

Deteksi Lubang Jalan Secara Otomatis dari Rekaman Drone Menggunakan Model *Machine Learning* Berbasis YOLOv5 Instance Segmentation di Kota Pekanbaru, Provinsi Riau, Indonesia

Badrul Huda Husain^{1*}, Takahiro Osawa², Sagung Putri Chandra Astiti³, Dodi Frianto⁴, Muhammad Rizki Nandika⁵, Dewi Agustine⁶

^{1,6}Balai Penyuluhan dan Pelatihan Kehutanan Pekanbaru *Ministry of Forestry of the Republic of Indonesia*
Jl. Hr Soebrantas Km 8, 5 Kotak Pos, Sidomulyo Bar., Kota Pekanbaru, Riau 28294, Indonesia

²*Center for Research and Application of Satellite Remote Sensing (YUCARS) Yamaguchi University*
2-16-1 Tokiwadai, Ube, Yamaguchi 755-8611, Japan.

³Program Studi Teknik Lingkungan, Fakultas Teknik, Universitas Udayana
Jl. Raya Kampus Unud, Jimbaran, Kec. Kuta Sel., Kabupaten Badung, Bali 80361.

⁴*Office for Standard Implementation of Environment and Forestry Instrument Kuok Ministry of Environment and Forestry Republic of Indonesia*

Jl. Raya Bangkinang-Kuok km. 9 Po. Box 4/BKN Bangkinang, Riau 28401

⁵*Research Center for Oceanography, National Research and Innovation Agency of Indonesia* Jln. Pasir Putih 1,
Ancol Timur, Jakarta, Indonesia, 14430

*Correspondent email: badrulhuda@menlhk.go.id

Diterima: 23 September 2024 | Disetujui: 29 Oktober 2024 | Diterbitkan: 31 Oktober 2024

Abstract. *This scientific journal presents an approach to automatically detect road potholes from drone footage using a machine-learning model based on YOLOv5. The primary objective of this research is to develop a reliable and efficient system for road quality inspection. The proposed model achieves promising results with an F1 confidence of 0.83, Precision confidence of 0.96, Precision-Recall of 0.716, and Recall confidence of 0.8. The study aims to serve as a preliminary development toward the future implementation of road quality inspection. By leveraging drone footage and advanced machine learning techniques, the automated detection of potholes can significantly enhance the efficiency and accuracy of road maintenance efforts. Early detection and prompt repair of potholes can lead to improve road safety and reduce vehicle damage. Using drones and machine learning models allows for efficient monitoring and assessment of road infrastructure, contributing to sustainable transportation systems and minimizing the environmental impact of inefficient road maintenance. Moreover, this research contributes to the advancement of technology application in the field of environmental science. Overall, this study highlights the potential of YOLOv5-based machine learning models in automating the detection of road potholes from drone footage. The results demonstrate its effectiveness in accurately identifying and localizing potholes, paving the way for further advancements in road quality inspection and technology applications within the field of environmental science.*

Keywords: *Drone, Machine Learning, Pothole, YOLOv5*

PENDAHULUAN

Infrastruktur jalan memainkan peran penting dalam memastikan sistem transportasi yang aman dan efisien (Kaiser & Barstow, 2022). Namun, seiring berjalannya waktu mengalami kerusakan, terutama karena adanya lubang, menimbulkan tantangan signifikan bagi pengguna jalan dan otoritas pemeliharaan. Deteksi dan perbaikan lubang yang tepat waktu sangat penting untuk menjaga keselamatan jalan dan mencegah kerusakan lebih lanjut pada kendaraan (Han et al., 2019). Metode inspeksi manual tradisional memerlukan banyak tenaga kerja, memakan waktu, dan sering kali rentan terhadap kesalahan manusia (Tan et al., 2020). Oleh karena itu, ada kebutuhan yang semakin besar untuk sistem otomatis yang dapat mendeteksi dan menemukan lubang dengan cepat dan efisien.

Dalam beberapa tahun terakhir, kemajuan teknologi drone dan algoritma pembelajaran mesin telah membuka kemungkinan baru untuk inspeksi kualitas jalan (Liang et al., 2023). Drone yang dilengkapi dengan kamera beresolusi tinggi dapat menangkap rekaman detail permukaan jalan, memberikan pandangan komprehensif tentang kondisi jalan dan infrastruktur (Molina et al., 2023). Dikombinasikan dengan model pembelajaran mesin yang kuat, citra udara ini dapat dianalisis dengan model pembelajaran mesin yang kuat untuk mendeteksi dan mengidentifikasi lubang secara otomatis (Wang et al., 2022). Makalah ini menyajikan pendekatan untuk deteksi lubang otomatis dari rekaman drone menggunakan model pembelajaran mesin yang dibangun di atas YOLOv5. YOLOv5 adalah algoritma deteksi objek

mutakhir dengan kinerja mengesankan dalam berbagai tugas penglihatan computer (Jocher et al., 2022). Dengan memanfaatkan kemampuan YOLOv5, penelitian kami bertujuan mengembangkan sistem yang akurat dan efisien untuk mendeteksi lubang dari citra drone.

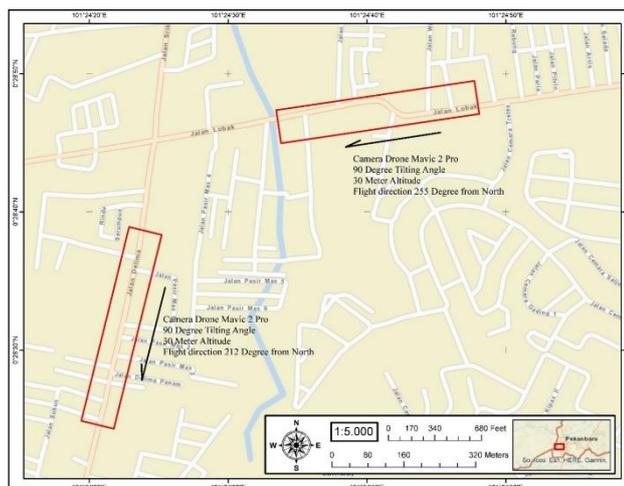
Penelitian sebelumnya (Jung & Choi, 2022) telah berhasil memanfaatkan YOLOv5, algoritma deteksi objek mutakhir, untuk mendeteksi dan melacak individu dalam rekaman kamera. Penelitian ini mengatasi tantangan deteksi orang untuk berbagai aplikasi seperti pengawasan, manajemen kerumunan, dan analisis aktivitas manusia. Tujuan utamanya adalah untuk mengidentifikasi dan melokalisasi individu dengan akurat dalam skenario waktu nyata, mencapai tingkat presisi dan recall yang tinggi..

Berbeda dengan penelitian awal yang berfokus pada deteksi orang, penelitian yang dipresentasikan di sini mengadopsi YOLOv5 untuk deteksi otomatis lubang jalan dari rekaman drone. Dengan mengganti objek yang diminati dengan lubang jalan, penelitian ini mengatasi kebutuhan kritis untuk deteksi dini dan perbaikan cepat kerusakan jalan. Penelitian ini menangani tantangan spesifik infrastruktur jalan, yaitu deteksi otomatis lubang, dan menyoroti manfaat potensial bagi otoritas pemeliharaan jalan, pengguna jalan, dan lingkungan. Secara keseluruhan, sementara penelitian awal (Jung & Choi, 2022) berfokus pada deteksi orang, penelitian ini memperluas aplikasi YOLOv5 ke domain yang berbeda, menunjukkan keserbagunaan dan adaptabilitas model.

METODE PENELITIAN

Lokasi Penelitian

Penelitian ini dilakukan di Pekanbaru pada tahun 2023, sebuah kota yang terletak di provinsi Riau, Indonesia. Area spesifik yang dipilih untuk penelitian ini adalah Jalan Delima dan Jalan Lobak. Jalan-jalan ini dipilih sebagai sampel representatif dari jaringan jalan di Pekanbaru, yang diketahui memiliki kepadatan lubang jalan yang bervariasi. Dengan memilih lokasi-lokasi ini, penelitian ini bertujuan untuk menangkap berbagai macam anomali permukaan jalan, sehingga memungkinkan evaluasi komprehensif terhadap kinerja model pembelajaran mesin berbasis YOLOv5 dalam mendeteksi dan melokalisasi lubang jalan secara akurat.



Gambar 1. Peta Lokasi Pengambilan Foto Udara yang digunakan dalam Penelitian
Sumber: Dokumentasi Pribadi

Alat dan Bahan

Drone DJI Mavic 2 Pro digunakan untuk mengambil rekaman yang diperlukan untuk analisis. Drone ini dilengkapi dengan kamera resolusi tinggi yang mampu menangkap gambar detail. Untuk penelitian ini, sudut kemiringan kamera diatur pada 90°, memastikan pandangan komprehensif dari permukaan jalan. Drone diterbangkan pada ketinggian 30 meter, memberikan perspektif optimal untuk menangkap sampel gambar lubang jalan. Pengambilan gambar foto udara yang sekaligus menjadi bahan dalam penelitian ini dilakukan pada 2 jalur terbang, yaitu jalur terbang yang terletak pada jalan Lobak, Pekanbaru dan jalur terbang yang terletak pada jalan Delima, Pekanbaru dengan masing masing arah terbang seperti yang ditunjukkan pada tabel 1.

Tabel 1. Jalur Terbang dan Arah Azimuth Terbang Drone

Jalur Terbang	Arah Azimuth Terbang
Jalan Lobak, Pekanbaru	255° dari arah utara
Jalan Delima, Pekanbaru	212° dari arah utara

Analisis Data

Penelitian ini melibatkan analisis data menggunakan segmentasi instance sebagai jenis model, menerapkan YOLO (You Only Look Once) sebagai arsitekturnya, dan memanfaatkan kerangka kerja PyTorch. Semua pemrosesan data, termasuk pelatihan, validasi, dan pengujian dilakukan di Google Colaboratory menggunakan kode sumber terbuka (*Open Source Code*).

1. Pengumpulan Data:

Rekaman drone diambil menggunakan drone kamera resolusi tinggi DJI Mavic 2 Pro dengan sudut kemiringan 90° pada ketinggian 30 meter. Secara spesifik, area dengan kondisi jalan yang bervariasi dan prevalensi lubang, seperti Jalan Delima dan Jalan Lobak di Pekanbaru, dipilih sebagai lokasi pengumpulan data.

2. Prapemrosesan Data (*Data Pre-processing*):

Rekaman drone yang diambil diproses dengan mengekstraksi frame individu untuk mendapatkan gambar. Anotasi manual dilakukan untuk memberi label pada lubang jalan menggunakan segmentasi instance, di mana setiap lubang jalan digambarkan dan diberi label unik. Dataset yang telah dianotasi dibagi menjadi set pelatihan, validasi, dan pengujian untuk evaluasi model.

3. Pemilihan Arsitektur:

YOLO (You Only Look Once) dipilih sebagai arsitektur untuk model segmentasi instance karena efektivitasnya yang terbukti dalam tugas deteksi objek (Yun & Park, 2022). Model ini diimplementasikan dalam kerangka kerja PyTorch, memanfaatkan kemampuan pengembangan model pembelajaran mendalam yang luas (Kim et al., 2022).

4. Pelatihan Data (*Data Training*):

Untuk membangun model segmentasi instance menggunakan YOLOv5 di Google Colaboratory, proses pembelajaran data menggunakan 141 gambar yang mengandung lubang jalan teridentifikasi. Gambar-gambar ini dipilih dengan cermat untuk mewakili berbagai kondisi jalan, kondisi pencahayaan, serta ukuran dan bentuk lubang jalan, memastikan kemampuan model untuk melakukan generalisasi dengan baik. Proses pelatihan terdiri dari iterasi melalui dataset beberapa kali, yang dikenal sebagai epoch, dengan 100 iterasi dilakukan. Selama proses pelatihan, model YOLOv5 belajar untuk mengidentifikasi dan melokalisasi lubang jalan dalam gambar input dengan menganalisis pola dan fitur yang terkait dengan objek-objek ini. Model menyesuaikan parameter internalnya, seperti kotak jangkar (*anchor boxes*), arsitektur jaringan backbone, dan ambang kepercayaan, melalui teknik optimisasi backpropagation dan gradient descent (Mohamed et al., 2022). Setiap epoch melibatkan pemasukan dataset ke dalam model, penyesuaian parameter model, dan pembaruan bobot untuk mengoptimalkan kinerja model dalam mendeteksi dan segmentasi lubang jalan dengan akurat (Jakubec et al., 2023). Proses iteratif ini bertujuan untuk meminimalkan perbedaan antara lokasi lubang jalan yang diprediksi dan anotasi kebenaran dasar dalam dataset pelatihan. Teknik augmentasi data diterapkan selama pelatihan untuk meningkatkan kemampuan generalisasi model. Teknik-teknik ini meliputi rotasi acak, translasi, skala, dan flipping horizontal pada gambar input. Dengan memperkenalkan variasi dalam data pelatihan, model menjadi lebih tangguh terhadap berbagai kondisi jalan dan lubang, meningkatkan kinerjanya pada data yang belum pernah dilihat sebelumnya (Hassan et al., 2023). Fungsi kerugian (*loss function*) digunakan sepanjang pelatihan untuk mengukur ketidakcocokan antara segmentasi lubang jalan yang diprediksi dan anotasi kebenaran dasar. Proses pelatihan di Google Colaboratory menyediakan lingkungan komputasi dengan sumber daya yang diperlukan, seperti akselerasi GPU, untuk melatih model YOLOv5 dengan efisien. Kode sumber terbuka yang tersedia untuk implementasi YOLOv5 di PyTorch memfasilitasi proses pelatihan, memungkinkan integrasi dan kustomisasi yang mulus untuk tugas spesifik segmentasi instance lubang jalan.

5. Evaluasi Model:

Model yang telah dilatih dievaluasi menggunakan dataset validasi, dengan mengukur metrik utama seperti presisi, recall, dan skor F1 (Arifando et al., 2023). Rumus untuk mengukur presisi, recall, dan skor F1 didefinisikan oleh persamaan 1), 2), dan 3) berturut-turut. Precision didefinisikan oleh :

$$P = \frac{TP}{TP+FP} \quad (1)$$

Keterangan:

P = Presisi

TP = *True Positive*

FP = *False Positive*

Recall didefinisikan oleh:

$$R = \frac{TP}{TP+FN} \quad (2)$$

Keterangan:

R = Recall

TP = True Positive

FN = False Negative

Sementara nilai skor F dapat diterjemahkan sebagai rata-rata ternormalisasi dari pengukuran Presisi dan Recall menggunakan persamaan yang diberikan oleh Persamaan 3. Nilai ini dihitung sebagai rata-rata harmonik dari presisi dan recall, bukan rata-rata aritmatika. Skor F1 memiliki nilai antara 0 dan 1; semakin tinggi nilainya, semakin tinggi akurasi dalam mendeteksi suatu objek.

$$F1 \text{ Score} = 2 \times \frac{P \times R}{P+R} \quad (3)$$

Keterangan:

P = Presisi

R = Recall

Kinerja model dinilai untuk memastikan deteksi dan segmentasi lubang jalan yang akurat menggunakan mAP. mAP (mean average precision) adalah nilai rata-rata dari AP (average precision), yang menunjukkan seberapa akurat hasil prediksi sebagaimana didefinisikan oleh persamaan 4.

$$mAP = \sum_{i=1}^N \frac{AP_i}{N} \quad (4)$$

Keterangan:

N = Jumlah kelas

AP = Presisi rata rata dari kelas yang berhasil dideteksi

Penyetelan model dan penyesuaian hyperparameter dilakukan berdasarkan hasil evaluasi. Pengujian independen menggunakan dataset terpisah untuk menilai kemampuan generalisasi model dan memverifikasi efektivitasnya.

6. Analisis Hasil:

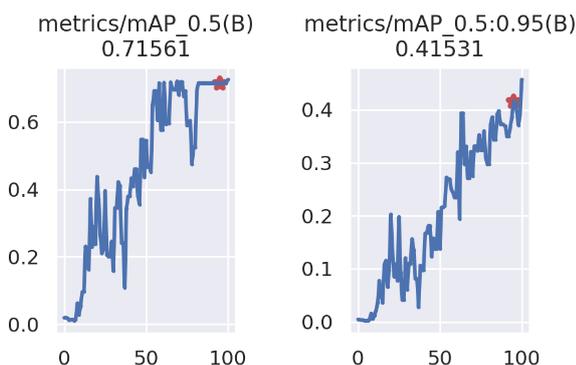
Pada fase *deployment*, model yang telah dilatih digunakan untuk membuat prediksi pada data baru yang belum pernah dilihat sebelumnya. Dalam deteksi lubang jalan, model yang telah di-deploy menerima foto udara dari drone sebagai input dan melakukan deteksi objek untuk mengidentifikasi serta menentukan lokasi lubang jalan dalam foto tersebut. Metrik kinerja model yang dilatih, termasuk presisi, recall, dan skor F1, dianalisis untuk mengevaluasi kemampuannya dalam mendeteksi dan memsegmentasi lubang-lubang jalan secara akurat.

HASIL DAN PEMBAHASAN

Dengan menggunakan dataset pelatihan yang terbatas, model YOLOv5 berhasil mencapai nilai mAP yang mengesankan sebesar 0,7 untuk deteksi lubang jalan. Tabel 1 dan Gambar 2 mengilustrasikan analisis kinerja model, menampilkan presisi, recall, skor F-1, dan nilai mAP, yang dihitung berdasarkan hasil terbaik yang diperoleh dari 100 kali pengulangan (*epochs*).

Tabel 2. Hasil Data Analisis untuk Deteksi Lubang Jalan Otomatis menggunakan Model yang Dilatih oleh YOLOv5

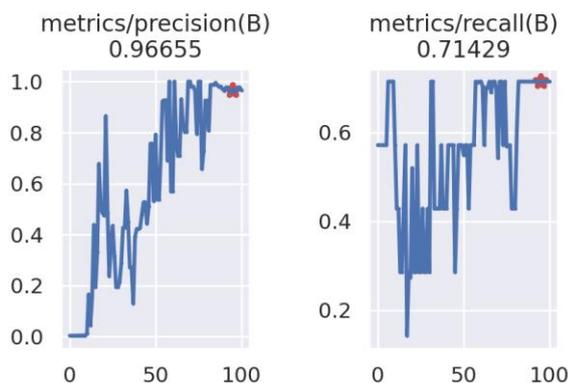
Model	Precision	Recall	F1-Score	mAP (0.5)
YOLOv5	0.96	0.71	0.83	0.7



Gambar 2. mAP yang Dihasilkan dari Deteksi Lubang Jalan Otomatis oleh YOLOv5
Sumber: Pengolahan Data (Dokumentasi Pribadi)

Nilai mAP (mean average precision) yang diperoleh sebesar 0,7 menunjukkan bahwa model YOLOv5 menunjukkan deteksi lubang jalan otomatis yang efektif, mengingat jumlah gambar pelatihan yang relatif kecil yang digunakan. Hasil ini menunjukkan kemampuan model untuk menggeneralisasi dan mendeteksi lubang jalan secara akurat, bahkan dengan dataset yang terbatas. Namun, penting untuk mempertimbangkan karakteristik khusus dan tantangan yang terkait dengan dataset dan kriteria evaluasi yang digunakan.

Seperti yang disebutkan sebelumnya, model YOLOv5 dilatih dengan dataset terbatas berupa 141 gambar, yang terdiri dari set pelatihan, validasi, dan pengujian. Meskipun ukuran dataset yang kecil, model mencapai hasil yang sangat baik dalam deteksi lubang jalan, dengan presisi sebesar 0,96, recall sebesar 0,71, dan skor F1 sebesar 0,8. Metrik-metrik ini menunjukkan kemampuan model untuk mengidentifikasi dan melokalisasi lubang jalan seperti yang ditunjukkan dalam gambar 3.



Gambar 3. Grafik hasil Pengukuran Precision dan Recall dari Deteksi Lubang Jalan Otomatis yang dilakukan oleh YOLOv5
Sumber: Pengolahan Data (Dokumentasi Pribadi)

Nilai presisi yang diperoleh sebesar 0,96 menunjukkan bahwa model YOLOv5 berhasil mengklasifikasikan semua deteksi positif sebagai lubang jalan, tanpa adanya positif palsu. Hal ini menunjukkan tingkat kepercayaan yang tinggi pada prediksi model. Nilai recall sebesar 0,71 mengimplikasikan bahwa model menangkap 71% dari lubang jalan sebenarnya yang ada dalam dataset. Meskipun masih ada ruang untuk perbaikan pada recall, kenyataan bahwa model dapat mendeteksi banyak lubang jalan dengan dataset yang terbatas patut diapresiasi.

Dalam perbandingan, kami membandingkan sebuah gambar yang telah dianotasi (Gambar 4), yang berfungsi sebagai gambar pelatihan untuk YOLOv5, dengan sebuah gambar yang diprediksi (Gambar 5) yang dihasilkan oleh algoritma deteksi objek YOLOv5. Gambar ini secara singkat mengevaluasi kinerja YOLOv5 dalam mengidentifikasi dan melokalisasi objek dengan benar dalam gambar. Model yang dihasilkan oleh YOLOv5 kemudian diterapkan pada rekaman drone aktual seperti yang terlihat pada Gambar 6 dan Gambar 7:



Gambar 4. Gambar Anotasi Lubang Jalan sebagai Gambar Pelatihan (Data Training) untuk YOLOv5. Sumber: Pengolahan Data (Dokumentasi Pribadi)

Gambar 5. Gambar Hasil Prediksi Lubang Jalan Dilakukan oleh YOLOv5. Sumber: Pengolahan Data (Dokumentasi Pribadi)

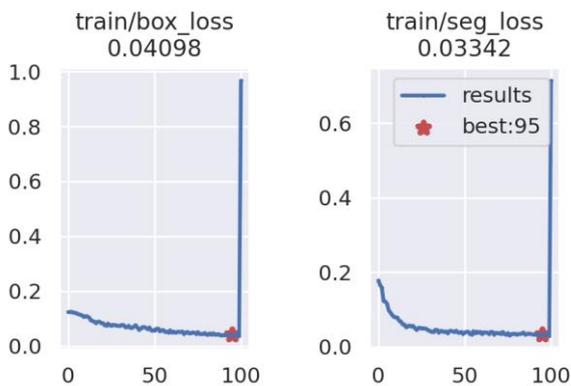


Gambar 6. Rekaman Drone Asli yang Diambil di Lokasi Penelitian di a).Jalan Delima, Pekanbaru, b).Jalan Lobak, Pekanbaru
 Sumber: Pengolahan Data (Dokumentasi Pribadi)

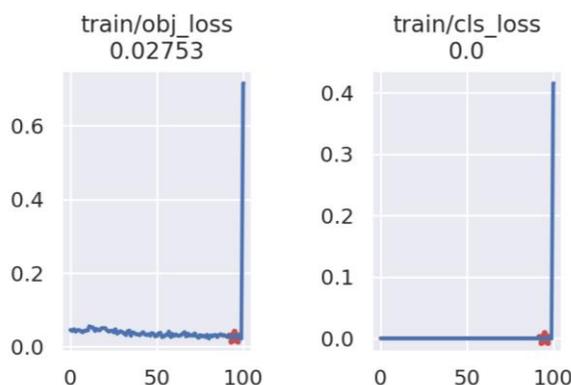
Gambar 7. Rekaman Drone dari Lokasi Penelitian di a).Jalan Delima, Pekanbaru, b).Jalan Lobak, Pekanbaru Setelah Model Deteksi Lubang Jalan Otomatis yang Dilakukan oleh YOLOv5 Diterapkan.
 Sumber: Pengolahan Data (Dokumentasi Pribadi)

Hasil dari deteksi otomatis lubang jalan di lokasi eksperimen penelitian cukup memberikan tantangan ke depannya karena berbagai faktor seperti variasi kondisi pencahayaan, permukaan jalan, dan penampilan lubang jalan. Secara tradisional, mendeteksi lubang jalan memerlukan pemeriksaan manual atau peralatan khusus. Namun, pendekatan yang diusulkan dalam penelitian ini menggunakan YOLOv5

berpotensi untuk mengotomatisasi proses ini. Dalam penelitian ini, model YOLOv5 dilatih dengan dataset terbatas, yang menunjukkan kemampuan untuk mendeteksi lubang jalan secara akurat. Meskipun dataset terbatas, namun tetap mampu berkinerja baik dalam mengidentifikasi lubang jalan dalam skenario dunia nyata. Temuan ini penting karena pelatihan model deep learning memerlukan dataset besar dan beragam untuk mencapai kinerja tinggi. Dalam kasus penelitian ini, dataset pelatihan menggunakan 141 gambar lubang jalan yang valid dengan 100 iterasi (epoch) dari proses pelatihan dengan hasil terbaik dari kerugian segmentasi terletak pada iterasi ke-95 (epoch) seperti yang dilihat pada Gambar 8 dan Gambar 9.

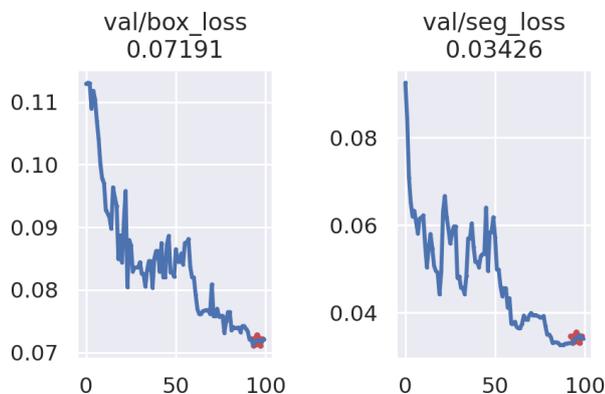


Gambar 8. Grafik Fungsi Kehilangan Data (Loss Function) *Boundary Box* dan *Segmentation* Pada Proses *Data Training* dari Deteksi Lubang Jalan Otomatis yang Dilakukan oleh YOLOv5
Sumber: Pengolahan Data (Dokumentasi Pribadi)

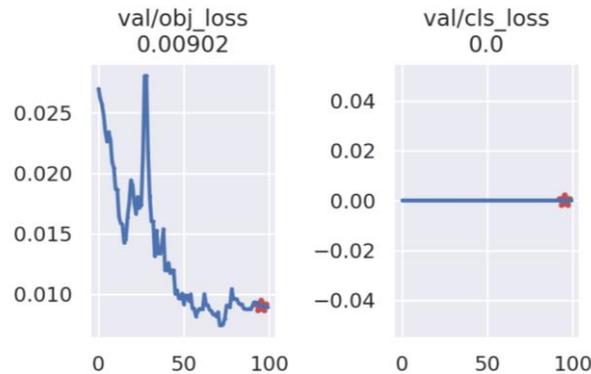


Gambar 9. Grafik Fungsi Kehilangan Data (Loss Function) *Object* dan *Class* Pada Proses *Data Training* dari Deteksi Lubang Jalan Otomatis yang Dilakukan oleh YOLOv5
Sumber: Pengolahan Data (Dokumentasi Pribadi)

Selain itu, pada penelitian ini juga diukur seberapa besar data yang hilang pada saat proses validasi data deteksi lubang jalan, seperti yang ditunjukkan oleh gambar 10-11:



Gambar 10. Grafik Fungsi Kehilangan Data (Loss Function) *Boundary Box* dan *Segmentation* Pada Proses *Data validation* dari Deteksi Lubang Jalan Otomatis yang Dilakukan oleh YOLOv5
Sumber: Pengolahan Data (Dokumentasi Pribadi)



Gambar 11. Grafik Fungsi Kehilangan Data (Loss Function) *Object dan Class* Pada Proses *Data Validation* dari Deteksi Lubang Jalan Otomatis yang Dilakukan oleh YOLOv5
Sumber: Pengolahan Data (Dokumentasi Pribadi)

Kinerja luar biasa dari model YOLOv5, meskipun dengan dataset terbatas, patut diapresiasi. Presisi sebesar 0,96 menunjukkan bahwa model mencapai tingkat prediksi yang sempurna untuk deteksi lubang jalan, menghindari positif palsu yang dapat menyebabkan perbaikan yang tidak perlu. Meskipun recall sebesar 0,71 menunjukkan adanya beberapa deteksi yang terlewat, penting untuk mempertimbangkan sifat menantang dari deteksi lubang jalan dan batasan ukuran dataset. Hasil ini menyoroti potensi model YOLOv5 untuk deteksi lubang jalan otomatis, bahkan saat dilatih dengan dataset terbatas. Presisi sebesar 1 menunjukkan bahwa model dapat diandalkan untuk identifikasi lubang jalan yang akurat, sementara skor F1 sebesar 0,8 menunjukkan kinerja keseluruhan yang tinggi. Peningkatan lebih lanjut pada recall dapat dicapai dengan memperluas dataset, menggabungkan rentang kondisi jalan yang lebih luas, dan menyetel ulang parameter model.

KESIMPULAN

Secara keseluruhan, model YOLOv5 efektif dalam deteksi lubang jalan otomatis, bahkan saat dilatih dengan dataset terbatas. Presisi yang dicapai sebesar 0,96 dan skor F1 yang baik sebesar 0,8, menunjukkan kemampuan model untuk mengidentifikasi lubang jalan secara akurat. Hasil ini memberikan wawasan berharga bagi peneliti dan praktisi yang bekerja pada aplikasi dunia nyata deteksi lubang jalan otomatis bahkan dengan menggunakan data pelatihan yang terbatas. Dan juga penelitian ini merupakan pendekatan untuk memberikan deteksi yang akurat dan pemeliharaan yang efisien terhadap lubang jalan menggunakan rekaman drone yang mengarah pada penghematan biaya bagi otoritas jalan. Dengan mengidentifikasi lubang jalan secara tepat dan memusatkan upaya pemeliharaan pada area yang membutuhkan, sumber daya dapat dialokasikan dengan lebih efisien, mengurangi biaya pemeliharaan secara keseluruhan dan memaksimalkan penggunaan anggaran yang tersedia. Berdasarkan artikel penelitian ini, kami menyarankan pendekatan untuk meningkatkan kinerja YOLOv5 dalam deteksi lubang jalan dengan mempertimbangkan faktor tambahan seperti augmentasi data, rotasi, dan variasi kondisi pencahayaan. Penyertaan faktor-faktor ini membantu mengurangi deteksi yang terlewat dari lubang jalan, menjadikan model lebih efektif dalam skenario dunia nyata. Temuan kami menyoroti pentingnya mengatasi berbagai faktor dalam meningkatkan kinerja model deteksi objek, yang berkontribusi pada peningkatan keselamatan jalan dan pemeliharaan infrastruktur yang lebih baik.

UCAPAN TERIMA KASIH

Kami ingin mengucapkan rasa terima kasih yang tulus kepada Balai Pelatihan Lingkungan Hidup Dan Kehutanan Pekanbaru – Kementerian Lingkungan Hidup dan Kehutanan Republik Indonesia atas kontribusi dalam penyediaan sumber daya yang diperlukan, khususnya drone dan akses ke platform pemrosesan gambar.

SIMPULAN

Secara keseluruhan, model YOLOv5 efektif dalam deteksi lubang jalan otomatis, bahkan saat dilatih dengan dataset terbatas. Presisi yang dicapai sebesar 0,96 dan skor F1 yang baik sebesar 0,8, menunjukkan kemampuan model untuk mengidentifikasi lubang jalan secara akurat. Hasil ini memberikan wawasan berharga bagi peneliti dan praktisi yang bekerja pada aplikasi dunia nyata deteksi lubang jalan otomatis bahkan dengan menggunakan data pelatihan yang terbatas. Dan juga penelitian ini merupakan pendekatan untuk memberikan deteksi yang akurat dan pemeliharaan yang efisien terhadap lubang jalan menggunakan rekaman drone yang mengarah pada penghematan biaya bagi otoritas jalan. Dengan mengidentifikasi lubang jalan secara tepat dan memusatkan upaya pemeliharaan pada area yang membutuhkan, sumber daya dapat dialokasikan dengan lebih efisien, mengurangi biaya pemeliharaan secara keseluruhan dan memaksimalkan penggunaan anggaran yang tersedia. Berdasarkan artikel penelitian ini, kami menyarankan pendekatan untuk meningkatkan kinerja YOLOv5 dalam deteksi lubang jalan dengan mempertimbangkan faktor tambahan seperti augmentasi data, rotasi, dan variasi kondisi pencahayaan. Penyertaan faktor-faktor ini membantu mengurangi deteksi yang terlewat dari lubang jalan, menjadikan model lebih efektif dalam skenario dunia nyata. Temuan kami menyoroti pentingnya mengatasi berbagai faktor dalam meningkatkan kinerja model deteksi objek, yang berkontribusi pada peningkatan keselamatan jalan dan pemeliharaan infrastruktur yang lebih baik.

DAFTAR PUSTAKA

- Arifando, R., Eto, S., & Wada, C. (2023). Improved YOLOv5-Based Lightweight Object Detection Algorithm for People with Visual Impairment to Detect Buses. *Applied Sciences (Switzerland)*, 13(9). <https://doi.org/10.3390/app13095802>.
- Han, S., Liu, M., Shang, W., Qi, X., Zhang, Z., & Dong, S. (2019). Timely and durable polymer modified patching materials for pothole repairs in low temperature and wet conditions. *Applied Sciences (Switzerland)*, 9(9). <https://doi.org/10.3390/app9091949>.
- Hassan, M. U., Steinnes, O. M. H., Gustafsson, E. G., Løken, S., & Hameed, I. A. (2023). Predictive Maintenance of Norwegian Road Network Using Deep Learning Models. *Sensors*, 23(6). <https://doi.org/10.3390/s23062935>.
- Jakubec, M., Lieskovská, E., Bučko, B., & Záborská, K. (2023). Comparison of CNN-Based Models for Pothole Detection in Real-World Adverse Conditions: Overview and Evaluation. In *Applied Sciences (Switzerland)* (Vol. 13, Issue 9). MDPI. <https://doi.org/10.3390/app13095810>.
- Jung, H. K., & Choi, G. S. (2022). Improved YOLOv5: Efficient Object Detection Using Drone Images under Various Conditions. *Applied Sciences (Switzerland)*, 12(14). <https://doi.org/10.3390/app12147255>.
- Kaiser, N., & Barstow, C. K. (2022). Rural Transportation Infrastructure in Low-and Middle-Income Countries: A Review of Impacts, Implications, and Interventions. In *Sustainability (Switzerland)* (Vol. 14, Issue 4). MDPI. <https://doi.org/10.3390/su14042149>.
- Kim, J. H., Kim, N., Park, Y. W., & Won, C. S. (2022). Object Detection and Classification Based on YOLO-V5 with Improved Maritime Dataset. *Journal of Marine Science and Engineering*, 10(3). <https://doi.org/10.3390/jmse10030377>.
- Liang, H., Lee, S. C., Bae, W., Kim, J., & Seo, S. (2023). Towards UAVs in Construction: Advancements, Challenges, and Future Directions for Monitoring and Inspection. In *Drones* (Vol. 7, Issue 3). MDPI. <https://doi.org/10.3390/drones7030202>.
- Mohamed, E., Sirlantzis, K., Howells, G., & Hoque, S. (2022). Optimisation of Deep Learning Small-Object Detectors with Novel Explainable Verification. *Sensors*, 22(15). <https://doi.org/10.3390/s22155596>.

- Molina, A. A., Huang, Y., & Jiang, Y. (2023). A Review of Unmanned Aerial Vehicle Applications in Construction Management: 2016–2021. *Standards*, 3(2), 95–109. <https://doi.org/10.3390/standards3020009>.
- Tan, Y., Li, S., & Wang, Q. (2020). Automated geometric quality inspection of prefabricated housing units using BIM and LiDAR. *Remote Sensing*, 12(15). <https://doi.org/10.3390/RS12152492>.
- Wang, D., Liu, Z., Gu, X., Wu, W., Chen, Y., & Wang, L. (2022). Automatic Detection of Pothole Distress in Asphalt Pavement Using Improved Convolutional Neural Networks. *Remote Sensing*, 14(16). <https://doi.org/10.3390/rs14163892>.
- Yun, H., & Park, D. (2022). Efficient Object Detection Based on Masking Semantic Segmentation Region for Lightweight Embedded Processors. *Sensors*, 22(22). <https://doi.org/10.3390/s22228890>.