RAM minimal 8 GB, dan kartu grafis yang mendukung komputasi GPU untuk mempercepat pelatihan model. Perangkat lunak yang digunakan meliputi sistem operasi, bahasa pemrograman Python, dan framework *deep learning* seperti TensorFlow atau PyTorch untuk membangun dan melatih model CNN. Selain itu, pustaka pendukung untuk pengolahan citra dan visualisasi data juga digunakan.

Analisis data dilakukan dengan mengevaluasi kinerja model CNN menggunakan metrik *precision*, *recall*, dan *mean average precision* (mAP). Hasil evaluasi ini digunakan untuk menilai kemampuan model dalam mendeteksi dan mengklasifikasikan kerusakan jalan dengan tepat. Analisis dilakukan secara deskriptif kuantitatif dengan membandingkan nilai metrik yang diperoleh pada data uji.

Penyajian data dalam penelitian ini ditampilkan dalam bentuk tabel, grafik, dan visualisasi hasil deteksi pada citra jalan. Penyajian ini bertujuan untuk memudahkan interpretasi hasil pengujian dan memberikan gambaran yang jelas tentang kinerja sistem deteksi kerusakan jalan yang dikembangkan.

C. HASIL DAN PEMBAHASAN

Karakteristik Subjek Penelitian

Subjek penelitian pada penelitian ini berupa citra permukaan jalan yang diklasifikasikan ke dalam enam kelas kerusakan berdasarkan *dataset* penelitian. Klasifikasi ini mencerminkan variasi jenis kerusakan yang umum ditemukan pada infrastruktur jalan, mulai dari retakan ringan hingga deformasi permukaan jalan yang bersifat struktural. Karakteristik subjek penelitian ini penting untuk menggambarkan kompleksitas data yang digunakan dalam proses pelatihan dan pengujian model deteksi kerusakan jalan berbasis *deep learning*.


Tabel 1: klarifikasi kerusakan berdasarkan dataset [Sumber data sendiri]

No	Kelas kerusakan	Jumlah citra	keterangan
1	Retakan(crack)	578	Retakan garis,retakan acak,retakan permukaan
2	Lubang(pothole)	497	Lubang kecil,lubang besar,deformasi permukaan
3	Retak longitudinal	122	Retakan memanjang searah jalur jalan
4	Retak transversal	96	Retakan melintang akibat tekanan kendaraan
5	Retak jaringan (alligator cracking)	88	Retakan pola kulit buaya akibat beban berlebih
6	deformasi	74	Gelombang, ambles, atau penurunan permukaan

Berdasarkan Tabel 1, terlihat bahwa kelas retakan (*crack*) dan lubang (*pothole*) memiliki jumlah citra paling dominan dibandingkan kelas kerusakan lainnya. Ketidakseimbangan distribusi data ini berpotensi memengaruhi kinerja model dalam mendeteksi kelas dengan jumlah data yang lebih sedikit.

Analisis Univariat

Analisis univariat dilakukan untuk mengevaluasi kinerja model CNN berdasarkan metrik evaluasi utama, yaitu *mean average precision* (mAP) dan *mAP@50:95*. Analisis ini bertujuan untuk melihat performa model secara keseluruhan tanpa mempertimbangkan perbedaan antar kelas kerusakan.



Gambar 1. Grafik Performa Model Berdasarkan Nilai mAP dan mAP@50:95

Berdasarkan Gambar 1, terlihat bahwa nilai mAP mengalami peningkatan secara bertahap seiring bertambahnya jumlah *epoch*. Pada tahap awal pelatihan, nilai mAP cenderung berfluktuasi, kemudian mulai menunjukkan tren peningkatan yang lebih stabil setelah memasuki *epoch* menengah hingga akhir. Hal ini menunjukkan bahwa model CNN mampu mempelajari pola visual kerusakan jalan secara bertahap melalui proses pelatihan.

Sementara itu, nilai *mAP@50:95* menunjukkan nilai yang lebih rendah dibandingkan mAP, namun tetap mengalami peningkatan yang konsisten. Perbedaan nilai ini mengindikasikan bahwa model memiliki performa yang lebih baik pada ambang *Intersection over Union* (IoU) yang lebih longgar dibandingkan IoU yang lebih ketat.

Analisis Bivariat

Analisis bivariat dilakukan untuk melihat hubungan antara proses pelatihan model dengan nilai *loss* yang dihasilkan, meliputi *box loss*, *class loss*, dan *object loss*. Analisis ini bertujuan untuk menilai stabilitas proses pembelajaran model CNN selama pelatihan.



Gambar 2. Grafik Box Loss, Class Loss, dan

Object Loss Selama Proses Pelatihan

Berdasarkan Gambar 2, dapat dilihat bahwa ketiga jenis *loss* mengalami penurunan signifikan pada tahap awal pelatihan, kemudian cenderung stabil pada *epoch* berikutnya. Penurunan *loss* ini menunjukkan bahwa model CNN berhasil meminimalkan kesalahan prediksi baik dalam aspek lokasi objek, klasifikasi kelas, maupun keberadaan objek kerusakan jalan.

Stabilnya nilai *loss* pada tahap akhir pelatihan mengindikasikan bahwa model telah mencapai kondisi konvergen dan tidak mengalami *overfitting* yang signifikan.

Analisis Multivariat

Analisis multivariat dilakukan untuk menilai pengaruh beberapa faktor secara simultan terhadap kinerja sistem deteksi kerusakan jalan. Faktor-faktor yang dianalisis meliputi distribusi kelas *dataset*, proses pelatihan model, serta dukungan infrastruktur sistem yang digunakan.


	Serverless	Dedicated	Self-Hosted
Workflows	✓	✓	✓
Basic Logic Blocks	✓	✓	✓
Pre-Trained Models	✓	✓	✓
Fine-Tuned Models	✓	✓	✓
Universe Models	✓	✓	✓
Active Learning	✓	✓	✓
Model Monitoring	✓	✓	✓
Foundation Models		✓	✓

Gambar 3. Dukungan Sistem Pengembangan dan Implementasi Model

Berdasarkan Gambar 3, terlihat bahwa sistem pengembangan model mendukung berbagai fitur penting seperti *pre-trained models*, *fine-tuning*, dan *active learning*. Kombinasi faktor-faktor ini berkontribusi terhadap peningkatan performa dan stabilitas model CNN dalam mendeteksi kerusakan jalan.

Analisis Univariat (Kinerja Model Deteksi Kerusakan Jalan)

Analisis univariat selanjutnya dilakukan untuk mengevaluasi kinerja akhir model deteksi kerusakan jalan berdasarkan metrik evaluasi yang dihasilkan dari proses pelatihan dan validasi model. Model yang dikembangkan menggunakan arsitektur *Object Detection* berbasis *Convolutional Neural Network* dengan *checkpoint dataset* COCO dan dilatih menggunakan platform Roboflow versi 3.0 dengan konfigurasi *fast object detection*.



Gambar 4. Hasil Evaluasi Kinerja Model Deteksi Kerusakan Jalan

Berdasarkan Gambar 4, diperoleh nilai *mean average precision* pada ambang *Intersection over Union* 50% (mAP@50) sebesar 52,2%, nilai *precision* sebesar 62,9%, dan nilai *recall* sebesar 50,9%. Nilai *precision* yang lebih tinggi dibandingkan *recall* menunjukkan bahwa model memiliki kemampuan yang baik dalam meminimalkan kesalahan prediksi positif, namun masih terdapat beberapa objek kerusakan jalan yang belum berhasil terdeteksi oleh sistem.

Nilai $mAP@50$ yang berada di atas 50% menunjukkan bahwa model mampu mengenali dan melokalisasi objek kerusakan jalan dengan tingkat ketepatan yang cukup baik pada ambang IoU moderat. Hasil ini mengindikasikan bahwa pendekatan *deep learning* berbasis CNN yang digunakan telah berhasil mempelajari fitur visual kerusakan jalan dari *dataset* yang digunakan.

Analisis Bivariat (Hubungan Proses Pelatihan dan Kinerja Model)

Hubungan antara proses pelatihan model dengan kinerja akhir sistem dapat dilihat dari durasi pelatihan dan stabilitas metrik evaluasi yang dihasilkan. Berdasarkan informasi pelatihan, model dilatih selama beberapa jam hingga mendekati konvergensi, dengan pemantauan metrik evaluasi dilakukan secara berkala pada *validation set*.

Hasil evaluasi menunjukkan bahwa peningkatan kinerja model sejalan dengan proses pembelajaran selama pelatihan berlangsung. Meskipun demikian, nilai *recall* yang masih lebih rendah dibandingkan *precision* menunjukkan bahwa model masih dipengaruhi oleh ketidakseimbangan distribusi *dataset*, khususnya pada kelas kerusakan dengan jumlah citra yang lebih sedikit. Temuan ini konsisten dengan hasil analisis distribusi data pada Tabel 1.

Analisis Multivariat (Pengaruh Arsitektur, Dataset, dan Platform Pelatihan)

Analisis multivariat dilakukan dengan mempertimbangkan pengaruh arsitektur model, karakteristik *dataset*, serta platform pelatihan terhadap kinerja sistem secara keseluruhan. Penggunaan *pre-trained model* dengan *checkpoint COCO* memberikan keuntungan pada tahap awal pelatihan karena model telah memiliki kemampuan dasar dalam mengenali objek visual.

Namun demikian, keterbatasan jumlah data pada beberapa kelas kerusakan serta variasi kondisi citra jalan memengaruhi performa akhir model, khususnya pada aspek

recall. Hal ini menunjukkan bahwa optimalisasi lebih lanjut, seperti penambahan *dataset*, peningkatan teknik augmentasi data, serta penyesuaian parameter pelatihan, berpotensi meningkatkan kinerja sistem secara signifikan.

Pembahasan

Hasil evaluasi model menunjukkan bahwa sistem deteksi kerusakan jalan berbasis *Convolutional Neural Network* mampu menghasilkan kinerja yang cukup baik dengan nilai $mAP@50$ sebesar 52,2%. Nilai *precision* yang relatif tinggi menunjukkan bahwa model mampu memberikan prediksi yang akurat terhadap objek kerusakan jalan yang terdeteksi, sedangkan nilai *recall* yang masih moderat menunjukkan adanya peluang peningkatan dalam mendeteksi lebih banyak objek kerusakan yang ada.

Secara keseluruhan, hasil penelitian ini mengindikasikan bahwa pendekatan *deep learning* berbasis CNN layak digunakan sebagai dasar pengembangan sistem deteksi kerusakan jalan otomatis. Dengan pengembangan lanjutan pada aspek *dataset* dan strategi pelatihan, sistem ini berpotensi menjadi solusi pendukung pemantauan kondisi jalan yang lebih efisien, objektif, dan berbasis data.



Gambar 5. Hasil uji coba kinerja

Gambar 5 menampilkan hasil uji coba kinerja sistem deteksi kerusakan jalan berbasis *Convolutional Neural Network* (CNN) dalam mengidentifikasi dan melokalisasi berbagai jenis kerusakan permukaan jalan pada citra uji. Visualisasi ini memperlihatkan keluaran model berupa *bounding box* dan label kelas kerusakan yang terdeteksi, seperti lubang (*pothole*), retakan (*crack*), serta deformasi permukaan jalan.

Berdasarkan Gambar 5, sistem mampu mendeteksi objek kerusakan jalan dengan tingkat ketepatan visual yang cukup baik, ditunjukkan oleh kesesuaian posisi *bounding box* dengan area kerusakan aktual pada citra. Hal ini menunjukkan bahwa model CNN telah berhasil mempelajari fitur visual utama dari kerusakan jalan, baik dalam bentuk perubahan tekstur permukaan maupun perbedaan pola warna pada aspal.

Namun demikian, pada beberapa citra uji masih ditemukan kondisi di mana sebagian kerusakan jalan belum terdeteksi secara optimal atau hanya terdeteksi sebagian. Kondisi ini umumnya terjadi pada citra dengan pencahayaan rendah, permukaan jalan yang tertutup genangan air, serta kerusakan dengan ukuran kecil atau pola yang menyerupai objek non-kerusakan, seperti marka jalan. Temuan ini sejalan dengan hasil evaluasi kuantitatif yang menunjukkan nilai *recall* lebih rendah dibandingkan *precision*, yang mengindikasikan bahwa model masih melewatkan sebagian objek kerusakan yang ada.

Secara keseluruhan, hasil uji coba kinerja yang ditunjukkan pada Gambar 5 memperkuat hasil evaluasi numerik sebelumnya, di mana sistem deteksi kerusakan jalan berbasis CNN menunjukkan performa yang cukup baik dalam mendeteksi objek kerusakan secara otomatis. Meskipun demikian, peningkatan kinerja masih dapat dilakukan melalui penambahan variasi *dataset*, khususnya pada kondisi lingkungan yang menantang, serta optimalisasi parameter pelatihan untuk meningkatkan

kemampuan model dalam mendeteksi seluruh objek kerusakan secara lebih menyeluruh.

D. PENUTUP

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa sistem deteksi kerusakan jalan berbasis *deep learning* dengan metode *Convolutional Neural Network* (CNN) mampu mendeteksi dan mengklasifikasikan kerusakan permukaan jalan menggunakan citra digital secara otomatis. Model yang dikembangkan menunjukkan kinerja yang cukup baik berdasarkan metrik evaluasi yang digunakan, seperti *precision*, *recall*, dan *mean average precision* (mAP), sehingga menunjukkan bahwa pendekatan CNN efektif dalam mengekstraksi fitur visual dan mengenali pola kerusakan jalan.

Hasil analisis juga menunjukkan bahwa kinerja sistem dipengaruhi oleh beberapa faktor, antara lain distribusi jumlah data pada setiap kelas kerusakan, variasi kondisi lingkungan pengambilan citra, serta kualitas proses pelatihan model. Ketidakseimbangan *dataset* pada beberapa kelas kerusakan masih berdampak pada kemampuan model dalam mendeteksi seluruh objek kerusakan secara optimal.

Secara keseluruhan, penelitian ini membuktikan bahwa penerapan metode CNN memiliki potensi untuk digunakan sebagai alat pendukung dalam pemantauan dan pemeliharaan infrastruktur jalan yang lebih efisien, objektif, dan berbasis data. Dengan pengembangan lebih lanjut, khususnya pada aspek penambahan *dataset* dan optimalisasi model, sistem deteksi kerusakan jalan ini diharapkan dapat diterapkan secara lebih luas dalam skala operasional.

E. DAFTAR PUSTAKA

- Arya, D., Maeda, H., Ghosh, S. K., Toshniwal, D., & Sekimoto, Y. (2022). RDD2022: A multi-national image dataset for automatic Road Damage Detection. *ArXiv*, 1–16. <https://doi.org/10.48550/arXiv.2209.08538>
- Azhari, F. A., Rohana, T., Kiki, & Fauzi, A. (2025). Road Damage Detection Using Yolov9-Based Imagery. *Sisfokom : Jurnal Sistem Informasi Dan Komputer*, 14(2), 196–201. <https://doi.org/10.32736/sisfokom.v14i2.2377>
- Denaro, L. G., & Lim, R. (2025). Analisis Deteksi Kerusakan pada Jalan Aspal menggunakan Deep Learning untuk Mendukung Efisiensi Biaya dan Waktu dalam Pemantauan Berkelanjutan. *Jurnal Dimensi Insinyur Profesional*, 3(1), 16–25. <https://doi.org/10.9744/jdip.3.1.16-25>
- Ghofur, M. A., Murdifin, Hardandrito, A. G., & 'Uyun, S. (2025). High Precision Deep Learning Model for Road Damage Classification using Transfer Learning. *Sistemasi: Jurnal Sistem Informasi*, 14(6), 3028–3036. <https://doi.org/10.32520/stmsi.v14i6.5707>
- Jiang, Y. (2024). Road damage detection and classification using deep neural networks. *Discover Applied Sciences*, 6, 421. <https://doi.org/10.1007/s42452-024-06129-0>
- Juanda, A., Muammar, R., & Sabilla, A. (2025). Evaluasi Kerusakan Perkerasan Jalan Perkotaan Berdasarkan Metode Pavement Condition Index (PCI) (Studi Kasus: Ruas Jalan Malikul Adil, Kota Langsa). *PRINCE : Journal of Planning and Research in Civil Engineering*, 4(3), 691–699.
- Khairunisa, N., Carudin, & Jamaludin, A. (2024). Analisis Perbandingan Algoritma CNN dan YOLO Dalam Mengidentifikasi Kerusakan Jalan. *JITET : Jurnal Informatika Dan Teknik Elektro Terapan*, 12(3), 1756–1768. <https://doi.org/10.23960/jitet.v12i3.44340>
- Lakshminarayanan, S., & Konidhala, J. (2024). Convolutional Neural Network for Pothole Identifications in Urban Roads. *International Journal of Advances in Signal and Image Sciences*, 10(1), 1–12. <https://doi.org/10.29284/ijasis.10.1.2024.1-12>
- Mulyana, D. I., & Wahyudi, I. (2025). Deteksi Kerusakan Jalan Berdasarkan Citra Digital Menggunakan Convolutional Neural Network (CNN). *JIMIK : Jurnal Indonesia Manajemen Informatika Dan Komunikasi*, 6(1), 294–302. <https://doi.org/10.35870/jimik.v6i1.1192>
- Nasution, M. U., Harahap, L. S., & Syakbani, F. (2025). Tinjauan Metode Pengolahan Citra Digital Untuk Deteksi Objek Otomatis. *JITET : Jurnal Informatika Dan Teknik Elektro Terapan*, 13(3), 1020–1028. <https://doi.org/10.23960/jitet.v13i3.7135>
- Zahra, K., Manalu, R. H. R., Nabillah, R., & Dewi, P. K. (2024). Analisis Dampak Pembangunan Infrastruktur Jalan terhadap Pertumbuhan Ekonomi Kecamatan Medan Tembung. *El-Mal: Jurnal Kajian Ekonomi & Bisnis Islam*, 5(3), 1857–1866. <https://doi.org/10.47467/elmal.v5i3.1070>
- Zain, M. M. (2024). Optimalisasi Kerusakan Jalan di Indonesia Melalui Aplikasi Pelaporan dan Pendeteksi Kerusakan Jalan. *ELEMENTER : Elektro Dan Mesin*

Terapan, 10(1), 54–64.
<https://doi.org/10.35143/elementer.v10i1.6300>

Zanevych, Y., Yovbak, V., Basystiuk, O., Shakhovska, N., Fedushko, S., & Argyroudis, S. (2024). Evaluation of Pothole Detection Performance Using Deep Learning Models Under Low-Light Conditions. *Sustainability*, 16(24), 10964.
<https://doi.org/10.3390/su162410964>

Zuhri, A. S. M., Nafiiyah, N., & Budi, A. S. (2025). Identification of Road Damage Using the Convolutional Neural Network (CNN) Method. *Jurnal Ilmiah Sistem Informasi*, 4(3), 802–817.
<https://doi.org/10.51903/jgn2sd35>