

# Identifikasi Jenis Kerusakan Perkerasan Jalan Menggunakan Metode *Single Shot Detector* Guna Meningkatkan Infrastruktur Pariwisata

Tri Maryono Rusadi<sup>\*1</sup>, Syamsul Bahri<sup>2</sup>, Bulqis Nebulla Syechah<sup>3</sup>, Muhammad Rijal Alfian<sup>4</sup>, Nuzla Af'idatur Robbaniyyah<sup>5</sup>

<sup>1,2,3,4,5</sup>Program Studi Matematika, Universitas Mataram NTB, Indonesia

e-mail: <sup>\*1</sup>rusadi.tm@staff.unram.ac.id, <sup>2</sup>syamsul.math@unram.ac.id,

<sup>3</sup>bulqisnebullas@unram.ac.id, <sup>4</sup>rijal\_alfian@unram.ac.id, <sup>5</sup>nuzla@unram.ac.id

## Abstrak

Kerusakan jalan pada kawasan pariwisata perlu diidentifikasi secara cepat dan akurat untuk mendukung keselamatan serta kualitas infrastruktur. Penelitian ini mengembangkan sistem identifikasi kerusakan perkerasan jalan berbasis citra digital menggunakan metode *Single Shot Detector* (SSD) dengan backbone *MobileNet*. Data diperoleh melalui perekaman video permukaan jalan, kemudian diekstraksi menjadi citra dan diproses melalui tahapan preprocessing seperti peningkatan kontras, penajaman, noise filtering, dan kompresi. Dataset terdiri dari empat jenis kerusakan—berlubang, bergelombang, amblas, dan retak kulit buaya—dengan total 978 citra yang dibagi menjadi data latih, validasi, dan uji. Hasil pengujian menunjukkan bahwa model SSD-*MobileNet* menghasilkan akurasi terbaik sebesar 80,41% pada batch size 64, dengan nilai mean Average Precision (mAP) 88,35%. Evaluasi lebih lanjut menunjukkan bahwa jenis kerusakan berlubang memiliki performa deteksi terbaik dengan nilai recall 92% dan F1-score 83,64%, sedangkan kerusakan amblas memiliki nilai terendah namun tetap berada di atas 50%. Temuan ini menunjukkan bahwa model mampu mengidentifikasi kerusakan jalan secara efektif dan berpotensi diterapkan dalam sistem pemantauan infrastruktur berbasis citra digital untuk mendukung pembangunan daerah pariwisata.

**Kata kunci**—citra digital, deep learning, infrastruktur jalan, kerusakan jalan, single shot detector

## 1. PENDAHULUAN

Jalan raya merupakan salah satu aspek penunjang kehidupan bermasyarakat. Namun terkadang jalan raya tidak selalu dalam kondisi baik [1]. Kerusakan jalan dapat menimbulkan ketidaknyamanan dalam berkendara dan bahkan dapat mengakibatkan kecelakaan. Dinas Pekerjaan Umum dan Penataan Ruang (PUPR) NTB menyebutkan pada tahun 2023 sekitar 180 kilometer jalan provinsi dalam kondisi rusak parah. Total jalan provinsi di Nusa Tenggara Barat (NTB) sepanjang 1.484,43 km, di mana lebih dari 10 persen dalam kondisi rusak parah [2]. Setiap adanya kerusakan jalan raya, sudah menjadi kewajiban pemerintah untuk segera memperbaikinya [3].



Gambar 1. Jalan Kondisi Rusak [4]

Berdasarkan kondisi tersebut, diperlukan evaluasi rutin terhadap keadaan jalan serta pelaksanaan pemeliharaan berkala untuk meminimalkan ataupun mencegah terjadinya kerusakan. Kerusakan pada perkerasan atau lapisan aspal perlu menjadi prioritas penanganan, terutama di wilayah dengan intensitas curah hujan tinggi seperti Indonesia, yang dapat mempercepat degradasi struktur perkerasan [5]. Tahapan awal dalam kegiatan pemeliharaan jalan adalah proses identifikasi kerusakan, yang berfungsi untuk menentukan tindakan perbaikan yang diperlukan. Identifikasi ini dapat dilakukan melalui metode manual maupun otomatis.

Metode manual dilakukan dengan meninjau kondisi jalan secara langsung, mendokumentasikan kerusakan menggunakan kamera, mengukur area kerusakan, serta menentukan tingkat kerusakan berdasarkan kategorinya sebelum disusun dalam bentuk laporan. Metode ini memerlukan waktu, tenaga, dan biaya yang besar, serta memiliki kelemahan berupa potensi subjektivitas yang dapat menurunkan tingkat akurasi penilaian. Pencatatan semacam ini idealnya digantikan oleh perangkat digital agar data dapat terdokumentasi dan tersinkronisasi secara lebih efektif [6]. Sementara itu, metode otomatis memanfaatkan perangkat yang mampu menangkap citra jalan dan mengklasifikasikan jenis kerusakan secara langsung. Metode ini lebih efisien, objektif, dan aman dalam mendukung proses pemeliharaan jalan serta upaya pembangunan infrastruktur.

Beberapa penelitian terkait pendeteksian citra telah dilakukan dengan berbagai metode dan fokus yang berbeda. Pendeteksian lubang jalan melalui tahapan segmentasi seperti binarization dengan *HST*, *median filter*, *closing*, serta *candidate extract (size, compactness, ellipticity, dan linearity)*, yang menghasilkan presisi sebesar 80% [7]. Selanjutnya, penelitian [8] menggunakan data input citra RGB untuk membedakan antara citra jalan retak dan citra jalan normal. CNN juga dimanfaatkan dalam penelitian [9] untuk mendeteksi retakan jalan secara lebih terstruktur. Selain itu, metode SSD diaplikasikan dalam penelitian [10], yang berfokus pada pendeteksian barang terlarang dalam pemeriksaan keamanan di bandara, stasiun, pusat perbelanjaan, dan tempat ramai lainnya, dengan hasil yang menunjukkan peningkatan stabilitas, kecepatan, serta akurasi pengenalan citra, dan rata-rata keakurasian mencapai lebih dari 90%.


Meskipun berbagai metode deteksi objek seperti Faster R-CNN, YOLO, maupun CNN telah banyak digunakan dalam penelitian pengolahan citra, penelitian ini memilih metode *Single Shot Detector* (SSD) karena mampu melakukan proses lokalisasi objek dan klasifikasi dalam satu tahap (*single stage*). Pendekatan tersebut menjadikan SSD memiliki waktu inferensi yang lebih cepat dibandingkan metode *two-stage detector* seperti Faster R-CNN, sehingga lebih sesuai untuk pengembangan sistem identifikasi kerusakan jalan yang diharapkan dapat bekerja secara real-time [11]. Selain itu, penggunaan backbone MobileNet memberikan keuntungan berupa ukuran model yang relatif ringan dengan kebutuhan komputasi yang lebih rendah tanpa mengurangi kemampuan deteksi secara signifikan [12]. Karakteristik tersebut menjadikan *SSD-MobileNet*

sesuai untuk diimplementasikan pada aplikasi berbasis web maupun perangkat bergerak yang memiliki keterbatasan sumber daya.

Berdasarkan uraian tersebut, penelitian ini bertujuan mengembangkan sistem identifikasi jenis kerusakan perkerasan jalan berbasis citra digital menggunakan metode *Single Shot Detector* (SSD) dengan backbone *MobileNet*. Sistem yang dikembangkan diharapkan mampu mendeteksi empat jenis kerusakan jalan, yaitu berlubang, bergelombang, amblas, dan retak kulit buaya secara otomatis serta mengevaluasi performa model menggunakan metrik akurasi, *mean Average Precision* (mAP), *precision*, *recall*, dan *F1-score*. Hasil penelitian ini diharapkan dapat menjadi alternatif solusi dalam mendukung proses pemantauan kondisi jalan, khususnya pada kawasan pariwisata.

## 2. METODE PENELITIAN

Pada penelitian ini, citra jalan berlubang, jalan bergelombang, jalan amblas dan jalan retak kulit buaya [13] didapatkan secara primer dan beberapa berupa data sekunder yang diperoleh dari Kaggle. Adapun prosedur atau langkah-langkah penelitian yang dilakukan dapat dilihat pada Gambar 2.




Gambar 2. Tahapan Penelitian

Penelitian ini diawali dengan kajian literatur serta survei lapangan untuk merumuskan tujuan utama, yaitu mengembangkan sistem pendeteksian kerusakan jalan berbasis citra digital dan metode SSD pada kawasan pariwisata. Batasan penelitian ditetapkan dengan memilih area wisata sebagai fokus serta menentukan ruas jalan yang sesuai untuk dijadikan sumber data. Pengumpulan data dilakukan melalui perekaman video menggunakan kendaraan bermotor, dengan posisi kamera tegak lurus terhadap permukaan jalan. Rekaman tersebut kemudian digunakan untuk menyeleksi dan mengelompokkan *dataset* sesuai jenis kerusakan yang teridentifikasi. Pengumpulan data menghasilkan 978 citra yang sebagian besar citra diperoleh melalui proses perekaman video dan hasil ekstraksi pada beberapa ruas jalan kawasan wisata di Pulau Lombok, sedangkan sebagian lainnya berasal dari dataset publik Kaggle untuk memperkaya variasi data pelatihan.

Seluruh citra hasil ekstraksi kemudian melalui proses pelabelan (*annotation*) menggunakan aplikasi LabelImg. Pada tahap ini setiap objek kerusakan diberi *bounding box*

sesuai dengan lokasi kerusakan pada citra serta diberi label kelas aktual (*ground truth*) berdasarkan empat kategori kerusakan, yaitu berlubang, bergelombang, amblas, dan retak kulit buaya. Proses pelabelan dilakukan secara manual untuk memastikan bahwa posisi objek dan kategori kerusakan telah sesuai dengan kondisi sebenarnya sehingga dapat digunakan sebagai data acuan dalam proses pelatihan model *SSD-MobileNet*. Setelah seluruh citra selesai diproses, dataset yang berjumlah 978 citra dibagi menjadi tiga bagian, yaitu 70% data pelatihan (684 citra), 15% data validasi (147 citra), dan 15% data pengujian (147 citra). Pembagian ini bertujuan agar model dapat mempelajari karakteristik data pada tahap pelatihan, melakukan penyesuaian parameter selama validasi, serta mengevaluasi kemampuan generalisasi menggunakan data yang belum pernah dilihat sebelumnya.

Tahap selanjutnya melibatkan proses *preprocessing* citra, mencakup peningkatan kualitas visual melalui penyesuaian kontras, penajaman, *edge enhancement*, penyaringan noise, pemberian *false color*, serta kompresi citra agar lebih efisien [14]. Data yang telah melalui tahap *preprocessing* kemudian diterapkan pada arsitektur awal model *deep learning* SSD untuk melakukan klasifikasi kerusakan jalan, menghasilkan keluaran berupa citra dengan *bounding box* dan label jenis kerusakan [16]. Pada tahap akhir, sistem diuji menggunakan data baru untuk menilai performa model, yang dilanjutkan dengan evaluasi terhadap hasil identifikasi dan tampilan antarmuka program guna menilai kualitas keseluruhan sistem yang dikembangkan. Secara umum, alur proses pendeteksian objek menggunakan metode SSD–MobileNet ditunjukkan pada Gambar 3.



Gambar 3. Tahap pendeteksian objek dengan SSD MobileNet


Proses dimulai dari citra yang diambil berupa video atau *image* sebagai input kondisi jalan berlubang. Model melakukan tahap pra-pemrosesan, meliputi penyesuaian ukuran, rotasi, serta konversi citra ke bentuk tensor guna meningkatkan kinerja dan keragaman data masukan. MobileNet digunakan untuk mengekstraksi fitur-fitur penting, seperti tepi, tekstur, dan bentuk [16]. Pada tahap ekstraksi fitur, *MobileNet* menghasilkan representasi fitur dalam bentuk *feature maps* yang mengandung informasi spasial mengenai pola tekstur, tepi, bentuk, dan perubahan intensitas piksel dari setiap jenis kerusakan jalan. *Feature maps* tersebut menjadi masukan utama

bagi SSD dalam menentukan lokasi objek melalui proses prediksi *bounding box* sekaligus menentukan kategori kerusakan. Dengan demikian, kualitas *feature maps* yang dihasilkan *MobileNet* sangat memengaruhi keberhasilan proses klasifikasi pada tahap berikutnya. Hasil ekstraksi berupa *feature maps* kemudian diproses oleh metode SSD. SSD menetapkan *anchor boxes* atau *default boxes* pada setiap lokasi citra melalui operasi konvolusi dan memprediksi *bounding boxes* untuk mengidentifikasi kemungkinan keberadaan objek jalan berlubang.

Selanjutnya, model mengklasifikasikan objek pada citra ke dalam empat kelas, yaitu jalan berlubang, jalan bergelombang, jalan amblas, dan jalan retak kulit buaya. Untuk meminimalkan duplikasi dan tumpang tindih *bounding boxes*, SSD menerapkan teknik *non-maximum suppression*. Tahap akhir menghasilkan skor deteksi kondisi jalan yang ditampilkan kepada pengguna. Pemilihan arsitektur *MobileNet* didasarkan pada efisiensinya serta kemampuannya beroperasi secara optimal pada aplikasi berbasis web dengan keterbatasan sumber daya komputasi.

### 3. HASIL DAN PEMBAHASAN

Berdasarkan hasil pengelompokan, kerusakan jalan diklasifikasikan ke dalam empat kategori, yakni jalan berlubang, jalan bergelombang, jalan amblas, dan retak kulit buaya. Setelah itu tahap *preprocessing* dilakukan untuk meningkatkan kualitas citra sebelum digunakan dalam proses pelatihan model. Penyesuaian kontras dilakukan agar perbedaan antara permukaan jalan dan area kerusakan menjadi lebih jelas. Selanjutnya diterapkan proses *sharpening* dan *edge enhancement* untuk mempertajam batas kerusakan sehingga karakteristik visual lebih mudah dikenali oleh model. *Noise filtering* digunakan untuk mengurangi gangguan akibat pencahayaan maupun tekstur permukaan jalan, sedangkan *pseudocoloring* diterapkan untuk meningkatkan kontras visual pada beberapa citra. Tahap terakhir berupa kompresi citra dilakukan untuk memperoleh ukuran data yang lebih efisien tanpa mengurangi informasi penting yang diperlukan selama proses pelatihan.




Gambar 4. Hasil preprocessing citra : (a) citra asli, (b) peningkatan kontras, (c) *sharpening*, (d) *edge enhancement*, (e) *noise filtering*, (f) citra hasil *preprocessing*.

Setelah *preprocessing* selesai dilakukan, diperoleh sebanyak 978 citra yang kemudian dibagi menjadi data pelatihan sebanyak 684 citra, data validasi 147 citra, dan data pengujian 147




citra. Pembagian ini dilakukan secara acak dengan tetap mempertahankan proporsi masing-masing kelas sehingga distribusi data pada setiap subset tetap seimbang.



Gambar 5. Pendistribusian Data menjadi empat *Class*


Gambar 5 menunjukkan bahwa kelas berlubang memiliki jumlah citra terbanyak dalam *dataset*, sedangkan kelas bergelombang, amblas, dan retak buaya memiliki jumlah data yang relatif seimbang namun lebih sedikit. Kondisi ini menunjukkan adanya ketimpangan distribusi antar kelas, meskipun seluruh jenis kerusakan tetap terwakili dengan baik. Secara umum, distribusi data tersebut masih memadai untuk mendukung pelatihan model deteksi kerusakan jalan berbasis SSD-MobileNet.




Gambar 6. (a) Grafik Akurasi *Training vs Validation*; (b) Grafik *Loss Training vs Validation*

Gambar 6 merupakan Grafik akurasi dan *loss* pelatihan serta validasi yang menunjukkan kinerja model SSD-MobileNet selama proses pembelajaran. Akurasi data latih meningkat secara konsisten hingga mencapai nilai tinggi, sedangkan akurasi data validasi juga menunjukkan peningkatan yang signifikan dan cenderung stabil pada *epoch* akhir. Hal ini menandakan bahwa model mampu mempelajari data dengan baik sekaligus mempertahankan kemampuan generalisasi.

Sejalan dengan hal tersebut, nilai *training loss* menurun tajam seiring bertambahnya *epoch*, sementara *validation loss* mengalami penurunan pada tahap awal dan relatif stabil selanjutnya. Pola ini menunjukkan proses optimasi yang efektif tanpa indikasi *overfitting* yang signifikan.

Gambar 7. *Confusion Matrix Multiclass*

Berdasarkan Gambar 7 *Confusion Matrix* diperoleh perhitungan rata-rata presisi, *recall*, dan *F1-Score* seluruh *image* data uji untuk masing-masing *class* jenis kerusakan jalan yang ditunjukkan pada Gambar 8.

Gambar 8. Grafik Rata-rata Presisi, Recall, dan *F1-Score* Berdasarkan Jenis Kerusakan Jalan

Berdasarkan Gambar 8, nilai rata-rata presisi tertinggi diperoleh pada kategori kerusakan retak kulit buaya, yaitu sebesar 92,31%. Sementara itu, nilai rata-rata *recall* tertinggi dicapai oleh kategori jalan berlubang dengan nilai 92%. Untuk metrik *F1-score*, performa terbaik juga ditunjukkan oleh kategori jalan berlubang dengan nilai 83,64%.

Sebaliknya, nilai rata-rata presisi terendah terdapat pada kategori jalan amblas dengan nilai 72,41%. Kategori yang sama juga menunjukkan nilai rata-rata *recall* terendah, yaitu 65,62%, serta nilai rata-rata *F1-score* terendah sebesar 68,85%. Secara keseluruhan, hasil ini mengindikasikan bahwa sistem mampu mengenali berbagai jenis kerusakan jalan dengan baik, ditunjukkan oleh nilai presisi, *recall*, dan *F1-score* terendah yang tetap berada di atas 50% pada seluruh kategori kerusakan.

Sedangkan untuk tingkat akurasi model SDD-*MobileNet* mencapai 80,41% untuk batchsize 64, dan 78,41% untuk batchsize 32. Nilai akurasi sebesar 80,41% menunjukkan bahwa model memiliki kemampuan yang cukup baik dalam membedakan empat jenis kerusakan jalan. Nilai mAP sebesar 88,35% juga menunjukkan bahwa kemampuan lokalisasi objek relatif tinggi. Perbedaan performa antar kelas dipengaruhi oleh variasi bentuk dan tekstur kerusakan. Kerusakan berlubang memiliki karakteristik visual yang lebih konsisten sehingga lebih mudah dikenali, sedangkan kerusakan amblas memiliki bentuk yang lebih bervariasi sehingga menghasilkan nilai precision dan recall yang lebih rendah.

Tabel 1. Perbandingan dari Setiap Model

| Model         | mAP (%) | Akurasi (%) |
|---------------|---------|-------------|
| Batch Size 32 | 83,86   | 78,38       |
| Batch Size 64 | 88,35   | 80,41       |

Gambar 9. Pengujian Model *SSD-MobileNet*

Gambar 9 merupakan hasil pengujian model *SSD-MobileNet* dalam mengidentifikasi berbagai kategori kerusakan pada permukaan jalan. Setiap citra menampilkan *bounding box* beserta nilai *confidence* yang menunjukkan tingkat keyakinan model terhadap klasifikasi yang dihasilkan. Pada bagian kiri atas, model berhasil mendeteksi kerusakan ambblas dengan tingkat kepercayaan sebesar 80%. Sementara itu, pada citra kanan atas teridentifikasi dua area berlubang, masing-masing dengan *confidence* 76% dan 82%. Citra kiri bawah menunjukkan keberhasilan model dalam mengenali kerusakan bergelombang dengan nilai kepercayaan 78%, sedangkan citra kanan bawah menggambarkan deteksi kerusakan retak buaya dengan *confidence* mencapai 74%.

Secara keseluruhan, visualisasi ini mengilustrasikan bahwa model *SSD-MobileNet* memiliki kapabilitas yang cukup baik dalam membedakan pola-pola visual dari berbagai jenis kerusakan jalan. Tingkat kepercayaan yang relatif tinggi pada setiap kelas menunjukkan bahwa arsitektur ini mampu melakukan deteksi dengan akurasi yang memadai pada kondisi jalan yang bervariasi. Dengan demikian, hasil ini mendukung kesimpulan bahwa *SSD-MobileNet* merupakan pendekatan yang efektif dan layak diterapkan dalam sistem deteksi kerusakan jalan berbasis citra digital. Pengujian dengan sistem antarmuka aplikasi identifikasi jenis kerusakan jalan, yaitu aplikasi yang diberi nama Pavement Detector. Berikut tampilan antarmuka aplikasi dapat dilihat pada Gambar 10.



Gambar 10. Tampilan Aplikasi Pavement detector

Berikut hasil pengujian aplikasi identifikasi jenis kerusakan jalan model *SSD-MobileNet* menggunakan data berupa video yang diperoleh dari tiga tempat wisata yang berbeda di Pulau



Lombok. Tiga tempat wisata tersebut antara lain Jalur wisata Cocotinos Sekotong, Jalur wisata Taman Nasional Gunung Rinjani (TNGR) dan Jalur wisata Pantai Labuhan Haji.

Tabel 2. Hasil Identifikasi Model SSD-*MobileNet* dengan data video

| Jalur Wisata             | Berlubang | Amblas | Bergelombang | Retak Kulit Buaya |
|--------------------------|-----------|--------|--------------|-------------------|
| Sekotong                 | 15        | 1      | 9            | 8                 |
| TNGR                     | 8         | 1      | 7            | 6                 |
| Pantai Labuhan Haji      | 7         | 3      | 8            | 8                 |
| <b>Total Keseluruhan</b> | 30        | 5      | 24           | 22                |

Berdasarkan hasil pada Tabel 2, jalur wisata Sekotong memiliki jumlah kerusakan terbanyak dibandingkan dua jalur lainnya, terutama pada kategori jalan berlubang dengan 15 temuan dan jalan bergelombang sebanyak 9 temuan. Pada jalur TNGR, jumlah kerusakan relatif lebih rendah, dengan temuan terbanyak pada kategori berlubang dan bergelombang, masing-masing sebanyak 8 dan 7 lokasi. Sementara itu, jalur wisata Pantai Labuhan Haji menunjukkan distribusi kerusakan yang cukup merata pada setiap kategori, dengan jumlah tertinggi pada kerusakan retak kulit buaya dan bergelombang.

Secara keseluruhan, hasil akumulasi menunjukkan bahwa jenis kerusakan jalan berlubang merupakan kategori yang paling dominan dengan total 30 temuan, diikuti oleh kerusakan bergelombang sebanyak 24 temuan dan retak kulit buaya sebanyak 22 temuan. Adapun kerusakan amblas memiliki jumlah paling sedikit, yaitu 5 temuan. Temuan ini mengindikasikan bahwa model SSD-*MobileNet* mampu mengidentifikasi dan membedakan berbagai jenis kerusakan jalan secara efektif pada kondisi dan lokasi yang berbeda, sehingga mendukung penerapannya dalam pemantauan kondisi jalan berbasis video.

#### 4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem identifikasi kerusakan perkerasan jalan menggunakan metode SSD dengan *backbone MobileNet*. Berdasarkan hasil pengujian terhadap 978 citra yang terdiri atas empat kategori kerusakan, model memperoleh akurasi terbaik sebesar 80,41% dengan nilai mAP 88,35%. Kategori kerusakan berlubang menunjukkan performa terbaik berdasarkan nilai *precision*, *recall*, dan *F1-score*, sedangkan kategori amblas masih menjadi tantangan karena memiliki karakteristik visual yang lebih beragam. Secara keseluruhan, SSD-*MobileNet* mampu mengidentifikasi berbagai jenis kerusakan jalan secara otomatis dan berpotensi mendukung proses pemantauan kondisi jalan pada kawasan pariwisata secara lebih cepat dan objektif.

#### 5. SARAN

Saran untuk penelitian selanjutnya adalah melakukan peningkatan kinerja model melalui optimasi hyperparameter, penambahan variasi dan jumlah dataset, serta penerapan teknik augmentasi data agar akurasi deteksi dapat lebih optimal pada berbagai kondisi jalan dan pencahayaan. Selain itu, pengembangan dapat diarahkan pada penggunaan *backbone* yang lebih kuat atau model deteksi terbaru untuk meningkatkan presisi pada berbagai jenis kerusakan jalan.

#### UCAPAN TERIMA KASIH

Peneliti menyampaikan terima kasih yang sebesar-besarnya kepada Universitas Mataram atas dukungan pendanaan dan fasilitas yang telah diberikan, sehingga penelitian ini dapat terlaksana dengan baik. Dukungan tersebut diberikan berdasarkan Kontrak Penelitian Nomor 2310/UN18L1/PP/2025. Peneliti juga menyampaikan apresiasi kepada seluruh pihak yang telah memberikan dukungan dan kontribusi selama proses pelaksanaan penelitian hingga penyelesaian artikel ini.

## DAFTAR PUSTAKA

- [1] P. A. Rosyady, F. F. Rahani, and A. R. C. Baswara, "AMARTO (Damaged Road Detector): Purwarupa sistem deteksi dan analisator kerusakan jalan raya Kota Yogyakarta berbasis citra digital dan GPS," *Jurnal Jarlit*, vol. 17, pp. 65–84, 2021.
- [2] Radarlombok.co.id, "Tangani Jalan Rusak, Pemprov NTB Usulkan Rp 1,5 Triliun ke Pusat," May 15, 2023. [Online]. Available: <https://radarlombok.co.id/tangani-jalan-rusak-pemprov-ntb-usulkan-rp-15-triliun-ke-pusat.html>. [Accessed: Dec. 18, 2024].
- [3] Republik Indonesia, Undang-Undang Republik Indonesia Nomor 22 Tahun 2009 tentang Lalu Lintas dan Angkutan Jalan. Jakarta, Indonesia: Pemerintah Republik Indonesia, 2009.
- [4] M. Idris, Rustijan, R. Adelwin, and J. Sugeng, *Inspeksi Keselamatan Jalan dan Pemanfaatan Hawkeye di dalam Pelaksanaan Inspeksi Keselamatan Jalan*. Bandung, Indonesia: BTLLJ-Pusjatan, 2010.
- [5] Departemen Pekerjaan Umum, *Manual Pemeliharaan Rutin untuk Jalan Nasional dan Jalan Provinsi, Jilid II: Metode Perbaikan Standar*. Jakarta, Indonesia: Direktorat Jenderal Bina Marga, Direktorat Bina Teknik, 1995.
- [6] R. H. Pramestya, "Deteksi dan Klasifikasi Kerusakan Jalan Aspal Menggunakan Metode YOLO Berbasis Citra Digital," Bachelor's thesis, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia, 2018.
- [7] S.-K. Ryu, T. Kim, and Y.-R. Kim, "Image-based pothole detection system for its service and road management system," *Mathematical Problems in Engineering*, vol. 2015, Art. no. 968361, 2015.
- [8] L. Zhang, F. Yang, Y. D. Zhang, and Y. J. Zhu, "Road crack detection using deep convolutional neural network," in *Proc. IEEE Int. Conf. Image Processing (ICIP)*, Phoenix, AZ, USA, 2016, pp. 3708–3712.
- [9] Z. Fan, Y. Wu, J. Lu, and W. Li, "Automatic pavement crack detection based on structured prediction with the convolutional neural network," *arXiv preprint arXiv:1802.02208*, 2018.
- [10] X. Xu et al., "Research on image detection and application of security dangerous goods based on SSD," in *Proc. IEEE 1st Int. Conf. Civil Aviation Safety and Information Technology (ICCASIT)*, 2019.
- [11] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 6, pp. 1137–1149, Jun. 2017.
- [12] A. G. Howard et al., "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," *arXiv preprint arXiv:1704.04861*, 2017.
- [13] F. Yudaningrum and Ikhwanudin, "Identifikasi jenis kerusakan jalan," *Teknika*, vol. 12, no. 2, pp. 1–8, 2017.
- [14] Z. Munawar, M. Hasnawi, I. S. Beno, I. W. A. S. Darma, C. K. Sasatradipraja, N. P. Sutramiani, and A. Amir, *Visi Komputer: Konsep, Metode, dan Aplikasi*. Bandung, Indonesia: Kaizen Media Publishing, 2023.
- [15] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C. Fu, and A. C. Berg, "SSD: Single Shot MultiBox Detector," in *Computer Vision – ECCV 2016, Lecture Notes in Computer Science*, vol. 9905. Cham, Switzerland: Springer, 2016, pp. 21–37.
- [16] M. S. Iswahyudi, I. Irmawati, J. A. Widiyans, G. S. Mahendra, M. Pratiwi, N. Hayati, S. Pormalingo, E. Miranda, W. Waryono, and H. I. Yannuarsyah, *Aplikasi Machine Learning di Berbagai Bidang*. Jambi, Indonesia: PT Sonpedia Publishing Indonesia, 2023.