

# Deteksi Kerusakan Jalan Berdasarkan Citra Digital Menggunakan *Convolutional Neural Network (CNN)*

Dadang Iskandar Mulyana <sup>1</sup>, Ilham Wahyudi <sup>2\*</sup>

<sup>1,2\*</sup> Program Studi Ilmu Komputer, Sekolah Tinggi Ilmu Komputer Cipta Karya Informatika, Kota Jakarta Timur, Daerah Khusus Ibukota Jakarta, Indonesia.

Email: mahvin2012@gmail.com <sup>1</sup>, wahyudiilham@gmail.com <sup>2\*</sup>

## Histori Artikel:

Dikirim 23 Oktober 2024; Diterima dalam bentuk revisi 13 November 2024; Diterima 20 Desember 2024; Diterbitkan 10 Januari 2025. Semua hak dilindungi oleh Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) STMIK Indonesia Banda Aceh.

## Abstrak

Jalan raya merupakan sebuah penghubung suatu kawasan atau daerah ke daerah lainnya yang dituju. Maraknya pembangunan jalan raya dikota-kota besar, tidak sebanding dengan pembenahan dan penataan ulang terhadap jalan-jalan rusak yang berada di beberapa daerah. Sebagian besar jalan rusak disebabkan oleh lalu lintas kendaraan dengan bobot besar atau muatan besar dengan intensitas yang cukup sering, serta bencana alam seperti banjir dan gempa bumi. Hal ini tentu saja mengganggu sistem lalu lintas, dan cukup membahayakan bagi para pengendara yang sering berlalu lalang pada kawasan yang banyak dijumpai jalan-jalan rusak. Dengan adanya kendala tersebut, maka penelitian ini bertujuan untuk membangun sebuah sistem yang dapat mendeteksi kerusakan jalan melalui tangkapan citra digital menggunakan metode convolutional neural network. Hasil dari penelitian ini didapatkan sebuah nilai akurasi pendekripsi kerusakan jalan mencapai 80%.

**Kata Kunci:** Deteksi; Jalan Rusak; CNN.

## Abstract

Highways are a connection between an area or region to another destination. The rapid construction of highways in big cities is not comparable to the improvement and rearrangement of damaged roads in several areas. Most of the damaged roads are caused by heavy vehicle traffic or heavy loads with quite frequent intensity, as well as natural disasters such as floods and earthquakes. This of course disrupts the traffic system, and is quite dangerous for drivers who often pass through areas where there are many damaged roads. With these obstacles, this study aims to build a system that can detect road damage through digital image capture using the convolutional neural network method. The results of this study obtained a road damage detection accuracy value reaching 80%.

**Keyword:** Detection; Damaged Road; CNN.

## 1. Pendahuluan

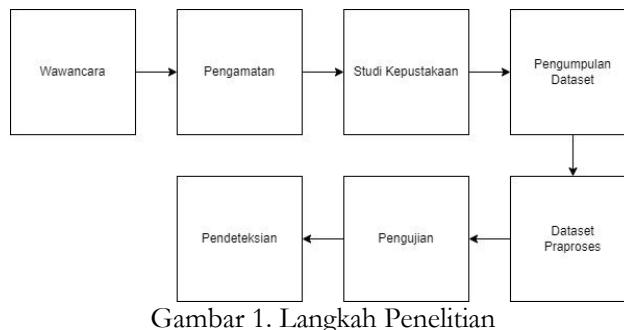
Jalan merupakan kebutuhan yang amat sangat penting bagi masyarakat terutama dalam beraktivitas. Jalan dapat mempermudah masyarakat dalam bertransportasi dari suatu daerah ke daerah lainnya (Sasmoro, 2023). Jalan, menurut Peraturan Pemerintah Republik Indonesia Nomor 34 tahun 2010 Bab 1 Pasal 1 Ayat 1, adalah transportasi darat yang mencakup semua bagian jalan beserta bangunan pelengkapnya yang digunakan untuk lalu lintas. Jalan dapat berada di permukaan tanah, di atas permukaan tanah, di bawah permukaan tanah, atau di atas air, kecuali jalan lori, jalan kabel, dan jalan kereta api. Jalan sebagai transportasi nasional dibangun karena merupakan faktor pendukung utama dalam bidang sosial, budaya, dan lingkungan. Tujuannya adalah untuk mencapai pemerataan pembangunan antar daerah serta meningkatkan pengembangan wilayah dan ekonomi secara berkelanjutan (Wibowo, 2023). Kondisi jalan juga berpengaruh terhadap lalu lintas di suatu daerah. Jalan rusak dipengaruhi oleh beberapa faktor seperti banjir, gempa bumi, atau seringnya lalu-lalang kendaraan dengan muatan besar atau di luar kapasitas. Kerusakan jalan tentu sangat berpengaruh terhadap kondisi pengendara, waktu, serta keselamatan. Dampak dari kerusakan tersebut dapat mengakibatkan kecelakaan tunggal atau beruntun bagi pengguna jalan jika kerusakan jalan tidak segera diperbaiki (Virgantara Putra, 2021). Oleh karena itu, penanganan kerusakan harus segera dilakukan. Merawat jaringan jalan membutuhkan manajemen yang terus-menerus karena jalan penting untuk transportasi darat. Pemantauan jalan sangat penting untuk meminimalisir kecelakaan yang disebabkan oleh kondisi jalan yang buruk. Namun, masalah utama dalam sistem pemantauan adalah banyaknya jaringan jalan yang perlu dipantau. Mengawasi secara terus-menerus bisa menjadi sulit, terutama untuk area yang luas. Sementara itu, pencarian kerusakan jalan secara manual membutuhkan waktu yang lama karena survei harus dilakukan di semua lokasi jaringan jalan. Melihat betapa pentingnya kondisi jalan terhadap kehidupan sosial masyarakat, hal ini juga menjadi dasar latar belakang masalah penelitian.

Peneliti menggunakan metode CNN (*Convolutional Neural Network*), di mana sistem mengamati tangkapan gambar (citra digital) dan kemudian mendekripsi atau mendeskripsikan apakah jalan tersebut "Rusak" atau "Tidak Rusak". Jaringan saraf konvolusional (CNN) adalah desain pembelajaran mesin yang biasanya digunakan untuk menyelesaikan masalah klasifikasi gambar (Tan & Le, 2019). Penelitian terdahulu menunjukkan bahwa pengujian dengan 200 dataset dan 20 label menghasilkan skor akurasi tertinggi sebesar 80% dan 60%. Hasil akurasi tertinggi yang diperoleh dari proses pelatihan model adalah 90% setelah 200 epoch (Qotrunnada & Utomo, 2022). Penelitian lainnya menunjukkan bahwa hasil akurasi training mencapai 90% dan hasil akurasi validasi sebesar 65%. Hasil percobaan menunjukkan bahwa 28 dari total 35 ekspresi berhasil ditebak dengan benar, dengan tingkat akurasi mencapai 80% (Budi, Harianto, & Setyati, 2023). Berdasarkan tingkat akurasi yang cukup tinggi, peneliti memilih metode CNN. Selain itu, pemrosesan data dengan teknik *pre-processing* dapat meningkatkan kinerja model dengan menambah variasi data. Dalam pembangunan sistem deteksi jalan rusak, peneliti menggunakan bahasa pemrograman *Python*. Tujuan dari dirancangnya sistem deteksi kerusakan jalan adalah untuk memberikan informasi kepada instansi terkait agar menanggulangi dengan cepat dan tanggap terkait permasalahan kerusakan jalan yang ada di beberapa daerah.

## 2. Metode Penelitian

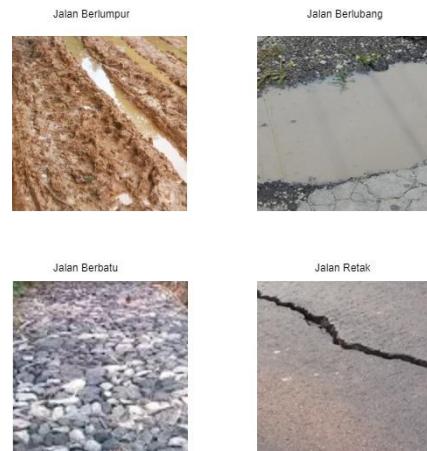
Untuk memperoleh hasil yang maksimal dalam sebuah proses penelitian, sering kita dengar tentang metode pengumpulan data, alat pengumpulan data, dan langkah penelitian agar terstruktur dengan baik (Sasmoro, 2023). Meskipun terkait, istilah-istilah ini memiliki arti yang berbeda. Metode pengumpulan data adalah cara yang digunakan oleh peneliti untuk mengumpulkan informasi. Pengumpulan data bertujuan untuk mendapatkan informasi yang diperlukan untuk mencapai tujuan penelitian. Alat pengumpulan data digunakan untuk mengumpulkan informasi (Wibowo, 2023).

Instrumen pengumpulan data bisa berupa *check list*, *kuesioner*, pedoman wawancara, atau kamera. Sementara itu, langkah penelitian adalah sebuah kerangka tahapan yang harus dilalui selama pengumpulan data dengan menggunakan alat pengumpulan data, kemudian implementasi hasil penelitian. Berikut adalah langkah penelitian yang dilakukan:

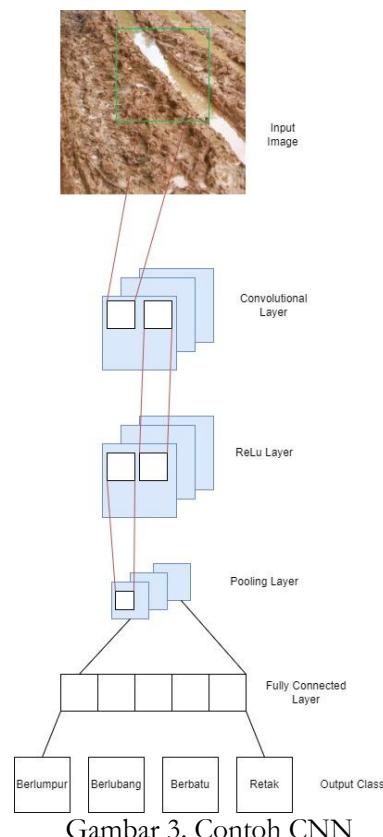


Gambar 1. Langkah Penelitian

Untuk memperoleh hasil yang maksimal dalam sebuah proses penelitian, sering kali dibahas mengenai metode pengumpulan data, alat pengumpulan data, dan langkah-langkah penelitian agar proses tersebut terstruktur dengan baik (Sasmito, 2023). Meskipun terkait, istilah-istilah ini memiliki makna yang berbeda. Metode pengumpulan data merujuk pada cara yang digunakan oleh peneliti untuk mengumpulkan informasi yang diperlukan untuk mencapai tujuan penelitian. Pengumpulan data bertujuan untuk mendapatkan informasi yang relevan dan mendukung analisis dalam penelitian tersebut (Wibowo, 2023). Alat pengumpulan data sendiri adalah instrumen yang digunakan dalam proses ini, yang bisa berupa *check list*, *kuesioner*, pedoman wawancara, atau kamera. Langkah-langkah penelitian merupakan kerangka tahapan yang harus dilalui selama pengumpulan data dan penerapan alat-alat pengumpulan data, yang kemudian diikuti dengan implementasi hasil penelitian. Salah satu metode pengumpulan data yang digunakan adalah wawancara, yaitu cara berbicara langsung antara peneliti dan narasumber (Virgantara Putra, 2021). Dengan kemajuan teknologi, wawancara dapat dilakukan melalui berbagai media, seperti telepon, email, atau *video call* menggunakan aplikasi seperti Zoom atau Skype. Wawancara ini terbagi menjadi dua kategori, yaitu wawancara terstruktur, di mana peneliti sudah menyusun daftar pertanyaan secara sistematis, dan wawancara tidak terstruktur, di mana peneliti lebih fleksibel dalam memperoleh informasi. Dalam wawancara terstruktur, peneliti biasanya menggunakan alat seperti *recorder* dan kamera untuk merekam informasi dari narasumber. Selain wawancara, metode lain yang digunakan adalah pengamatan, yang merupakan cara pengumpulan data yang rumit karena melibatkan banyak faktor yang berbeda dalam prosesnya (Azmi, 2023). Pengamatan ini tidak hanya digunakan untuk menilai sikap responden, tetapi juga untuk mencatat berbagai fenomena yang terjadi, terutama dalam studi yang meneliti perilaku manusia, proses kerja, atau fenomena alam. Selain itu, studi kepustakaan juga digunakan untuk mengumpulkan artikel, karya ilmiah terdahulu, dan buku yang berkaitan dengan topik penelitian serta menjadi sumber referensi yang relevan (Tan & Le, 2019). Untuk keperluan penelitian ini, dataset diperoleh dari situs *kaggle.com*, dengan peneliti mengumpulkan 200 citra digital yang dibagi ke dalam empat kelas, yaitu *Berlubang*, *Retak*, *Lumpur*, dan *Bebatuhan* (Wibowo, 2023). Dataset yang dikumpulkan kemudian diproses melalui langkah *preprocessing*, yang bertujuan untuk menyiapkan data mentah agar lebih mudah dilatih dan menghasilkan model yang lebih baik (Budi, Harianto, & Setyati, 2023). Langkah *preprocessing* ini melibatkan *resize* dan *crop* gambar untuk menyorot fitur yang relevan untuk klasifikasi. Selain itu, data dibagi menjadi tiga bagian: data latih (*train*), data validasi (*validation*), dan data uji (*test*). Pembagian data dilakukan dalam dua rasio berbeda, yaitu pertama dengan 50% data latih, 30% data validasi, dan 20% data uji, dan kedua dengan 60% data latih, 20% data validasi, dan 20% data uji. Proses *data preprocessing* ini diilustrasikan dalam gambar 2.

**Gambar 2.** Data Pra-proses

*Convolutional Neural Network* (CNN) merupakan algoritma *deep learning* yang dianggap sebagai salah satu inovasi terbaik dari Jaringan Syaraf Tiruan (JST) karena dirancang secara khusus untuk pendekripsi dan klasifikasi gambar (Azmi, 2023). Struktur CNN terinspirasi dari cara kerja syaraf dalam tubuh manusia, terutama syaraf pada otak manusia, yang mampu mengenali pola secara efektif. Proses klasifikasi dengan metode CNN melibatkan berbagai tahapan, mulai dari pengambilan fitur gambar hingga pengklasifikasian menjadi berbagai kategori yang ditentukan. Pada kemampuan ini, CNN telah menjadi standar dalam berbagai aplikasi pengolahan citra digital, termasuk dalam deteksi kerusakan jalan.

**Gambar 3.** Contoh CNN

*Matriks konfusi* adalah salah satu metode yang digunakan untuk mengevaluasi tingkat akurasi suatu model. *Matriks konfusi* ini mencakup empat hasil perhitungan utama, yaitu *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN) (Budi, Harianto, & Setyati, 2023). Nilai akurasi menggambarkan kemampuan sistem dalam mengklasifikasikan data secara benar. Akurasi ditentukan dengan membandingkan jumlah data yang benar-benar diklasifikasikan dengan total jumlah data yang ada. Selain akurasi, nilai presisi juga menjadi indikator penting, yang dihitung dengan rumus tertentu seperti yang ditunjukkan pada Persamaan 1. Nilai akurasi, yang merupakan penjumlahan data positif yang benar-benar terkласifikasi dibagi dengan jumlah data positif, dapat dihitung menggunakan Persamaan 2. Sementara itu, sensitivitas menunjukkan tingkat keakuratan sistem dalam mengklasifikasikan hasil positif, seperti yang dirumuskan dalam Persamaan 3. Skor F1, yang mencerminkan keseimbangan antara presisi dan sensitivitas, dihitung dengan membagi data negatif yang benar-benar diprediksi dengan total data negatif, sesuai dengan Persamaan 4.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$

$$\text{Presisi} = \frac{TP}{TP + FP} \times 100\% \quad (2)$$

$$\text{Sensitivitas} = \frac{TP}{TP + FN} \times 100\% \quad (3)$$

$$\text{F1 - Score} = 2 \times \frac{\text{Presisi} \times \text{Sensitivitas}}{\text{Presisi} + \text{Sensitivitas}} \quad (4)$$

Keterangan:

TP : benar-benar positif. Artinya, nilai data positif yang diketahui kebenarannya.

TN : benar-benar negatif. Artinya, nilai data negatif yaitu h. dinyatakan benar.

FP : negatif palsu. Artinya,h. menghapus nilai data positif secara salah.

FN : negatif palsu. Artinya, h. Nilai data negatif salah ditentukan.

Hasil dari sistem yang dibangun, yaitu mampu menangkap sebuah citra kemudian melakukan deteksi dengan mendeskripsikannya dalam bentuk tulisan pada tampilan layar.

Tabel 1. Alur Pengujian

Scenario	Keterangan
Pembagian data	50% data latih, 30% data validasi dan 20% data test
	60% data latih, 20% data validasi dan 20% data test
Kelas	Berlumpur, berlubang, berbau, retak
Ukuran	224x224 Pixel
Batch size	32
Epochs	20,50,80,100

### 3. Hasil dan Pembahasan

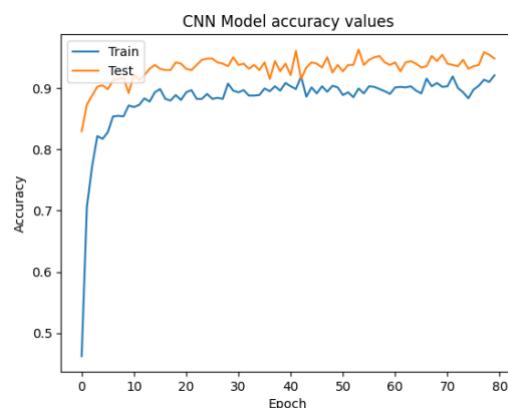
#### 3.1 Hasil

Proses berikutnya adalah melatih model. Sebelum memulai pelatihan pada model, jumlah *epochs* yang akan digunakan telah ditentukan sebelumnya. Penelitian sebelumnya yang menjadi referensi dalam penelitian ini tidak memberikan batasan pasti mengenai jumlah *epochs* yang diperlukan, karena jumlah *epochs* dapat bervariasi tergantung pada jumlah data dan struktur yang digunakan. Tabel 2 menunjukkan percobaan pelatihan model dengan beberapa proporsi pembagian data dan jumlah *epochs*.

Tabel 2. Percobaan model

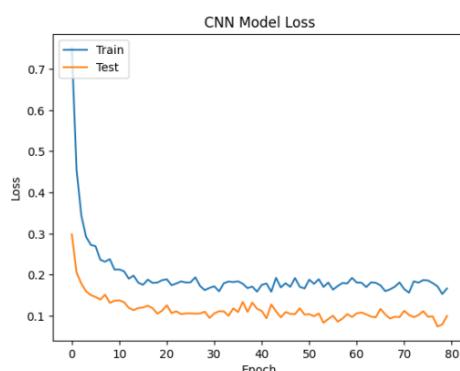
Percobaan ke	Rasio	Epochs	Latih		Validasi	
			Akurasi	Loss	Akurasi	Loss
1	70:30	20	0,86	0,19	0,91	0,11
2	70:30	50	0,90	0,15	0,93	0,11
3	70:30	80	0,92	0,16	0,94	0,10
4	70:30	100	0,90	0,18	0,93	0,11
5	80:20	20	0,87	0,18	0,94	0,09
6	80:20	50	0,90	0,17	0,93	0,10
7	80:20	80	0,89	0,18	0,91	0,12
8	80:20	100	0,90	0,18	0,93	0,07

Berbagai percobaan *training* pada model dipilih model pada percobaan ke-3 yang menghasilkan akurasi training dengan nilai 0,92 dan akurasi validasi bernilai 0,94. Hasil akurasi training dan validasi dapat dilihat pada gambar 4.



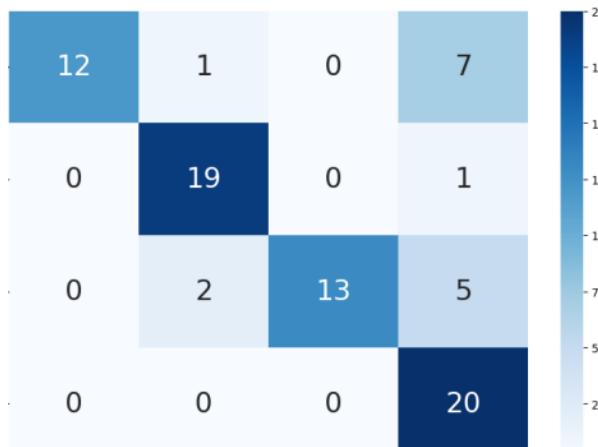
Gambar 4. Akurasi Pelatihan dan Validasi

Tampilan *loss* pada training bernilai 0,16 dan loss validasi dengan nilai 0,10. Hasil loss pada training dan validasi dapat dilihat pada gambar 5. Setelah mendapatkan hasil pada model. Tahap selanjutnya dalam penelitian ini adalah menguji model yang telah dibuat.



Gambar 5. Loss Pada Pelatihan dan Validasi

Tahap selanjutnya dalam penelitian ini adalah menguji model yang telah dibuat. Pengujian merupakan tahapan yang selalu dilakukan setelah sistem selesai dibuat, untuk mengukur keberhasilan yang dicapai dalam suatu penelitian. Pengujian pada penelitian ini dilakukan dengan menggunakan *confusion matrix* di *Google Colab* untuk mengetahui akurasi, presisi, *recall*, dan *f1-score* pada model. Model diuji menggunakan dataset uji dengan jumlah 80 gambar, yang terdiri dari 20 gambar *cordana*, 20 gambar *sehat*, 20 gambar *pestalotiopsis*, dan 20 gambar *sigatoka*. Hasil *confusion matrix* dapat dilihat pada gambar 6.



Gambar 6. Matrix Konfusi

Menggunakan persamaan (1-4) diketahui akurasi test sebesar 82%, presisi sebesar 85%, *recall* sebesar 83% dan *f1-score* sebesar 82%. Secara keseluruhan model yang dihasilkan baik dan hasil test identik dengan hasil pelatihan dan validasi. Model yang telah dihasilkan bisa diterapkan untuk melakukan klasifikasi jalan rusak dengan cara mengambil gambar jalan rusak dan melakukan test klasifikasi menggunakan model yang telah dibuat.

### 3.2 Pembahasan

Hasil penelitian menunjukkan bahwa model deteksi kerusakan jalan yang dirancang menggunakan *Convolutional Neural Network (CNN)* mampu mencapai tingkat akurasi yang signifikan. Berdasarkan hasil pengujian, model ini memperoleh tingkat akurasi sebesar 82%, presisi 85%, *recall* 83%, dan *f1-score* 82%. Hasil ini menunjukkan bahwa model yang dikembangkan memiliki kinerja yang cukup stabil dan dapat diandalkan dalam mengidentifikasi kerusakan jalan, seperti yang juga ditemukan dalam penelitian oleh Wibowo (2023) yang menggunakan metode serupa untuk mendeteksi keretakan jalan aspal. Hasil penelitian ini memperkuat temuan dari Sasmito (2023), yang menunjukkan bahwa teknik *deep learning* dapat memberikan akurasi yang tinggi dalam pendekripsi kerusakan jalan melalui pengolahan citra digital. Penting untuk dicatat bahwa keberhasilan model ini sangat dipengaruhi oleh tahap *preprocessing* data, di mana teknik *resize* dan *crop* gambar digunakan untuk menyorot fitur-fitur penting yang relevan untuk klasifikasi. Langkah ini sejalan dengan temuan dari Angulo *et al.* (2019), yang menunjukkan bahwa tahap persiapan data yang baik dapat meningkatkan kinerja model dalam mendeteksi kerusakan fisik pada jalan. Pembagian dataset menjadi data latih, validasi, dan uji juga membantu meningkatkan kinerja model, karena memungkinkan model untuk belajar dari variasi data yang lebih representatif. Namun, meskipun hasilnya cukup baik, terdapat beberapa tantangan yang perlu diperhatikan. Misalnya, meskipun akurasi pada dataset pelatihan sangat tinggi, akurasi pada dataset validasi sedikit lebih rendah, yang menunjukkan adanya kemungkinan *overfitting* pada model. Hal ini sejalan dengan penelitian sebelumnya oleh Virgantara Putra (2021), yang juga melaporkan tantangan serupa dalam pendekripsi kerusakan jalan dengan menggunakan *CNN*.

Pengaturan parameter model yang lebih hati-hati dan penambahan variasi data bisa menjadi langkah yang diperlukan untuk meningkatkan kemampuan generalisasi model. Hasil yang diperoleh dari penelitian menunjukkan bahwa model deteksi kerusakan jalan berbasis CNN memiliki potensi besar untuk diterapkan dalam pemantauan infrastruktur jalan secara otomatis dan efisien, seperti yang juga dilaporkan oleh Aparna *et al.* (2019) dalam penelitian tentang deteksi lubang jalan menggunakan CNN. Sistem ini diharapkan dapat membantu instansi terkait dalam merespons kerusakan jalan dengan cepat, sehingga dapat meminimalisir dampak negatif terhadap keselamatan pengendara. Penelitian ini berhasil mengembangkan sistem deteksi kerusakan jalan yang dapat diterapkan menggunakan berbagai perangkat seperti kamera atau drone, yang sejalan dengan temuan dari Khairul Azmi (2023) tentang penerapan CNN dalam pengklasifikasian objek berbasis citra.

#### 4. Kesimpulan

Model yang dihasilkan telah dianggap layak digunakan karena hasil test identik dengan hasil training. Evaluasi kinerja model dilakukan dengan menilai beberapa metrik untuk mengetahui nilai presisi, *recall*, f1-score, dan akurasi. Presisi mengukur seberapa akurat prediksi nilai positif, *recall* mengukur kemampuan model untuk menemukan semua nilai positif yang sebenarnya, sedangkan f1-score adalah gambaran keseluruhan keseimbangan antara presisi dan recall. Model klasifikasi yang dihasilkan, penelitian ini telah sukses mengembangkan sistem deteksi jalan rusak menggunakan metode CNN. Model dengan kinerja terbaik bisa mencapai Tingkat akurasi sebesar 82%, presisi sebesar 85%, *recall* sebesar 83% dan f1-score sebesar 82%. Penelitian yang telah dilakukan berhasil membuat suatu model yang bisa membantu para pengguna jalan mengklasifikasi jalan rusak pada model penelitian dapat diterapkan menggunakan *drone* ataupun kamera untuk mendapat gambar jalan yang akan diklasifikasi.

#### 5. Daftar Pustaka

- Angulo, A., Vega-Fernández, J. A., Aguilar-Lobo, L. M., Natraj, S., & Ochoa-Ruiz, G. (2019). Road damage detection acquisition system based on deep neural networks for physical asset management. In *Advances in Soft Computing: 18th Mexican International Conference on Artificial Intelligence, MICAI 2019, Xalapa, Mexico, October 27–November 2, 2019, Proceedings 18* (pp. 3-14). Springer International Publishing.
- Azmi, K., Defit, S., & Sumijan, S. (2023). Implementasi convolutional neural network (CNN) untuk klasifikasi batik tanah liat sumatera barat. *Jurnal Unitek*, 16(1), 28-40.
- Bhatia, Y., Rai, R., Gupta, V., Aggarwal, N., & Akula, A. (2022). Convolutional neural networks based potholes detection using thermal imaging. *Journal of King Saud University-Computer and Information Sciences*, 34(3), 578-588.
- Budi, R., Harianto, R. A., & Setyati, E. (2023). Segmentasi Citra Area Tumpukan Sampah Dengan Memanfaatkan Mask R-CNN. *INSYST: Journal of Intelligent System and Computation*, 5(1), 58-64. <https://doi.org/10.52985/insyst.v5i1.305>.
- Dari, S. W., & Triloka, J. (2022, August). Kajian Algoritme Mask Region-Based Convolutional Neural Network (Mask R-CNN) dan You Look Only Once (YOLO) Untuk Deteksi Penyakit Kulit Akibat Infeksi Jamur. In *Prosiding Seminar Nasional Darmajaya* (Vol. 1, pp. 132-138).

Nugroho, P. A., Fenriana, I., & Arijanto, R. (2020). Implementasi deep learning menggunakan convolutional neural network (CNN) pada ekspresi manusia. *Algor*, 2(1), 12-20.

Qotrunnada, F. M., & Utomo, P. H. (2022, February). Metode Convolutional Neural Network untuk Klasifikasi Wajah Bermasker. In *PRISMA, Prosiding Seminar Nasional Matematika* (Vol. 5, pp. 799-807).

Rizal, F., Hasyim, F., Malik, K., & Yudistira, Y. (2021). Implementasi Algoritma Convolutional Neural Networks (CNN) Untuk Klasifikasi Batik. *COREAI: Jurnal Kecerdasan Buatan, Komputasi dan Teknologi Informasi*, 2(2), 40-47. <https://plu.mx/plum/a/?doi=10.33650/coreai.v2i2.3365>.

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>.

Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.

Wijaya, A. T., Putra, O. V., & Umami, J. (2021). Deteksi Jalan Berlubang Pada Citra Berkabut Menggunakan Convolutional Neural Network Dan Dark Channel Prior. *Prosiding Sains Nasional dan Teknologi*, 1(1). <http://dx.doi.org/10.36499/psnst.v1i1.5035>.

Wona, M. M. A., Asyifa, S. A., Virgianti, R., Hamid, M. N., Handoko, I. M., Septiani, N. W. P., & Lestari, M. (2023). Klasifikasi Batik Indonesia Menggunakan Convolutional Neural Network (CNN). *Jurnal Rekayasa Teknologi Informasi (JURTI)*, 7(2), 172-179.

Yulianto, Y., & Wibowo, A. (2023). Deteksi Keretakan Jalan Aspal Menggunakan Metode Convolutional Neural Network. *Power Syst*, 4(2), 581-594.