

Analisis Perbandingan Kinerja Model *ResNet50* Dan *EfficientNet-B0* Dalam Klasifikasi Kerusakan Jalan

Muhammad Abdul Ghofur^{1*}, Ahmad Bahrul Ulum²

^{1,2}Magister Informatika, UIN Sunan Kalijaga Yogyakarta, Indonesia

Email: ¹23206052012@student.uin-suka.ac.id, ²23206052008@student.uin-suka.ac.id

Email Penulis Korespondensi: ¹23206052012@student.uin-suka.ac.id

Abstrak—Kerusakan jalan memiliki dampak signifikan terhadap aspek keselamatan, kenyamanan, dan kelancaran transportasi. Namun, identifikasi kerusakan secara manual membutuhkan waktu, tenaga, serta sumber daya yang besar. Penelitian ini bertujuan mengembangkan sistem klasifikasi otomatis tingkat kerusakan jalan berbasis pengolahan citra digital dengan membandingkan kinerja dua arsitektur Convolutional Neural Network (CNN) pretrained, yaitu *ResNet50* dan *EfficientNet-B0*. Dataset penelitian terdiri atas 1.800 citra permukaan jalan yang terbagi secara seimbang ke dalam tiga kategori, yaitu jalan baik, rusak ringan, dan rusak berat. Seluruh citra melalui tahap praproses berupa normalisasi dan penyesuaian ukuran agar sesuai dengan masukan model. Selanjutnya, metode transfer learning diterapkan pada model pretrained untuk memanfaatkan pengetahuan awal dari dataset berskala besar, sedangkan evaluasi kinerja dilakukan menggunakan K-Fold Cross Validation (K=5) guna meningkatkan reliabilitas serta mengurangi potensi bias. Hasil penelitian menunjukkan bahwa *ResNet50* dan *EfficientNet-B0* mampu mencapai akurasi hingga 99% dengan nilai *Precision* dan *F1-Score* yang tinggi. Temuan ini menegaskan keunggulan model pretrained dalam klasifikasi citra kerusakan jalan, sehingga *ResNet50* dan *EfficientNet-B0* direkomendasikan untuk pengembangan sistem deteksi kerusakan jalan secara real-time yang efisien serta dapat diintegrasikan ke dalam sistem monitoring infrastruktur berbasis teknologi cerdas.

Kata kunci: *EfficientNet-B0*, K-Fold Cross Validation, *ResNet50*,

Abstract—Road damage has a significant impact on safety, comfort, and transportation efficiency. However, manual identification of road conditions requires considerable time, effort, and resources. This study aims to develop an automatic road damage severity classification system based on digital image processing by comparing the performance of two pretrained Convolutional Neural Network (CNN) architectures, namely ResNet50 and EfficientNet-B0. The dataset consists of 1,800 road surface images evenly distributed into three categories: good, minor damage, and severe damage. All images underwent preprocessing, including normalization and resizing, to match the input requirements of the models. Transfer learning was applied to the pretrained architectures to leverage prior knowledge from large-scale datasets, while model performance was evaluated using K-Fold Cross Validation (K=5) to enhance reliability and reduce potential bias. The results demonstrate that both ResNet50 and EfficientNet-B0 achieved Accuracy of up to 99%, along with high Precision and F1-Score values. These findings highlight the effectiveness of pretrained models in classifying road damage images, suggesting that ResNet50 and EfficientNet-B0 are highly recommended for the development of efficient real-time road damage detection systems that can be integrated into smart infrastructure monitoring technologies.

Keywords: EfficientNet-B0, K-Fold Cross Validation, ResNet50

1. PENDAHULUAN

Jalan umum merupakan fasilitas publik yang harus dimanfaatkan sebesar-besarnya untuk kepentingan rakyat. Berdasarkan Undang-Undang Nomor 38 Tahun 2004 tentang Jalan, Pasal 4 menyatakan bahwa pemerintah berkewajiban mengelola jalan guna mewujudkan efisiensi biaya transportasi sehingga dapat mendorong pertumbuhan ekonomi nasional [1]. Infrastruktur jalan merupakan elemen krusial dalam mendukung mobilitas dan pertumbuhan ekonomi di Indonesia. Kerusakan jalan, seperti retakan, lubang, atau permukaan yang tidak rata, mengganggu kelancaran transportasi, memperbesar potensi kecelakaan, dan menyebabkan kerugian ekonomi di kota besar dan daerah pedesaan [2]. Menurut Kementerian Pekerjaan Umum dan Perumahan Rakyat [3], sekitar 25% dari 47.000 kilometer jalan nasional dan 53% dari 50.000 kilometer jalan provinsi mengalami kerusakan ringan hingga berat, yang mengakibatkan kerugian ekonomi mencapai sekitar Rp15 triliun (~USD 1 miliar) per tahun akibat penurunan efisiensi logistik dan peningkatan biaya perawatan kendaraan. Faktor seperti beban lalu lintas berlebih, curah hujan tinggi, dan kurangnya pemeliharaan rutin memperburuk kondisi ini [4].

Oleh karena itu, metode yang akurat dan optimal secara komputasi diperlukan untuk mendeteksi serta mengklasifikasikan kerusakan jalan guna mendukung perawatan infrastruktur. Identifikasi manual memiliki keterbatasan, seperti subjektivitas petugas, keterbatasan cakupan area, serta tingginya biaya dan waktu. Oleh karena itu, pendekatan otomatis berbasis pengolahan citra dan kecerdasan buatan diperlukan untuk meningkatkan efektivitas deteksi kerusakan jalan.

Seiring kemajuan kecerdasan buatan perkembangan teknologi deep learning, khususnya pada bidang image classification dengan *Convolutional Neural Networks* (CNN), membuka peluang besar untuk menyelesaikan

permasalahan tersebut. CNN mampu mengenali dan membedakan pola visual dari citra kerusakan jalan dengan *Accuracy* tinggi, bahkan dalam kondisi pencahayaan dan sudut pandang yang bervariasi. Beberapa arsitektur CNN yang telah terbukti efektif dalam tugas klasifikasi visual adalah *CNN Custom*, *ResNet50*, *MobileNetV2*, dan *EfficientNet-B0*.

Model *ResNet50* dikenal luas karena kemampuannya dalam mengatasi degradasi *Accuracy* pada jaringan dalam melalui teknik residual learning. Sementara itu, *MobileNetV2* dirancang khusus untuk perangkat dengan sumber daya terbatas, seperti sistem pemantauan bergerak, dengan tetap mempertahankan performa klasifikasi yang baik. Di sisi lain, *EfficientNet-B0* merupakan arsitektur modern yang secara sistematis mengatur skala kedalaman, lebar, dan resolusi input untuk mencapai keseimbangan antara *Accuracy* tinggi dan efisiensi komputasi [5]. Efisiensinya menjadikannya cocok untuk penerapan dalam sistem inspeksi real-time.

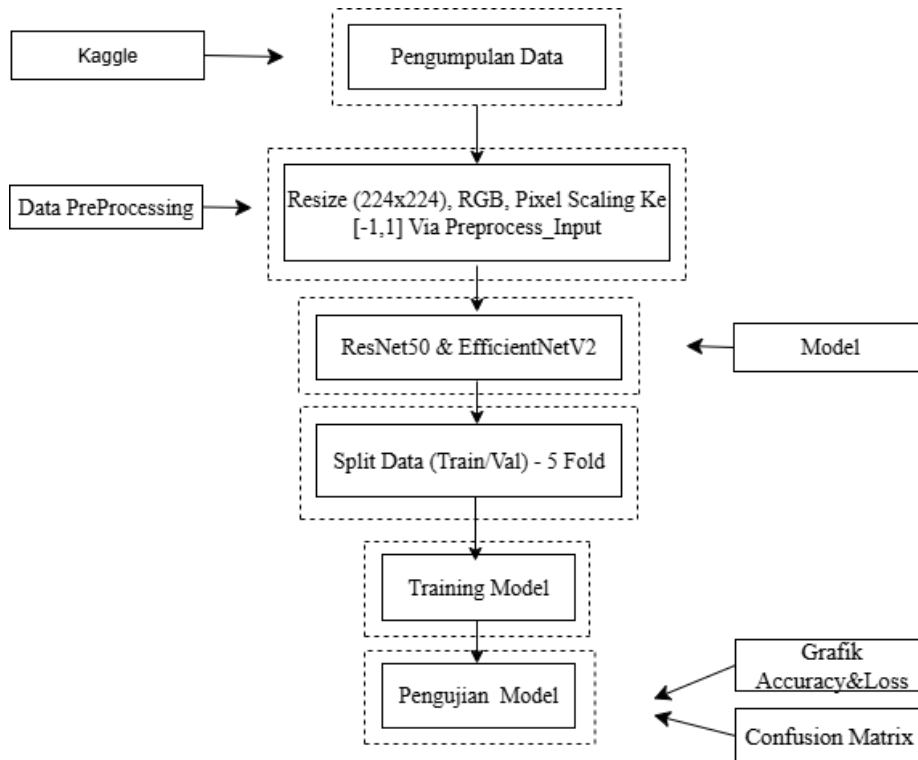
Beberapa penelitian sebelumnya telah menunjukkan hasil yang menjanjikan. Misalnya, [6] menggunakan *EfficientNet-B0* untuk mendeteksi retakan pada permukaan beton dengan tingkat *Accuracy* tinggi, sementara [7], mengaplikasikan model yang sama dalam klasifikasi kerusakan kendaraan dari rekaman *CCTV*.

Sebagian besar penelitian terdahulu juga hanya mengklasifikasikan kondisi jalan dalam dua kategori sederhana (rusak atau tidak rusak), tanpa mempertimbangkan tingkat kerusakan secara detail. Selain itu, banyak yang belum mengintegrasikan teknik validasi silang seperti *K-Fold Cross Validation* atau menyamakan *preprocessing* antar model, sehingga evaluasi performa model kurang komprehensif. Penelitian ini memberikan kontribusi dalam mengisi gap tersebut dengan memanfaatkan dataset berisi 1.800 gambar yang dibagi secara seimbang ke dalam tiga kelas kerusakan jalan: baik, rusak ringan, dan rusak berat. Masing-masing model akan dievaluasi menggunakan validasi silang *5-Fold*, dengan *preprocessing* yang disesuaikan dengan arsitektur masing-masing, serta augmentasi data untuk memperkuat generalisasi.

Dengan pendekatan ini, penelitian diharapkan dapat mengidentifikasi arsitektur model terbaik yang bukan hanya akurat, tetapi juga efisien secara komputasi dan dapat diandalkan dalam implementasi nyata di lapangan. Hal ini penting dalam mendukung sistem monitoring infrastruktur berbasis AI, terutama dalam konteks pengembangan smart city dan pemeliharaan jalan berkelanjutan.

2. METODE PENELITIAN

Penelitian ini menggunakan metode kuantitatif dengan pendekatan eksperimental untuk mengevaluasi performa beberapa arsitektur CNN, yaitu *ResNet50* dan *EfficientNet-B0*, dalam mengklasifikasikan tiga tingkat kerusakan jalan: baik, rusak ringan, dan rusak berat. Metode penelitian meliputi tahap identifikasi masalah, pengumpulan dan praproses data, pelatihan model menggunakan *ResNet50* dan *EfficientNet-B0*, evaluasi dengan validasi silang *5-Fold*, serta analisis kinerja menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*, adapun metode penelitian di tunjukan pada Gambar 1.



Gambar 1. Metode penelitian

2.1. Data Penelitian

Data yang digunakan dalam penelitian ini bersumber dari dataset yang tersedia pada platform Kaggle. Dataset ini mengandung serangkaian gambar dengan 3 kelas jenis kerusakan jalan yaitu jalan baik, jalan rusak ringan dan jalan rusak berat dengan berbagai tingkat kerusakan. Dataset ini dipilih karena kekayaan fitur visual yang dapat dimanfaatkan untuk melatih model dengan kemampuan deteksi yang baik, sebagaimana ditunjukkan pada Tabel 1.

Tabel 1. Rincian Jumlah Dataset

No	Label	Jumlah
1	Jalan baik	600
2	Jalan rusak ringan	600
3	Jalan rusak berat	600
	Total	1800

2.2. Preprocessing

Praproses dilakukan untuk mempersiapkan data sebelum tahap pelatihan model [8]. Pada tahap *preprocessing*, citra masukan untuk arsitektur *ResNet50* dan *EfficientNet-B0* diubah ukurannya menjadi 224×224 piksel dan dikonversi ke format RGB. Selanjutnya dilakukan *pixel scaling* ke rentang $[-1, 1]$ menggunakan fungsi *preprocess_input* sesuai arsitektur masing-masing. Proses ini bertujuan menyesuaikan normalisasi data dengan bobot *pretrained* yang telah dilatih pada dataset ImageNet sehingga kompatibilitas dan efektivitas fitur yang dipelajari tetap terjaga. Apabila dataset bersifat tidak seimbang, teknik *class weighting* atau *resampling* juga dapat diterapkan untuk mengurangi bias prediksi, meskipun langkah tersebut tidak digambarkan pada diagram.

2.3. Pemodelan

Penelitian ini membandingkan kinerja dua arsitektur, yaitu *ResNet50* dan *EfficientNet-B0*. *ResNet50* merupakan arsitektur dengan 50 lapisan yang dilengkapi *residual connections* untuk mengatasi permasalahan *vanishing gradient* [9]. Sementara itu *EfficientNet-B0* merupakan varian dasar dari arsitektur EfficientNet yang dikembangkan oleh Google AI dengan tujuan menghasilkan model jaringan saraf yang efisien secara komputasional namun tetap memiliki kinerja tinggi. Arsitektur ini mengadopsi konsep *compound scaling*, yaitu peningkatan kedalaman, lebar, dan resolusi secara proporsional untuk mengoptimalkan keseimbangan antara akurasi dan efisiensi. Sebagai model dengan jumlah parameter paling sedikit dalam seri EfficientNet, *EfficientNet-B0* tetap efektif dalam tugas klasifikasi gambar. Struktur utamanya terdiri atas blok berulang yang memanfaatkan *depthwise separable convolutions* serta fungsi aktivasi *Swish* [5]. Dalam penerapan *transfer learning*, backbone *pretrained* dimanfaatkan sebagai ekstraktor fitur, kemudian ditambahkan *classification head* yang terdiri atas lapisan *GlobalAveragePooling* atau *Flatten*, dilanjutkan dengan *Dense* dan *Dropout*, serta diakhiri dengan lapisan *Dense Softmax* untuk klasifikasi tiga kelas. Pada tahap awal, sebagian lapisan dibekukan (*frozen*) untuk mempertahankan bobot pralatih, kemudian dilakukan *fine-tuning* pada lapisan atas setelah bagian *classification head* mencapai kestabilan, jika diperlukan.

2.4. Split Data dengan 5-Fold Cross Validation

K-Fold cross validation merupakan salah satu metode statistik yang diimplementasikan untuk mengevaluasi performansi dari model atau algoritma yang telah dirancang. Pada tahap pelatihan dataset dibagi menjadi data latih dan data validasi. Model akan dilatih menggunakan data latih dan divalidasi menggunakan data validasi sebanyak *k-Fold* kali [10]. Selain itu *k-fold cross validation* adalah cara yang efektif dalam menggabungkan atribut dan setting parameter *machine learning* dalam melatih model *prediction* yang lebih baik [11].

2.5. Training Model

Training model dilakukan menggunakan dataset yang telah melalui tahap praproses. Parameter utama, seperti *learning rate*, *batch size*, dan jumlah *epoch*, ditetapkan berdasarkan eksperimen awal guna mengoptimalkan kinerja model. Optimizer Adam digunakan untuk mempercepat konvergensi, sedangkan fungsi *cross-entropy loss* diterapkan untuk menghitung selisih antara prediksi dan label sebenarnya. Seluruh proses pelatihan dijalankan pada perangkat keras GPU untuk mempercepat waktu komputasi [9].

2.6. Evaluasi Model

Pada tahap ini, pengujian sistem dievaluasi menggunakan *Confusion Matrix* untuk menghitung nilai *Accuracy*, *Precision*, *F1-Score*, dan *F-1 score* [12]. Persamaan untuk menghitung nilai *Accuracy*, *Precision*, *F1-Score*, dan *F-1 score* dapat dilihat pada persamaan (1), (2), (3), dan (4).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \tag{1}$$

$$Precision = \frac{TP}{TP+FP} \tag{2}$$

$$Recall = \frac{TP}{TP+FN} \tag{3}$$


$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{4}$$

True Positive (TP): Jumlah data positif yang diidentifikasi dengan benar oleh sistem. True Negative (TN): Jumlah data negatif yang diidentifikasi dengan benar oleh sistem. False Positive (FP): Jumlah data yang seharusnya negatif tetapi diklasifikasikan sebagai positif oleh sistem. False Negative (FN): Jumlah data yang seharusnya positif tetapi diklasifikasikan sebagai negatif oleh sistem.

3. HASIL DAN PEMBAHASAN


3.1. Evaluasi Grafik Accuracy dan Loss ResNet50

Gambar 2 menunjukkan akurasi validasi pada setiap *Fold*, di mana seluruh *Fold* mencapai nilai di atas 0,99 sejak awal pelatihan. *Fold* ke-5 tampil paling stabil dengan akurasi mendekati 1,00, sementara *Fold* ke-1 dan ke-3 meningkat secara bertahap hingga mencapai 1,00 pada epoch ke-8 sampai ke-10. *Fold* ke-2 sempat menurun hingga 0,9833 dan *Fold* ke-4 mengalami fluktuasi, namun keduanya kembali meningkat mendekati 1,00 pada akhir pelatihan.



Gambar 2. Grafik Accuracy ResNet50


Grafik 3 menunjukkan nilai loss validasi pada setiap *Fold* selama proses cross-validation. Secara umum, loss mengalami penurunan seiring bertambahnya epoch meskipun masih terdapat fluktuasi pada beberapa *Fold*. *Fold* 4 menunjukkan hasil terbaik dengan loss paling rendah dan stabil di akhir epoch, sedangkan *Fold* 2 cenderung memiliki loss lebih tinggi dibandingkan *Fold* lainnya. Hal ini menggambarkan bahwa model mampu belajar dengan baik, meskipun terdapat variasi performa antar *Fold*.



Gambar 3. Grafik Loss ResNet50


3.2. Grafik Accuracy dan Loss EfficientNet-B0

Gambar 4 memperlihatkan akurasi validasi pada setiap *Fold*, di mana seluruh *Fold* menunjukkan peningkatan performa seiring bertambahnya epoch. *Fold* ke-5, ke-2, dan ke-4 mencapai akurasi tertinggi mendekati 1,00, sedangkan *Fold* ke-1 relatif lebih rendah dengan nilai akhir sekitar 0,9790.



Gambar 4. Grafik Accuracy EfficientNet-B0


Grafik 5 memperlihatkan tren penurunan loss validasi pada setiap *Fold* selama proses cross-validation. Hampir semua *Fold* menunjukkan penurunan loss yang konsisten hingga mencapai nilai rendah dan stabil di epoch akhir. *Fold* 4 memperoleh hasil terbaik dengan loss sekitar 0.0106, sedangkan *Fold* 1 memiliki loss tertinggi di akhir pelatihan yaitu 0.0885. Hal ini menunjukkan bahwa model secara umum mampu belajar dengan baik, meskipun terdapat variasi performa antar *Fold*.



Gambar 5. Grafik Loss EfficientNet-B0

3.3. Evaluasi Confusion Matrix ResNet50

Confusion Matrix pada Gambar 6 menunjukkan bahwa model memiliki performa sangat baik dengan Accuracy sebesar 99,67%. Kelas baik memperoleh Precision 99,83%, F1-Score 99,50%, dan *f1-score* 99,66%. Kelas rusak berat mencapai Precision 99,34%, F1-Score 99,67%, dan *f1-score* 99,50%. Sementara itu, kelas rusak ringan memiliki Precision, F1-Score, dan *f1-score* yang seimbang, masing-masing sebesar 99,33%. Secara keseluruhan, seluruh metrik evaluasi berada di atas 99%, yang menunjukkan bahwa model mampu melakukan klasifikasi dengan tingkat kesalahan yang sangat rendah dan konsistensi prediksi yang tinggi pada semua kelas.



Gambar 6. Confusion Matrix ResNet50

3.4. Hasil Accuracy Validasi Tiap Fold


Tabel 2 menunjukkan perbandingan akurasi validasi model *ResNet50* dan *EfficientNet-B0* pada lima *Fold*. Secara umum, kedua model memiliki akurasi yang sangat tinggi di atas 0.97. *ResNet50* unggul pada *Fold 1*, *Fold 3*, *Fold 4*, dan *Fold 5* dengan akurasi mendekati 1.00, sedangkan *EfficientNet-B0* menunjukkan hasil terbaik pada *Fold 2* dengan akurasi 0.9944.

Tabel 2. Hasil *Accuracy* Validasi Tiap *Fold*

Model	Fold 1 (Biru)	Fold 2 (Hijau)	Fold 3 (Merah)	Fold 4 (Ungu)	Fold 5 (Oranye)
<i>ResNet50</i>	0.9944	0.9833	0.9972	0.9972	0.9972
<i>EfficientNet-B0</i>	0.9750	0.9944	0.9917	0.9944	0.9944

3.5. Evaluasi *Confusion Matrix EfficientNet-B0*

Gambar 8 menunjukkan *Confusion Matrix* model *EfficientNet-B0* dengan *Accuracy* 99,2% dengan *Precision*, *F1-Score*, dan *F1-score* di atas 99% pada semua kelas. Dari 600 citra per kelas, sebagian besar terklasifikasi benar, dengan kesalahan prediksi hanya 1–5 citra. Hasil ini membuktikan model mampu mengenali kondisi jalan baik, rusak berat, dan rusak ringan dengan tingkat ketepatan yang sangat tinggi.



Gambar 7. *Confusion Matrix EfficientNet-B0*

3.5. Hasil penelitian pada model

Hasil pengujian model menunjukkan bahwa metrik evaluasi berupa *Accuracy*, *Precision*, *F1-Score*, dan *f1-score* digunakan untuk membandingkan kinerja arsitektur CNN pretrained dalam mengklasifikasikan kerusakan jalan. Tabel 3 menyajikan hasil evaluasi dua arsitektur, yaitu *ResNet50* dan *EfficientNet-B0*. Secara umum, keduanya memiliki performa sangat baik dengan nilai evaluasi pada kisaran 99%–100%. *ResNet50* mencapai *Precision* dan *f1-score* sempurna (100%) dengan *Accuracy* dan *F1-Score* sebesar 99%, yang menunjukkan kemampuan tinggi dalam mengidentifikasi kelas dengan tingkat kesalahan yang sangat rendah. Sementara itu, *EfficientNet-B0* menampilkan hasil konsisten pada seluruh metrik dengan nilai 99%, yang menandakan keseimbangan antara ketepatan dan cakupan prediksi. Secara keseluruhan, kedua arsitektur menunjukkan kinerja yang hampir setara, meskipun *ResNet50* sedikit lebih unggul pada aspek *Precision* dan *f1-score*.

Tabel 3. Hasil penelitian pada model

No	Arsitektur	<i>Accuracy</i>	<i>Precision</i>	<i>F1-Score</i>	<i>F-1 Score</i>
1	<i>ResNet50</i>	99%	100%	99%	100%
2	<i>EfficientNet-B0</i>	99%	99%	99%	99%

3.6. Perbandingan dengan penelitian sebelumnya

Tabel 4 membandingkan kinerja beberapa arsitektur jaringan saraf pada tugas klasifikasi citra. Model *Xception* yang diuji pada dataset privat memperoleh *Accuracy* sebesar 90%, sedangkan *LeNet-5* hanya mencapai 80% pada dataset serupa. Pendekatan *Hybrid CNN-LSTM* yang diuji menggunakan data dari platform Kaggle menunjukkan hasil lebih baik dengan *Accuracy* 97,5%, sedangkan CNN murni pada dataset yang sama hanya mencapai 92,76%, pada *ResNet-18* hanya mencapai 92% pada dataset publik dan koleksi mandiri. Sementara itu, hasil pengujian model yang diusulkan, yaitu *ResNet50* dan *EfficientNet-B0*, pada dataset Kaggle mampu mencapai *Accuracy* tertinggi sebesar 99%. Hal ini menunjukkan bahwa model yang diusulkan memiliki performa lebih unggul dibandingkan arsitektur



Tabel 4. Perbandingan dengan penelitian sebelumnya

Teknik/Model	Kumpulan Data	Accuracy
<i>Xception</i> [13]	Privat	90%
<i>LeNet-5</i> [14]	Privat	80%
<i>Hybrid CNN-LSTM</i> [15]	Platform Kaggle.	Hybrid CNN-LSTM 97.5% dan CNN 92.76%.
<i>ResNet-18</i> [9]	sumber publik dan koleksi mandiri	
<i>ResNet50</i> (Usulan kami)	Kaggle.	99%
<i>EfficientNet-B0</i> (Usulan kami)	Kaggle.	99%

4. KESIMPULAN

Penelitian ini mengevaluasi kinerja arsitektur Convolutional Neural Network (CNN), yaitu *ResNet50* dan *EfficientNet-B0*, dalam tugas klasifikasi tingkat kerusakan jalan. Hasil eksperimen menunjukkan bahwa *ResNet50* memperoleh performa terbaik dengan *Accuracy* 99%, *Precision* 100%, *F1-Score* 99%, dan *f1-score* 100%, sehingga mampu membedakan detail visual antar kelas kerusakan secara sangat akurat. *EfficientNet-B0* menempati posisi kedua dengan kinerja yang hampir setara, ditunjukkan oleh *Accuracy*, *Precision*, *F1-Score*, dan *f1-score* sebesar 99%. Selain itu, *EfficientNet-B0* memiliki efisiensi komputasi yang lebih baik, sehingga berpotensi diterapkan pada sistem pemantauan kerusakan jalan berbasis waktu nyata (*real-time monitoring*). Pendekatan *transfer learning* dengan memanfaatkan model *pretrained* terbukti efektif dalam meningkatkan performa klasifikasi, terutama pada kondisi data terbatas.

Secara keseluruhan, hasil penelitian ini menegaskan bahwa penggunaan arsitektur *pretrained* CNN, khususnya *ResNet50* dan *EfficientNet-B0*, merupakan solusi yang akurat, efisien, serta layak diimplementasikan pada sistem pemantauan otomatis kerusakan jalan. Temuan ini sekaligus mendukung pengembangan teknologi pemantauan infrastruktur cerdas yang berkelanjutan dan relevan dengan kebutuhan *smart city*.

Adapun saran untuk penelitian selanjutnya adalah melakukan eksplorasi terhadap arsitektur yang lebih mutakhir, seperti *EfficientNetV2*, *Vision Transformer (ViT)*, atau *Swin Transformer*, yang berpotensi meningkatkan akurasi dan efisiensi komputasi lebih lanjut. Selain itu, pemanfaatan dataset yang lebih bervariasi dengan kondisi pencahayaan, sudut pandang, latar belakang, serta kondisi jalan yang beragam akan memperkuat kemampuan generalisasi model pada situasi nyata. Integrasi metode *explainable AI (XAI)* seperti *Grad-CAM* atau *LIME* juga direkomendasikan agar sistem tidak hanya akurat, tetapi juga dapat memberikan interpretasi visual yang meningkatkan kepercayaan pengguna. Lebih lanjut, pengembangan implementasi berbasis *edge computing* atau *mobile deployment* dapat menjadi arah penelitian lanjutan guna mendukung sistem pemantauan jalan yang adaptif, efisien, dan responsif di lapangan.

UCAPAN TERIMAKASIH

Penulis dengan penuh rasa hormat menyampaikan terima kasih kepada berbagai pihak yang telah memberikan dukungan, kontribusi, serta bantuan baik dalam bentuk bimbingan, fasilitas, maupun masukan yang berharga, sehingga penelitian ini dapat terlaksana dengan baik dan terselesaikan sesuai dengan tujuan yang telah direncanakan..

REFERENCES

- [1] M. R. Silaen, I. S., Sinaga, A. I., Hasibuan, F. N., Siagian, H. N., dan Ramadhan, "Perspektif Pendidikan Islam Tentang Hukum Penutupan Jalan Umum: Keadilan, Aksesibilitas, dan Kesejahteraan Umat," *J. Mudabbir (Jurnal Res. Educ. Stud.*, vol. 5, no. 1, pp. 238–245, 2025.
- [2] R. Rustam, M., Susanto, A., & Hidayat, "Deteksi Kerusakan Jalan Menggunakan Deep Learning dan Citra UAV," *J. Teknol. dan Sist. Komput.*, vol. 11(1), pp. 33–41, 2023.
- [3] K. P. U. dan P. Rakyat, "Statistik Infrastruktur Jalan 2021," Jakarta: Direktorat Jenderal Bina Marga.
- [4] N. Fitri, "Analisis Kerusakan Jalan Akibat Curah Hujan dan Beban Lalu Lintas di Indonesia," *J. Transp. dan Infrastruktur*, vol. 8(2), pp. 77–85, 2022.
- [5] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," *36th Int. Conf. Mach. Learn. ICML 2019*, vol. 2019-June, pp. 10691–10700, 2019.
- [6] M. Kavitha, R., Suganthi, S., & Arun, "Deep Learning-Based Crack Detection on Concrete Structures Using EfficientNet," *J. Struct. Eng.*, vol. 49(3), pp. 256–264, 2023.
- [7] D. Wahyudin, M., & Rachmawati, "Vehicle Damage Classification from CCTV Footage Using EfficientNetB0," *J. Intell. Transp. Syst.*, vol. 13(1), pp. 15–27, 2025.



- [8] D. Restu Fauzi and G. D. Ashabil Haqdu, "Comparison of CNN Models Using EfficientNetB0, MobileNetV2, and ResNet50 for Traffic Density with Transfer Learning," *JISTICS | J. Intell. Syst. Technol. Inform.*, vol. 1, no. 1, pp. 22–30, 2025, [Online]. Available: <https://journal.apatika.org/index.php/jistics>
- [9] H. Saparudin, M. A. Ramdi, and F. S. Alfarizi, "Implementasi Convolutional Neural Network dan ResNet-18 untuk Klasifikasi Kerusakan Jalan Berbasis Citra," vol. 1, no. 1, pp. 27–31, 2025.
- [10] Y. N. FUADAH, I. D. UBAIDULLAH, N. IBRAHIM, F. F. TALININGSING, N. K. SY, and M. A. PRAMUDITHO, "Optimasi Convolutional Neural Network dan K-Fold Cross Validation pada Sistem Klasifikasi Glaukoma," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 10, no. 3, p. 728, 2022, doi: 10.26760/elkomika.v10i3.728.
- [11] W. Wijiyanto, A. I. Pradana, S. Sopingi, and V. Atina, "Teknik K-Fold Cross Validation untuk Mengevaluasi Kinerja Mahasiswa," *J. Algoritm.*, vol. 21, no. 1, pp. 239–248, 2024, doi: 10.33364/algoritma/v.21-1.1618.
- [12] U. Multi, D. Palembang, J. Rajawali, and N. Palembang, "Klasifikasi Kanker Kulit Pada Citra Dermatoskopi Menggunakan CNN 1,2," vol. 5, no. 1, 2024, doi: 10.35957/algoritme.xxxx.
- [13] R. L. Gaho, I. T. Ali, and E. Prakasa, "Klasifikasi Kualitas Permukaan Jalan Raya Menggunakan Metode CNN Berbasis Arsitektur Xception," pp. 354–365, 2024.
- [14] A. W. Mulia, I. Ruslianto, D. M. Midyanti, J. Rekayasa, and S. Komputer, "PONTIANAK DAN SEKITARNYA DENGAN MENGGUNAKAN," vol. 11, no. 01, pp. 11–20, 2023.
- [15] I. A. Pradana, A. D. Rahajoe, and A. N. Sihananto, "JALAN BERBASIS ANDROID DENGAN IMPLEMENTASI ALGORITMA HYBRID CNN-LSTM," vol. 5, no. 2, pp. 1–10, 2024.