

Implementasi ResNet-50 untuk Identifikasi Jenis Kerusakan Pada Permukaan Jalan Raya

Ilham Khefi Ramadhanu¹, Wahyu Cahyo Utomo², Resty Wulanningrum³

¹⁻³Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: ¹ilhamkhefiramadhanu@gmail.com, ²wahyu.utomo@unpkdr.ac.id, ³restyw@unpkdr.ac.id

Abstrak – Kerusakan jalan seperti lubang dan retakan berdampak pada penurunan kenyamanan dan keselamatan, sementara inspeksi visual manual masih memerlukan waktu, biaya besar, dan berpotensi menghasilkan penilaian yang rentan mengalami kesalahan. Penelitian ini bertujuan mengklasifikasikan jenis kerusakan jalan menggunakan arsitektur ResNet-50 berbasis citra. Dataset didapat dari dokumentasi, RDD2022, Roboflow dan Mendeleet Data yang terbagi dalam empat kelas, yaitu lubang, retak melintang, retak memanjang, dan retak buaya. Data kemudian melalui tahapan pra-pemrosesan dan augmentasi diantaranya flip horizontal, shear, grayscale, dan penyesuaian brightness. Dataset dibagi menjadi 80% data pelatihan dan 20% data pengujian. Model ResNet-50 dilatih selama beberapa epoch menggunakan data hasil augmentasi, sedangkan kinerja model dievaluasi menggunakan metrik accuracy, precision, recall, dan f1-score. Hasil pengujian menunjukkan bahwa model memperoleh akurasi keseluruhan sebesar 92,04% dengan nilai precision, recall, dan f1-score tiap kelas berada pada kisaran 0,92–0,93. Hasil ini menunjukkan bahwa ResNet-50 mampu melakukan klasifikasi kerusakan jalan secara cukup akurat dan seimbang antar kelas. Dengan demikian, pendekatan ini berpotensi mendukung proses evaluasi kondisi jalan secara lebih objektif dan membantu pengambilan keputusan dalam perencanaan pemeliharaan jalan.

Kata Kunci — CNN, Computer Vision, Kerusakan Jalan, Pengolahan Citra, ResNet-50

1. PENDAHULUAN

Jalan merupakan salah satu kebutuhan vital dalam kehidupan masyarakat karena memiliki peran penting dalam memperlancar mobilitas dari satu titik ke titik lainnya. Selain berfungsi sebagai sarana transportasi darat yang menunjang aktivitas manusia dan distribusi barang [1], kualitas jalan yang baik juga meningkatkan koneksi antarwilayah. Infrastruktur jalan yang memadai dapat mendorong pertumbuhan sektor industri, perdagangan, maupun pariwisata karena arus logistik menjadi lebih efisien [2]. Namun demikian, kualitas jalan tidak selalu stabil dan sering mengalami penurunan akibat faktor lingkungan, kondisi cuaca ekstrem, beban kendaraan yang berlebih, serta kurangnya kegiatan pemeliharaan. Faktor-faktor yang dapat mengganggu kenyamanan serta keselamatan pengguna jalan tersebut mengakibatkan berbagai bentuk kerusakan seperti retakan dan lubang [3].

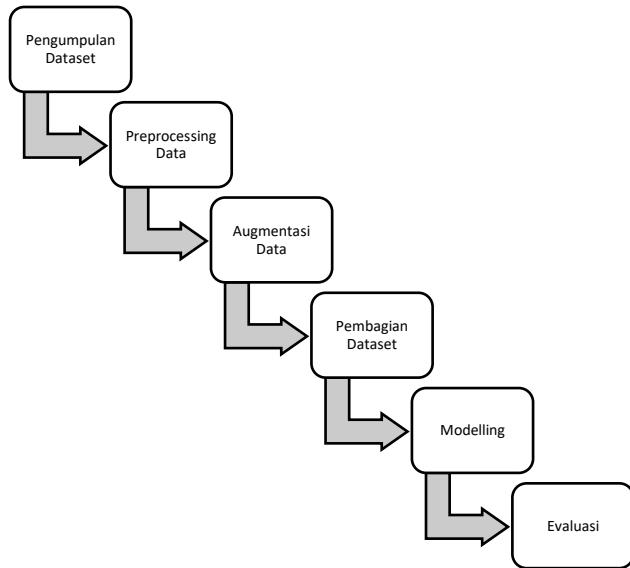
Retakan dan lubang ini merupakan jenis kerusakan jalan yang paling sering dijumpai di Indonesia. Data pada tahun 2024 menunjukkan bahwa sekitar 53,2% jalan masih berada dalam kondisi rusak [4], yang mencerminkan rendahnya kualitas infrastruktur jalan nasional. Kondisi ini tidak lepas dari lemahnya sistem pemantauan dan pelaporan kerusakan yang hingga kini masih banyak dilakukan secara manual. Praktik pelaporan konvensional tersebut membuat proses identifikasi kerusakan menjadi lambat, subjektif, dan rentan terhadap kesalahan [5]. Kondisi tersebut menegaskan perlunya pendekatan yang lebih modern dan otomatis dalam mendekripsi kerusakan jalan.

Permasalahan deteksi kerusakan jalan dapat diselesaikan dengan pendekatan modern salah satunya yaitu *computer vision* yang menawarkan alternatif solusi yang jauh lebih efisien [6]. *Computer vision* memungkinkan sistem komputer menganalisis dan memahami konten visual secara otomatis [7], sehingga dapat dimanfaatkan untuk mendekripsi kerusakan pada permukaan jalan tanpa intervensi manusia. Berbagai penelitian sebelumnya telah menunjukkan keberhasilan penggunaan *computer vision* dalam melakukan identifikasi kerusakan jalan secara otomatis, terutama melalui pemanfaatan CNN dengan arsitektur seperti ResNet-50. Beberapa studi bahkan melaporkan tingkat akurasi yang mencapai 99%, mengindikasikan potensi besar teknologi ini untuk digunakan dalam pemantauan infrastruktur jalan [8].

ResNet-50 menjadi salah satu arsitektur yang sangat potensial untuk klasifikasi kerusakan jalan karena kemampuannya mengekstraksi fitur visual secara mendalam dari citra permukaan [9]. Kemampuan ini membuat representasi fitur yang dihasilkan menjadi lebih kaya dan detail, sehingga meningkatkan kualitas prediksi model. Dengan demikian, penerapan ResNet-50 membuka peluang analisis kondisi jalan yang lebih objektif, terukur, dan konsisten.

2. METODE PENELITIAN

Pada penelitian ini digunakan sebuah pendekatan yang menyeluruh untuk menentukan jenis kerusakan jalan raya. Proses yang dilakukan meliputi beberapa tahapan utama, mulai dari pengumpulan data, pengolahan dan augmentasi citra, hingga penerapan model yang digunakan. Alur lengkap penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

2.1 Pengumpulan Dataset

Penelitian menggunakan dataset gambar kerusakan jalan yang bersumber dari data primer, RDD2022, Roboflow, dan Mendeley data sebanyak 800 gambar. Dengan rincian kelas yaitu melintang, memanjang, retak buaya, dan lubang.

2.2 *Preprocessing Data*

Dataset yang telah dikumpulkan selanjutnya dilakukan pra proses sebelum dianalisis lebih lanjut, yaitu pengaplikasian *AutoOrient* dan *Resize* atau mengubah ukuran citra dalam satuan pixel [10].

2.3 Augmentasi Data

Untuk meningkatkan kemampuan generalisasi model dan menekan kemungkinan terjadinya *overfitting*, pada proses pelatihan diterapkan teknik augmentasi data [11]. Setiap sampel data pelatihan dapat menghasilkan hingga tiga variasi citra baru melalui beberapa transformasi, antara lain *flip* horizontal yaitu pembalikan citra ke arah kiri dan kanan [12], *shear* horizontal dan vertikal, penerapan mode *grayscale*, serta pengaturan tingkat kecerahan. Kombinasi augmentasi tersebut digunakan untuk meniru berbagai kondisi di lapangan, sehingga model ResNet-50 menjadi lebih tahan terhadap perbedaan orientasi, pencahayaan, dan distorsi ringan pada citra kerusakan jalan.

2.4 Pembagian Dataset

Dataset pada penelitian ini dipisahkan menjadi dua bagian, yaitu data pelatihan dan data pengujian. Sekitar 80% dari keseluruhan data digunakan sebagai data training untuk membangun dan melatih model, sedangkan sisanya 20% dimanfaatkan sebagai data testing untuk menguji kinerja model.

2.5 *Modelling*

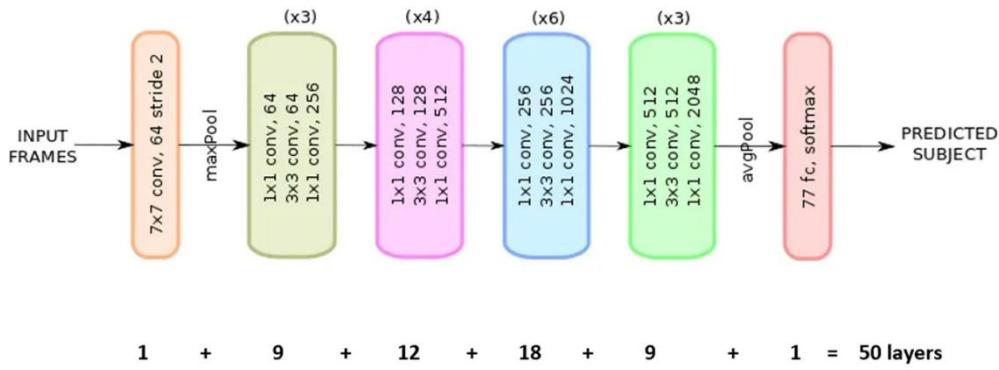
Pada penelitian ini, arsitektur CNN yang digunakan adalah ResNet-50 (*Residual Network 50-layer*). ResNet-50 merupakan salah satu model deep learning berbasis residual learning yang terdiri dari 50 lapis jaringan dengan blok residual yang dirancang untuk mengatasi masalah *vanishing gradient* pada jaringan yang sangat dalam [13]. Melalui penggunaan *skip connection* pada setiap blok residual, ResNet-50 mampu mengekstraksi fitur citra secara lebih efektif dan stabil, sehingga banyak digunakan untuk tugas klasifikasi citra, termasuk dalam konteks identifikasi dan klasifikasi jenis kerusakan jalan.

Persamaan matematis untuk blok residual adalah:

Keterangan:

- 1) x adalah input ke blok.
 - 2) $F(x, \{W_i\})$ adalah fungsi pemetaan residual yang dipelajari oleh dua atau tiga lapisan konvolusional di dalam blok.
 - 3) y adalah output akhir blok.

Dengan rincian lapisan arsitektur seperti pada:



Gambar 2. Arsitektur ResNet-50

(Sumber Gambar: <https://www.ultralytics.com/blog/what-is-resnet-50-and-what-is-its-relevance-in-computer-vision>)

2.6 Evaluasi

Untuk menilai tingkat keberhasilan kinerja sistem yang menggunakan model ResNet-50 dalam mengklasifikasikan jenis kerusakan jalan, digunakan beberapa metrik evaluasi, antara lain Accuracy, Precision, Recall, F1-Score, serta Confusion Matrix [14]. Metrik-metrik tersebut memberikan gambaran seberapa baik model dalam mengenali setiap kelas kerusakan, baik secara keseluruhan maupun per kelas [15].

Confusion matrix merupakan sebuah tabel yang menggambarkan jumlah data uji yang diprediksi benar dan salah oleh model untuk masing-masing kelas [16]. Pada penelitian ini, model ResNet-50 digunakan untuk mengklasifikasikan empat kelas kerusakan jalan, yaitu lubang, retak melintang, retak memanjang, dan retak buaya, sehingga confusion matrix yang dihasilkan berbentuk tabel 4×4 . Setiap baris pada confusion matrix merepresentasikan kelas sebenarnya (*actual label*), sedangkan setiap kolom menunjukkan kelas hasil prediksi model (*predicted label*). Nilai diagonal utama pada confusion matrix menunjukkan jumlah prediksi yang benar untuk setiap kelas, sedangkan nilai di luar diagonal menunjukkan kesalahan klasifikasi. Adapun contoh confusion matrix adalah sebagai berikut:

Tabel 1. Confusion Matrix

| Class | Aktual Positif | Aktual Negatif |
|------------------|---------------------|---------------------|
| Prediksi Positif | TP (True Positive) | TN (True Negative) |
| Prediksi Negatif | FP (False Positive) | FN (False Negative) |

Dalam Tabel 1. terdapat empat komponen penting pada confusion matrix, yaitu True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Dengan rincian penjelasan sebagai berikut:

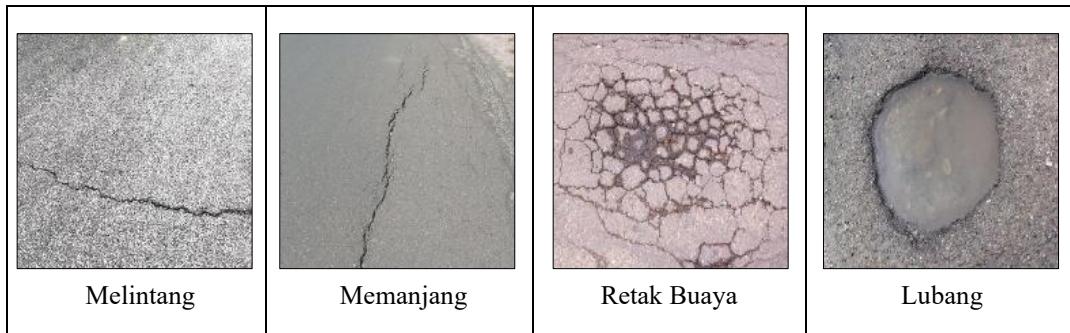
- 1) True Positive (TP)
Jumlah kasus ketika model memprediksi suatu kelas dengan benar sesuai label aslinya.
 - 2) True Negative (TN)
Jumlah kasus ketika model dengan tepat memprediksi bahwa suatu sampel tidak termasuk ke dalam kelas tertentu.
 - 3) False Positive (FP)
Kondisi ketika model memprediksi suatu sampel sebagai kelas tertentu padahal sebenarnya bukan.
 - 4) False Negative (FN)
Kondisi ketika model gagal memprediksi suatu sampel sebagai kelas tertentu meskipun sebenarnya sampel tersebut merupakan bagian dari kelas tersebut.

Keempat komponen ini menjadi dasar dalam perhitungan precision, recall, dan f1-score, sehingga sangat penting untuk memahami bagaimana model bekerja dalam membedakan setiap kelas kerusakan jalan.

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Dataset

Penelitian ini menggunakan dataset citra kerusakan jalan sebanyak 800 gambar yang berasal dari beberapa sumber, yaitu data primer hasil dokumentasi langsung di lapangan, serta dataset sekunder dari RDD2022, Roboflow, dan Mendeley Data. Penggabungan beberapa sumber ini bertujuan untuk mendapatkan variasi kondisi kerusakan jalan yang lebih beragam, baik dari segi tekstur permukaan, pencahayaan, sudut pengambilan gambar, maupun lingkungan sekitar, sehingga model yang dibangun diharapkan memiliki kemampuan generalisasi yang lebih baik terhadap berbagai kondisi nyata di lapangan.



Gambar 3. Sampel dataset tiap kelas

Dataset tersebut diklasifikasikan ke dalam empat jenis kerusakan jalan, yaitu melintang, memanjang, retak buaya, dan lubang seperti pada Gambar 3. Secara rinci, jumlah citra pada masing-masing kelas adalah 200 gambar untuk kelas lubang, 200 gambar untuk kelas retak melintang, 200 gambar untuk kelas retak memanjang, dan 200 gambar untuk kelas retak buaya. Pembagian kelas ini disusun agar mewakili ragam bentuk kerusakan yang umum ditemukan pada perkerasan jalan, dan sekaligus digunakan sebagai dasar pelabelan data dalam proses pelatihan dan pengujian model klasifikasi kerusakan jalan.

3.2 Preprocessing Data

Dataset yang telah dikumpulkan selanjutnya melalui tahap pra-pemrosesan (*preprocessing*) sebelum dianalisis lebih lanjut. Pada tahap ini, dilakukan pengaplikasian *AutoOrient* untuk menyesuaikan orientasi citra secara otomatis sesuai metadata, sehingga arah gambar menjadi konsisten dan tidak terbalik atau miring. Setelah itu, dilakukan proses *resize* atau pengubahan ukuran citra dalam satuan piksel ke resolusi tertentu agar seragam, sehingga memudahkan proses pelatihan model dan mengurangi beban komputasi tanpa menghilangkan informasi penting pada citra kerusakan jalan.

3.3 Augmentasi Data

Dalam penelitian ini diterapkan teknik augmentasi data untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko *overfitting*. Augmentasi data dilakukan dengan cara menghasilkan hingga tiga variasi citra baru dari setiap sampel data pelatihan (*outputs per training example*: 3). Dengan demikian, model tidak hanya belajar dari citra asli, tetapi juga dari berbagai versi citra yang telah mengalami transformasi, sehingga lebih siap menghadapi variasi kondisi nyata di lapangan saat digunakan untuk mengenali kerusakan jalan.

Beberapa jenis transformasi yang digunakan antara lain *flip horizontal*, *shear*, *grayscale*, dan penyesuaian *brightness*. Transformasi *flip horizontal* membalik citra ke arah kiri dan kanan sehingga membantu model menjadi lebih *robust* terhadap perbedaan orientasi pengambilan gambar. Transformasi *shear* diterapkan secara horizontal dan vertikal hingga $\pm 10^\circ$, yang mensimulasikan distorsi perspektif ringan akibat sudut pengambilan foto yang berbeda, namun tetap menjaga bentuk kerusakan agar tidak tampak terlalu terdistorsi dan masih realistik.

Selain itu, sebagian citra (sekitar 18%) diubah menjadi *grayscale* untuk mendorong model lebih peka terhadap tekstur dan kontras permukaan jalan, bukan hanya informasi warna. Penyesuaian *brightness* dilakukan dalam rentang -15% hingga $+15\%$ untuk meniru variasi pencahayaan, seperti kondisi terang, teduh, maupun sedikit gelap. Kombinasi berbagai augmentasi ini membantu model ResNet-50 menjadi lebih tahan terhadap perubahan orientasi, pencahayaan, dan distorsi ringan, sehingga diharapkan mampu memberikan performa klasifikasi kerusakan jalan yang lebih stabil pada kondisi data yang beragam.

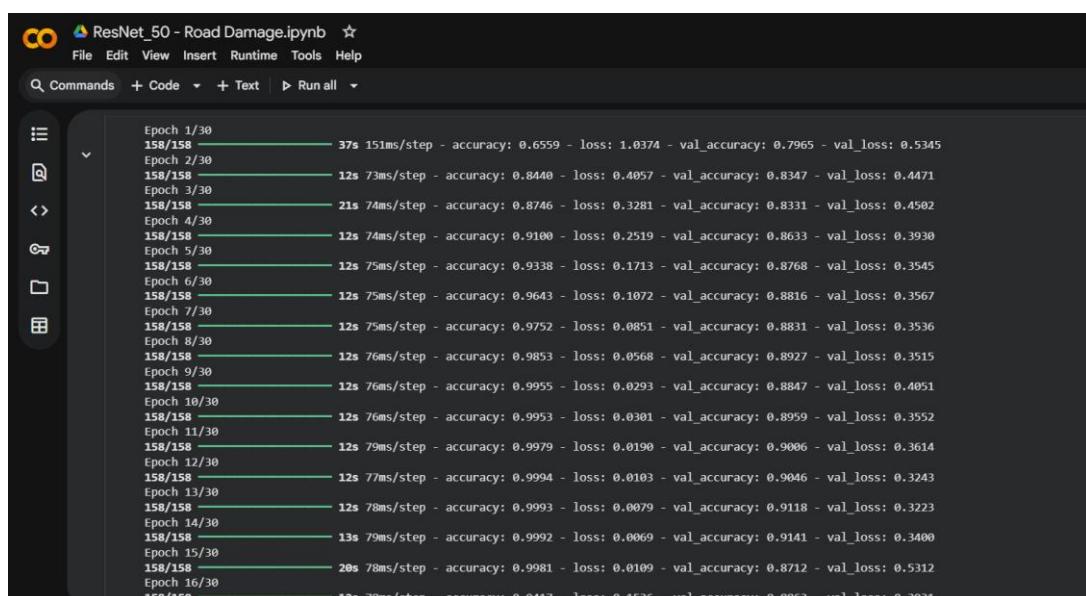
3.4 Pembagian Dataset

Dataset pada penelitian ini dibagi menjadi dua kelompok utama, yaitu data pelatihan dan data pengujian dengan proporsi 80:20. Setelah melalui proses augmentasi, 80% dataset digunakan sebagai data *training*. Data pelatihan ini dimanfaatkan untuk membangun dan melatih model sehingga mampu mempelajari pola, tekstur, dan karakteristik visual dari masing-masing kelas kerusakan jalan yang dianalisis. Penambahan jumlah data melalui augmentasi membuat variasi citra yang dilihat model menjadi lebih beragam, sehingga diharapkan kemampuan model dalam mengenali kerusakan pada berbagai kondisi nyata dapat meningkat.

Sementara itu, 20% data dialokasikan sebagai data *testing* yang digunakan untuk menguji kinerja model setelah proses pelatihan selesai. Data pengujian ini tidak dilibatkan dalam proses pembelajaran maupun augmentasi, sehingga dapat memberikan gambaran yang lebih objektif terhadap kemampuan generalisasi model ketika dihadapkan pada data baru. Melalui pengujian ini, berbagai metrik evaluasi seperti akurasi, precision, dan recall dapat dihitung untuk menilai sejauh mana model berhasil mengklasifikasikan jenis kerusakan jalan dengan tepat.

3.5 Modelling

Pelatihan model dilakukan menggunakan arsitektur ResNet-50 dengan memanfaatkan dataset kerusakan jalan yang sebelumnya telah dikumpulkan dan melalui tahap pra-pemrosesan di platform Roboflow, seperti pengaturan anotasi, pengubahan ukuran (*resize*), serta penyiapan format dataset agar siap digunakan dalam proses pelatihan. Setelah dataset selesai diproses dan diekspor dari Roboflow, proses training model dilakukan di lingkungan Google Colab dengan memanfaatkan fasilitas komputasi berbasis GPU untuk mempercepat proses pembelajaran.

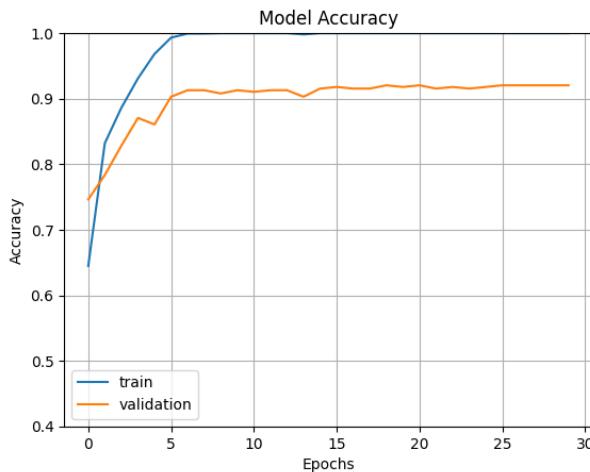


```
Epoch 1/30
158/158 37s 151ms/step - accuracy: 0.6559 - loss: 1.0374 - val_accuracy: 0.7965 - val_loss: 0.5345
Epoch 2/30
158/158 12s 73ms/step - accuracy: 0.8440 - loss: 0.4057 - val_accuracy: 0.8347 - val_loss: 0.4471
Epoch 3/30
158/158 21s 74ms/step - accuracy: 0.8746 - loss: 0.3281 - val_accuracy: 0.8331 - val_loss: 0.4502
Epoch 4/30
158/158 12s 74ms/step - accuracy: 0.9100 - loss: 0.2519 - val_accuracy: 0.8633 - val_loss: 0.3930
Epoch 5/30
158/158 12s 75ms/step - accuracy: 0.9338 - loss: 0.1713 - val_accuracy: 0.8768 - val_loss: 0.3545
Epoch 6/30
158/158 12s 75ms/step - accuracy: 0.9643 - loss: 0.1072 - val_accuracy: 0.8816 - val_loss: 0.3567
Epoch 7/30
158/158 12s 75ms/step - accuracy: 0.9752 - loss: 0.0851 - val_accuracy: 0.8831 - val_loss: 0.3536
Epoch 8/30
158/158 12s 76ms/step - accuracy: 0.9853 - loss: 0.0568 - val_accuracy: 0.8927 - val_loss: 0.3515
Epoch 9/30
158/158 12s 76ms/step - accuracy: 0.9955 - loss: 0.0293 - val_accuracy: 0.8847 - val_loss: 0.4051
Epoch 10/30
158/158 12s 76ms/step - accuracy: 0.9953 - loss: 0.0301 - val_accuracy: 0.8959 - val_loss: 0.3552
Epoch 11/30
158/158 12s 79ms/step - accuracy: 0.9979 - loss: 0.0190 - val_accuracy: 0.9006 - val_loss: 0.3614
Epoch 12/30
158/158 12s 77ms/step - accuracy: 0.9994 - loss: 0.0103 - val_accuracy: 0.9046 - val_loss: 0.3243
Epoch 13/30
158/158 12s 78ms/step - accuracy: 0.9993 - loss: 0.0079 - val_accuracy: 0.9118 - val_loss: 0.3223
Epoch 14/30
158/158 13s 79ms/step - accuracy: 0.9992 - loss: 0.0069 - val_accuracy: 0.9141 - val_loss: 0.3400
Epoch 15/30
158/158 20s 78ms/step - accuracy: 0.9981 - loss: 0.0109 - val_accuracy: 0.8712 - val_loss: 0.5312
Epoch 16/30
158/158 12s 78ms/step - accuracy: 0.9417 - loss: 0.1536 - val_accuracy: 0.8863 - val_loss: 0.3931
```

Gambar 4. Proses Pelatihan Model

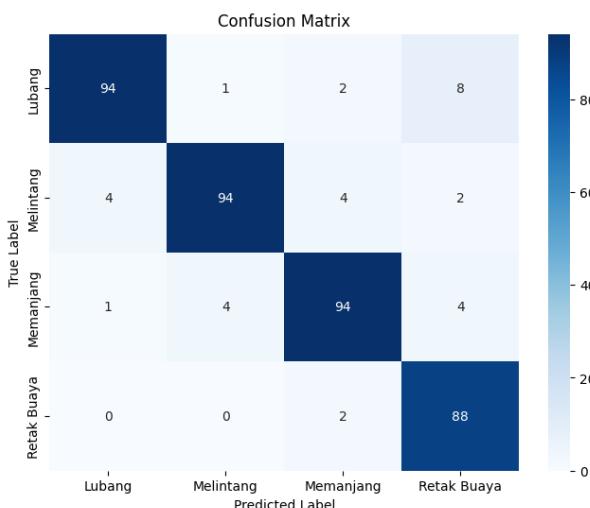
3.6 Evaluasi

Model ResNet-50 dilatih selama 30 epoch menggunakan dataset yang telah disiapkan. Dari hasil pelatihan selama 6.42 menit, model berhasil mencapai nilai akurasi sebesar 0.9204 atau sekitar 92,04%, yang menunjukkan bahwa model memiliki kemampuan yang cukup baik dalam mengenali dan mengklasifikasikan jenis kerusakan jalan berdasarkan citra yang digunakan dalam penelitian ini.



Gambar 5. Grafik Akurasi

Berdasarkan Gambar 5. grafik akurasi, terlihat bahwa nilai akurasi pelatihan mengalami peningkatan yang sangat cepat pada epoch-epoch awal dan mencapai hampir 100% sekitar epoch ke-5 hingga ke-10. Setelah itu, akurasinya cenderung stabil dan tidak menunjukkan perubahan signifikan pada epoch berikutnya. Sementara itu, akurasi validasi juga memperlihatkan tren meningkat dari kisaran 75–80% pada awal pelatihan hingga mencapai sekitar 91–92% pada epoch akhir. Stabilitas akurasi validasi pada rentang tersebut menunjukkan bahwa model ResNet-50 tidak hanya mampu mempelajari pola data pelatihan dengan sangat baik, tetapi juga memiliki kemampuan generalisasi yang cukup baik terhadap data validasi. Hal ini ditunjukkan oleh nilai akurasi validasi yang tinggi dan relatif konsisten hingga akhir proses pelatihan tanpa penurunan drastis yang menandakan *overfitting* berat.



Gambar 6. Confusion Matrix

Berdasarkan Gambar 3, peneliti akan mengevaluasi performa model dengan beberapa metrik evaluasi, antara lain Precision, Recall, F1-Score untuk memberikan gambaran seberapa baik model dalam mengenali setiap kelas kerusakan, baik secara keseluruhan maupun per kelas.

Tabel 2. *Classification Report*

| Class | precision | recall | f1-score |
|--------------------|-----------|--------|----------|
| Lubang | 0.95 | 0.90 | 0.92 |
| Melintang | 0.95 | 0.90 | 0.93 |
| Memanjang | 0.92 | 0.91 | 0.92 |
| Retak Buaya | 0.86 | 0.98 | 0.92 |

Accuracy: 0.9204

Berdasarkan hasil evaluasi yang disajikan pada tabel, model ResNet-50 berhasil mencapai akurasi keseluruhan sebesar 0,9204 (92,04%), yang menunjukkan bahwa model memiliki kemampuan yang baik dalam melakukan klasifikasi empat jenis kerusakan jalan. Nilai akurasi ini mencerminkan bahwa secara umum model

mampu mempelajari pola visual pada data dengan cukup efektif sehingga dapat menghasilkan prediksi yang konsisten pada data uji. Kinerja ini menunjukkan bahwa model memiliki kemampuan generalisasi yang memadai terhadap variasi citra kerusakan jalan.

Jika ditinjau lebih rinci berdasarkan setiap kelas, nilai precision, recall, dan f1-score berada dalam rentang yang relatif tinggi, yaitu 0,86 hingga 0,98. Pada kelas Lubang, model memperoleh precision 0,95 dan recall 0,90, sementara kelas Melintang menunjukkan performa serupa dengan precision 0,95 dan recall 0,90. Kelas Memanjang juga menunjukkan keseimbangan yang baik antara ketepatan dan keberhasilan deteksi dengan precision 0,92 dan recall 0,91. Hal ini mengindikasikan bahwa model mampu mengidentifikasi sebagian besar sampel dari ketiga kelas tersebut dengan tingkat kesalahan prediksi yang rendah.

Sementara itu, kelas Retak Buaya menunjukkan karakteristik yang sedikit berbeda, dimana recall sangat tinggi (0,98) namun precision lebih rendah (0,86). Ini menandakan hampir semua citra Retak Buaya berhasil terdeteksi oleh model, meskipun beberapa prediksi yang dihasilkan masih keliru. Meskipun demikian, nilai f1-score yang tetap tinggi (0,92) menunjukkan bahwa performa keseluruhan pada kelas ini tetap baik. Secara umum, kombinasi nilai evaluasi pada seluruh kelas memperlihatkan bahwa model ResNet-50 bekerja secara konsisten dan efektif dalam mengklasifikasikan berbagai jenis kerusakan jalan.

4. SIMPULAN

Berdasarkan seluruh rangkaian proses yang telah dilakukan, mulai dari pengumpulan dataset, pra-pemrosesan citra, augmentasi data, pembagian data pelatihan dan pengujian, hingga pelatihan dan evaluasi model, dapat ditarik beberapa kesimpulan sebagai berikut.

1. Penelitian ini berhasil merancang sebuah model klasifikasi kerusakan jalan berbasis arsitektur ResNet-50 yang mampu membedakan empat kategori kerusakan, yaitu lubang, retak melintang, retak memanjang, dan retak buaya. Dataset awal berjumlah 800 citra yang kemudian melalui proses pra-pemrosesan dan augmentasi. Langkah ini memperkaya variasi data yang tersedia dan membantu model dalam mempelajari tekstur serta bentuk kerusakan secara lebih mendalam.
2. Skema pembagian data dengan komposisi 80% sebagai data pelatihan dan 20% sebagai data pengujian, disertai penerapan teknik augmentasi (*flip horizontal, shear, grayscale*, dan penyesuaian *brightness*), terbukti berkontribusi pada peningkatan kemampuan generalisasi model. Hasil pelatihan menunjukkan kurva akurasi yang cenderung stabil, di mana akurasi pelatihan meningkat hingga hampir mencapai 100%, sementara akurasi validasi berada pada kisaran 92–93%. Hal ini menunjukkan bahwa model ResNet-50 tidak hanya mampu mempelajari pola dari data pelatihan, tetapi juga memberikan performa yang baik ketika diuji menggunakan data yang belum pernah dilihat sebelumnya.
3. Dari hasil evaluasi menggunakan metrik accuracy, precision, recall, dan f1-score, model ResNet-50 yang dikembangkan memperoleh akurasi keseluruhan sekitar 92,04%. Nilai precision, recall, dan f1-score untuk setiap kelas berada pada kisaran 0,86 hingga 0,98, yang mengindikasikan bahwa model mampu melakukan klasifikasi terhadap masing-masing jenis kerusakan jalan dengan performa yang cukup baik dan relatif seimbang antar kelas. Secara keseluruhan, dapat disimpulkan bahwa arsitektur ResNet-50 layak dan efektif digunakan sebagai model klasifikasi kerusakan jalan berbasis citra pada penelitian ini.

5. SARAN

Berdasarkan hasil penelitian yang telah diperoleh, beberapa saran yang dapat diajukan untuk pengembangan ke depan antara lain perlu dilakukan penambahan dan perluasan dataset, baik dari sisi jumlah maupun variasi kondisi lapangan (lokasi, cuaca, waktu pengambilan, dan jenis perkerasan) agar kemampuan generalisasi model ResNet-50 semakin meningkat, menambahkan kelas-kelas kerusakan lain serta pelabelan yang lebih rinci untuk memperoleh gambaran kondisi jalan yang lebih komprehensif, melakukan eksplorasi arsitektur model lain dan pengujian berbagai kombinasi *hyperparameter* serta skema augmentasi guna mendapatkan konfigurasi model yang lebih optimal, serta melaksanakan analisis kesalahan (*error analysis*) secara lebih mendalam terhadap citra yang salah klasifikasi sebagai dasar perbaikan dataset dan model pada penelitian selanjutnya.

DAFTAR PUSTAKA

- [1] A. Syafiq, M. Zuhri, N. Nafiiyah, and A. Setia Budi, “IDENTIFICATION OF ROAD DAMAGE USING THE CONVOLUTIONAL NEURAL NETWORK (CNN) METHOD,” *J. Ilm. Sist. Inf.*, vol. 4, no. 3, pp. 802–817, Nov. 2025, doi: 10.51903/JGN2SD35.
- [2] M. Jannah and E. Kurniati, “ANALISIS PERAN PEMERINTAH DAERAH TERHADAP PEMBANGUNAN INFRASTRUKTUR SEBAGAI UPAYA MENDORONG PERTUMBUHAN EKONOMI DI PROVINSI LAMPUNG,” *J. Ilmu Ekon.*, vol. 4, no. 1, pp. 231–251, Apr. 2025, doi: 10.59827/JIE.V4I1.220.
- [3] R. A. Gumelar, A. Susetyaningsih, and M. B. Zaman, “Pengaruh Kerusakan Jalan Terhadap Kenyamanan Pengguna Jalan di Jalan Raya,” *J. Konstr.*, vol. 21, no. 2, pp. 265–274, Oct. 2023, doi: 10.33364/KONSTRUKSI/V.21-2.1416.
- [4] P. D. dan T. I. K. P. Umum, “Kondisi Permukaan Jalan Nasional Tahun 2024 - Kondisi Permukaan Jalan Nasional | Open Data PU.” Accessed: Nov. 10, 2025. [Online]. Available: <https://data.pu.go.id/dataset/kondisi-permukaan-jalan-nasional/resource/bac96332-e8d7-41d0-8d2c-55474bb06b68#%7Bview-graph:%7BgraphOptions:%7Bhooks:%7BprocessOffset:%7B%7D,bindEvents:%7B%7D%7D%7D%7D,graphOptions:%7Bhooks:%7BprocessOffset:%7B%7D,bindEvents>
- [5] H. Saparudin, M. A. Ramdi, and F. S. Alfarizi, “Implementasi Convolutional Neural Network dan ResNet-18 untuk Klasifikasi Kerusakan Jalan Berbasis Citra,” 2025. [Online]. Available: <https://journal.aptika.org/index.php/japtika>
- [6] F. T. Anggraeny, B. Rahmat, and S. P. Pratama, “Deteksi Ikan Dengan Menggunakan Algoritma Histogram of Oriented Gradients,” *Inform. Mulawarman J. Ilm. Ilmu Komput.*, vol. 15, no. 2, p. 114, Sep. 2020, doi: 10.30872/JIM.V15I2.4648.
- [7] T. A. Dompeipen, S. R. U. A. Sompie, and M. E. . Najoan, “Computer Vision Implementation for Detection and Counting the Number of Humans,” *J. Tek. Inform.*, vol. 16, no. 1, pp. 65–76, Mar. 2021, doi: 10.35793/JTI.V16I1.31471.
- [8] M. A. Ghofur and A. B. Ulum, “Analisis Perbandingan Kinerja Model ResNet50 Dan EfficientNet-B0 Dalam Klasifikasi Kerusakan Jalan,” *J. Media Inform.*, vol. 6, no. 5, pp. 2504–2511, Sep. 2025, doi: 10.55338/JUMIN.V6I5.6843.
- [9] T. Berliani, E. Rahardja, and L. Septiana, “Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16,” *J. Med. Heal.*, vol. 5, no. 2, pp. 123–135, Aug. 2023, doi: 10.28932/JMH.V5I2.6116.
- [10] R. Indah Juwita Harahap, S. Khairani, and corespondent author, “Implementasi Metode K-Nearest Neighbor Untuk Klasifikasi Penyakit Tanaman Mentimun Pada Citra Daun,” *J. Ilmu Komput. dan Sist. Inf.*, vol. 3, no. 2, pp. 135–145, May 2024, doi: 10.70340/JIRSI.V3I2.123.
- [11] S. Samidin and A. Fadjeri, “Klasifikasi Gambar Batu-Kertas-Gunting Menggunakan Convolutional Neural Network dengan Fungsi Callback untuk Mencegah Overfitting,” *J. Penelit. Inov.*, vol. 4, no. 2, pp. 785–794, Jun. 2024, doi: 10.54082/JUPIN.413.
- [12] D. Husen, “EVALUASI TEKNIK AUGMENTASI DATA UNTUK KLASIFIKASI TUMOR OTAK MENGGUNAKAN CNN PADA CITRA MRI,” *Tek. Teknol. Inf. dan Multimed.*, vol. 5, no. 2, pp. 219-227–219 – 227, Dec. 2024, doi: 10.46764/TEKNIMEDIA.V5I2.220.
- [13] L. Zhang, Y. Bian, P. Jiang, and F. Zhang, “A Transfer Residual Neural Network Based on ResNet-50 for Detection of Steel Surface Defects,” *Appl. Sci. 2023, Vol. 13, Page 5260*, vol. 13, no. 9, p. 5260, Apr. 2023, doi: 10.3390/APP13095260.
- [14] F. Wu and H. Lin, “Effect of transfer learning on the performance of VGGNet-16 and ResNet-50 for the classification of organic and residual waste,” *Front. Environ. Sci.*, vol. 10, p. 1043843, Oct. 2022, doi: 10.3389/FENVS.2022.1043843/BIBTEX.
- [15] F. I. Rahman, L. Lukman, and H. Hildayati, “Sistem Klasifikasi Kerusakan Jalan Metode Machine Learning dengan Algoritma K-Means dan Random Forest,” *Arus J. Sains dan Teknol.*, vol. 3, no. 1, pp. 116–126, Jun. 2025, doi: 10.57250/AJST.V3I1.1212.
- [16] I. Fatahna, P. D. K. Sari, A. N. Kamilah, R. Wulanningrum, and W. C. Utomo, “Implementasi Computer Vision Terhadap Jenis Kualitas Pisang Susu Menggunakan Metode YOLOv8n Berbasis WebApps,” *Semin. Nas. Teknol. Sains*, vol. 4, no. 1, pp. 1–10, Jan. 2025, doi: 10.29407/9EZQF773.