

Implementasi Algoritma Yolo Untuk Mendeteksi Jalan Berlubang dan Retak

Laela Sakinah[#], Emy Haryatmi[#], Tri Agus Riyadi^{*}

[#] Magister Teknik Elektro, Direktorat Teknologi dan Rekayasa, Universitas Gunadarma, , 16424, Indonesia

^{*} Informatika, Fakultas Teknologi Industri, Universitas Gunadarma, Jl. Margonda Raya, Depok, 16424, Indonesia

E-mail: laelasakinah26[at]gmail.com, emy_h[at]staff.gunadarma.ac.id, ta_riyadi[at]staff.gunadarma.ac.id

ABSTRACTS

Roads are transportation facilities intended for traffic as well as public infrastructure that supports the mobility and accessibility of road users. Road damage is commonly found and is often identified manually. Since the invention of Computer Vision in the 1950s, object detection and classification have attracted significant interest in various sectors, including industry and medicine. Since then, many studies have been conducted using various Deep Learning algorithms capable of detecting objects. This research utilizes the YOLOv8 (You Only Look Once) algorithm to detect and classify images. This algorithm works by predicting bounding boxes and class probabilities on the entire image in a single capture. In its application, the data is divided into training, validation, and testing datasets, consisting of images of damaged roads categorized into cracks and potholes. By applying specific configurations in the YOLOv8 algorithm, the resulting output includes the Confusion Matrix calculations. The research involves analyzing results from various data train and validation splits: 70%-30%, 80%-20%, and 90%-10%, with training epochs of 25x, 50x, and 100x, to evaluate how training iterations affect performance outcomes. The results indicate that the highest confidence level is achieved when using a 90%-10% split between training and validation data, reaching 88% confidence, F1-Score of 88.7%, Recall of 90.8%, and Precision of 86.7% at the 100th epoch.

Manuscript received Aug 5, 2025;
revised Aug 15, 2025. accepted Sep
5, 2025 Date of publication Sep
30, 2025. International Journal,
JITSI : Jurnal Ilmiah Teknologi
Sistem Informasi licensed under a
Creative Commons Attribution-
Share Alike 4.0 International
License



ABSTRAK

Jalan merupakan sarana transportasi yang diperuntukan bagi lalu lintas sekaligus menjadi fasilitas publik yang mendukung mobilitas dan aksesibilitas pengguna jalan. Kerusakan jalan seringkali ditemui dan pengidentifikasiannya dilakukan secara manual. Semenjak ditemukannya Computer Vision pada tahun 1950-an, deteksi dan klasifikasi suatu objek telah banyak diminati oleh banyak pihak, baik di bidang industri maupun kedokteran, sejak saat itu banyak yang melakukan penelitian dengan berbagai algoritma Deep Learning yang dapat mendeteksi suatu objek. Penelitian dilakukan dengan menggunakan Algoritma YOLOv8 (You Only Look One) untuk mendeteksi dan mengklasifikasi data berupa citra dimana algoritma ini bekerja dengan cara memprediksi bounding box dan kelas probabilitas pada citra utuh dalam sekali capture. Dalam penerapannya, data dibagi menjadi data pelatihan, valid dan tes. Data ini berupa kumpulan citra jalan rusak dengan kategori retak dan berlubang. Dengan menggunakan kondisi khusus dalam menjalankan algoritma YOLOv8 maka hasil yang didapatkan berupa perhitungan Confusion Matrix. Penelitian dilakukan dengan cara menganalisis hasil dari masing-masing perbandingan data latih dan validasi sebesar 70%-30%, 80%-20% dan 90%-10% serta berbagai epoch mulai dari 25x, 50x sampai dengan 100x. Hal ini dilakukan untuk melihat sejauh mana proses pelatihan dapat menghasilkan hasil terbaik. Hasil penelitian yang diperoleh menunjukkan tingkat keyakinan tertinggi saat data

memiliki rasio 90% - 10% untuk data pelatihan dan validasi dengan mencapai 88%, F1- score sebesar 88,7%, Recall 90.8% dan Precision 86.7% pada epoch ke-100.

Keywords / Kata Kunci — *Computer Vision; Road Damage; Deep Learning; Object Classification; Yolo*

CORRESPONDING AUTHOR

Emy Haryatmi
Magister Teknik Elektro, Direktorat Teknologi dan Rekayasa, Universitas Gunadarma, , 16424, Indonesia
Email: emy_h[at]staff.gunadarma.ac.id

1. PENDAHULUAN


Jalan merupakan sarana transportasi lalu lintas dan fasilitas umum untuk membantu mobilitas dan aksesibilitas pengguna jalan [1], sehingga dapat memudahkan pengguna mencapai tempat tujuan. Jalan yang baik sangat penting untuk menunjang keselamatan, keamanan, kenyamanan, serta efisiensi waktu terhadap jarak yang ditempuh [2]. Kerusakan berupa perkerasan lapisan penutup aspal harus diutamakan untuk diperbaiki [3], karena pada daerah dengan curah hujan yang tinggi seperti Indonesia, kerusakan jalan dapat terjadi lebih cepat sehingga langkah yang harus dilakukan dalam pemeliharaan jalan adalah dengan mengidentifikasi kerusakan pada jalan tersebut. Metode identifikasi dapat menggunakan metode manual dan otomatis. Identifikasi dapat dilakukan secara otomatis berbasis pengolahan citra dan *computer vision* seperti *deep learning* [4], CNN [5], [6] dan YOLO [7], [8], [9]. Teknologi YOLO (*You Only Look Once*) merupakan *detector* objek satu tahap (*one-stage*) untuk mendeteksi suatu objek secara *real-time* dan memanfaatkan satu jaringan *Convolutional Neural Network* (CNN) untuk melakukan klasifikasi citra, dan lokalisasi objek menggunakan *bounding box* [10] dengan implementasi mudah [11], hasil efektif [12] dan tingkat akurasi tinggi [12], [13], [14] membuat YOLO banyak digunakan dalam berbagai aplikasi seperti pengawasan pada mesin ATM [15], bidang Kesehatan [16], maupun pengamanan pada lalu lintas [17]. Studi sebelumnya melaporkan penggunaan YOLO untuk deteksi kerusakan jalan dengan tingkat akurasi tinggi – seperti pada penelitian [7] mencapai ~99,25%. Hal ini yang mendasari penulis menggunakan algoritma YOLO untuk penelitian. Adapun penelitian dilakukan dengan cara membandingkan setiap data dan variasi *epoch* untuk mengetahui hasil mana yang lebih baik. Penelitian ini bertujuan membuat sistem deteksi kerusakan jalan (retak dan lubang) menggunakan YOLOv8 pada platform komputasi awan (*Google Colab*) sehingga dapat diimplementasikan dengan lebih mudah, cepat dan efisien

2. METODOLOGI PENELITIAN

Tahapan penelitian dirancang untuk memudahkan langkah-langkah dalam melakukan proses penelitian secara sistematis sehingga permasalahan dapat terpecahkan. Adapun diagram metode penelitian dapat dilihat pada gambar 1

TABEL 1. Pembagian Dataset

Data Train	Data Validasi	Data Test
70%	25%	5%
80%	15%	5%
90%	5%	5%




GAMBAR 1. Alur Penelitian

1. Dataset

Dataset merupakan kumpulan data berisi citra jalan dengan menggunakan data primer dan sekunder. Data primer diperoleh secara manual langsung diambil dengan cara memotret objek secara langsung menggunakan handphone Samsung A54 dengan resolusi 1080 x 2340 (Full HD+) dan deep colour High Dynamic Range (HDR) yang memberikan peningkatan kualitas visual pada layar, terutama dalam kontras, warna, dan detail bayangan maupun sorotan terang yang bersifat Dinamis (berubah per-adegan/frame) adapun data primer mencakup berbagai kondisi pencahayaan dan sudut pengambilan gambar dan data sekunder diambil dari situs open image dataset pada metadata [18]. Total citra yang didapat sebanyak 2641 yang memuat jalan retak dan jalan berlubang yang terbagi atas gambar primer sebanyak 688 dan gambar sekunder sebanyak 1773. Adapun banyak nya gambar terbagi menjadi gambar retak 1313 dan untuk gambar lubang 1164. Masing-masing dataset dibagi menjadi data latih yang terdiri dari data train dan data valid dan data uji datatest. Tabel 1 menunjukkan pembagian dataset. Data train dan data validasi diproses menggunakan algoritma YOLO (*You Only Look Once*).

2. Pre-prosesing

Setiap citra di ubah ukurannya sehingga memiliki resolusi yang sama 640x640 piksel dan mengubah ekstensinya menjadi JPG karena memiliki ukuran file yang kecil sehingga memudahkan proses pelatihan yang lebih cepat dan ringan pada RAM dan GPU serta memiliki kompatibilitas yang tinggi dan menjadi standar pada dataset publik seperti COCO, Pascal VOC dan lainnya. Hal ini dilakukan untuk memenuhi persyaratan input Yolo. selanjutnya masing-masing citra diberikan label kotak pembatas (anotasi) dengan 2 notasi yaitu lubang dengan anotasi nol dan retak dengan anotasi satu. Semua Anotasi (bounding box dan label kelas) disimpan dalam format VOC/PASCAL untuk memudahkan pelatihan model deteksi objek. Contoh dari anotasi data dapat dilihat pada gambar 2.



GAMBAR 2. Anotasi Data

3. Arsitektur dan Pelatihan Model

Model YOLOv8l (varian large) dilatih menggunakan platform Google Colab dengan paket Ultralytics YOLOv8. Versi ini memiliki tiga komponen utama yaitu backbone (tulang kepala) yang berfungsi untuk ekstraksi fitur menggunakan CSPDarknet53, selanjutnya neck (leher) untuk menggabungkan fitur berbagai skala menggunakan modul C2f, dan terakhir head (leher) untuk mendeteksi kelas serta kotak pembatas. Pelatihan dilakukan menggunakan perangkat GPU melalui platform Google Colab. Model YOLOv8 diinisialisasi dengan bobot awal standar, kemudian dilatih pada data latih dengan ukuran batch 16, jumlah epoch naik berkala dari 25, 50 dan 100 dengan ukuran 640 pixel. Proses pelatihan menghasilkan nilai confusion matrix, serta loss kotak (box loss), klasifikasi (cls loss), dan difference in distribution loss (DFL) pada data latih dan validasi. Hasil pelatihan berupa bobot akhir "last.pt" dan "best.pt" yang siap diuji. Pelatihan dibagi menjadi dua skenario yang pertama yaitu dengan perbandingan nilai komputasi (Epoch) dari 25, 50 sampai 100x komputasi dengan data latih sesuai standar penelitian YOLOv8 yaitu 80%-20% dari total data. Sedangkan skenario kedua yaitu dengan perbandingan dataset dan nilai komputasinya diambil dari hasil terbaik dari skenario pertama.

4. Pengukuran Kinerja

Setelah pelatihan, model dievaluasi pada data test yang terpisah. Pengukuran kinerja sistem dihitung dari nilai recall, presisi, akurasi, dan F1-score berdasarkan matriks kebingungan (confusion matrix). Dalam Confusion Matrix terdapat empat istilah yang merupakan representasi dari hasil proses klasifikasi pada Confusion Matrix yaitu True Positif (TP), True Negatif (TN), False Positif (FP), dan False Negatif (FN).

Recall

Recall merupakan persamaan yang menyatakan seberapa baik sistem dapat mendeteksi objek positif yang sebenarnya pada data, Recall merupakan rasio antara prediksi positif yang benar dengan total semua kasus positif yang sebenarnya ada. Adapun persamaannya:

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} \quad (1)$$

Precision

Precision merupakan suatu persamaan yang menyatakan proporsi deteksi benar terhadap seluruh deteksi positif. Adapun persamaannya:

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} \quad (2)$$

Accuracy

Accuracy merupakan suatu persamaan yang menyatakan keseluruhan prediksi benar dari semua kelas Positif dan Negatif. Adapun Persamaannya:

$$Accuracy = \frac{True\ Positive + True\ Negative}{True\ Positive + False\ Negative + False\ Positive + True\ Negative} \quad (3)$$

F-measure

F-measure dikarenakan sulit untuk membandingkan dua model dengan presisi rendah dan recall tinggi atau sebaliknya. Sehingga untuk membuatnya sebanding digunakanlah F-Score. F-score membantu mengukur Recall dan Precision secara bersamaan. Adapun Persamaannya:

$$F - measure = 2 \times \frac{Recall \times Precision}{Recall + Precision} \quad (4)$$

Metrik-metrik ini menjadi tolak ukur kinerja model dalam deteksi dan klasifikasi kerusakan jalan

3. Hasil Dan Pembahasan

Dalam penelitian digunakan dua skenario yang pertama hasil performa dari sistem berdasarkan perbandingan epoch dengan perbandingan data standar yaitu 80% untuk data latih dan 20% untuk data validasi selanjutnya tahap ke dua hasil epoch terbaik akan diterapkan pada pengujian untuk perbandingan 70% data latih 30% data validasi, 80% untuk data latih dan 20% untuk data validasi, 90% untuk data latih dan 10% untuk data validasi. Adapun hasil pelatihan sesuai pada tahap pertama didapatkan confusion matrix seperti pada tabel 2 dibawah ini:

TABEL 2. Nilai True Positive (TP), False Positive (FP) dan False Negative (FN) pada Epoch 25, 50 dan 100

Nilai Epoch	Kelas	True Positive (TP)	False Positive (FP)	False Negative (FN)
25	Lubang	0.88	0.18	0.11
	Retak	0.91	0.82	0.09
50	Lubang	0.92	0.18	0.08
	Retak	0.92	0.82	0.08
100	Lubang	0.91	0.20	0.09
	Retak	0.95	0.80	0.05

TABEL 3. Perbandingan Hasil Pelatihan Datalatih Berdasarkan Nilai Epoch

Epoch	25	50	100
Presisi (%)	84.75	85.7	88
Recall (%)	81.4	86.2	84.5
mAP50 (%)	88.7	90.5	91
mAP50-95 (%)	55.95	61	63.74
F1-score (%)	83	85.9	86

Tabel 2 diatas menunjukkan semakin besar nilai epoch akan semakin besar nilai true positive dan false negativenya. ini menunjukkan sistem bekerja dengan baik jika proses pelatihan menggunakan komputasi sebanyak 100kali. Hasil dari tabel 2 selanjutnya digunakan untuk menghitung precision, recall, F1-score. Namun hasil ini jika dihitung manual menggunakan rumus pada pengukuran kinerja akan terjadi selisih dikarenakan pada yolo perhitungan performa pada sistem dipengaruhi oleh nilai nms dengan nilai threshold selama pelatihan dimulai dari 0.5 hingga 0.95 dalam interval 0.05 (untuk mAP50-95) dan IoU 0.5 digunakan khusus untuk mAP50, sedangkan pada penelitian prediksi IoU yang digunakan 0.7 sehingga jika dua prediksi memiliki IoU > 0.7 maka hanya satu akan dipertahankan. Hasil nilai precision, recall, dan F1-score berdasarkan dari data yang telah didapatkan pada confusion matrix, dapat dilihat pada tabel 3.

Tabel 3 menunjukkan peningkatan kinerja seiring bertambahnya jumlah epoch. Sehingga pada pelatihan 100 epoch menghasilkan hasil performa yang tinggi yaitu precision 88%, mAP50 88,7%, mAP50-95 63,74% dan F1-score 86% walaupun hasil recall menempati nilai tertinggi 86,3% saat pelatihan menggunakan epoch50. Dari hasil ini maka penelitian selanjutnya akan menggunakan epoch100. Selain menghasilkan nilai performa, perbandingan ini berpengaruh pada hasil loss yang terjadi saat pelatihan berlangsung. Pada tabel 4 menunjukkan setiap nilai pelatihan ditambah maka loss yang terjadi selama pelatihan semakin berkurang mendekati 0. Adapun Nilai terbaik dapat dilihat pada pelatihan dengan menggunakan banyaknya komputasi sebanyak 100 kali.

Tabel 5 menunjukkan perbandingan metrik kinerja model YOLOv8 pada data latih dan validasi secara berturut-turut 70%-30%, 80%-20%, 90%-10% dengan menggunakan epoch sebanyak 100.

TABEL 4. Perbandingan Hasil Loss Dengan Data Latih 80% dan Data Validasi 20%

Epoch	Train box_loss	Train cls_loss	Train dfl_loss	Val box_loss	Val cls_loss	Val dfl_loss
25	0.9	0.75	1.27	1.3	0.9	1.5
50	0.7	0.56	1.1	1.1	0.8	1.4
100	0.5	0.4	1	1	0.7	1.3

TABEL 5. Nilai True Positive (TP), False Positive (FP) dan False Negative (FN)

Dataset (Data latih-Data Validasi)	Kelas	True Positive (TP)	False Positive (FP)	False Negative (FN)
70% - 30%	Lubang	0.93	0.24	0.07
	Retak	0.91	0.76	0.09
80% - 20%	Lubang	0.92	0.28	0.08
	Retak	0.92	0.72	0.08
90% - 10%	Lubang	0.98	0.29	0.02
	Retak	0.91	0.71	0.09

Pada pelatihan dengan perbandingan data dapat dilihat bahwa semakin kecil jumlah data validasi akan semakin kecil sistem memprediksi objek dengan benar dan semakin banyak data yang di latih akan memperbesar jumlah prediksi yang benar. Hasil dari Confusion Matrix, kemudian dikalkulasi untuk mendapatkan nilai Precision, Recall, F1-score dan mean average Precision.

TABEL 6. Hasil Seluruh Perbandingan Data yang Digunakan

Dataset (Data latih – Data Validasi)	Precis ion (%)	Recall (%)	MAP50 (%)	F1- Score (%)
70% - 30%	84.5	92	64,98	88.09
80% - 20%	83.7	86.4	88.6	85.03
90% - 10%	86.7	90.8	93.2	88.07


TABEL 7. Hasil Loss Seluruh Perbandingan Data yang Digunakan

Dataset (Data latih – Data Validasi)	Train box_ loss	Train cls_ loss	Train dfl_ loss	Val box_ loss	Val cls_ loss	Val dfl_ loss
70% - 30%	0.54	0.34	1.	1.1	0.68	1.3
80% - 20%	0.5	0.4	1	1	0.7	1.3
90% - 10%	0.61	0.41	1	0.9	0.54	1.2

Tabel 6 menunjukkan menunjukkan perbandingan performa dengan jumlah data latih yang memiliki perbandingan yang berbeda. Untuk data latih dengan persentasi 70% - 30% memiliki nilai Recall yang lebih besar dari yang lain yaitu sebesar 92% ini menunjukan pada data tersebut sistem dapat mendeteksi objek dengan baik. mAP adalah suatu metrik untuk mengukur akurasi objek detektor sehingga semakin tinggi mAP berarti pendeteksi objek semakin akurat. Untuk mAP lebih besar untuk data latih dengan persentasi 90% - 10% yang bernilai 93.2% dan nilai presisi sebesar 86.7%. Pada menghasilkan nilai F1-scorenya sebesar 88.70% menunjukan keseimbangan precision terhadap recall baik. Sedangkan untuk perbandingan loss nya dapat dilihat pada tabel 7.


Tabel 7 menunjukkan nilai loss terdapat variasi hasil dimana untuk data dengan perbandingan 80% - 20% train box_loss memiliki nilai sedikit lebih kecil dibanding dengan data 70% - 30% dan 90% - 10%. Sedangkan train cls_loss nilai terkecil ada pada perbandingan data 70% - 30% dan untuk selanjutnya keunggulan berada pada perbandingan data 90% - 10%. Adapun untuk nilai loss sendiri semakin kecil nilainya maka akan semakin bagus system dalam memprediksi.

Selanjutnya dilakukan pengujian terhadap gambar jalanan berlubang dan retak berdasarkan perbandingan dataset yang telah dilakukan sebelumnya. Pengujian dilakukan pada nilai dataset pada setiap perbandingan data 70% - 30%, 80% - 20% dan 90% - 10%. Hasil pengujian terhadap jalanan retak dapat dilihat pada gambar 3.



GAMBAR 3. Pengujian Gambar Jalanan Retak dengan Perbandingan Data Latih dan Data Uji (a) 70% - 30%, (b) 80% - 20%, (c) 90% - 10%

Pada Gambar diatas sistem berhasil mendeteksi jalanan retak namun dengan nilai confidence yang berbeda. Dalam gambar terlihat jelas bahwa dengan data 90% - 10% hasilnya nilai confidence lebih besar yaitu sebesar 0.76 atau 76%. Pengujian selanjutnya dilakukan terhadap jalanan berlubang. Hasil pengujian dapat dilihat pada gambar 4. Berdasarkan hasil pengujian, semua sistem berhasil mendeteksi jalanan retak namun dengan nilai confidence yang berbeda.



GAMBAR 4. Pengujian Gambar Jalanan Berlubang dengan Perbandingan Data Latih dan Data Uji (a) 70% - 30%, (b) 80% - 20%, (c) 90% - 10%

Dalam gambar terlihat jelas bahwa dengan data 80% - 20% memiliki nilai confidence yang tinggi namun tidak keseluruhan terdeteksi hasilnya berbeda dengan data 90% - 10% semua gambar terdeteksi dengan baik walaupun dengan nilai confidence lebih kecil jika dibanding dengan perbandingan data 80% - 20%.

4. KESIMPULAN

Penelitian ini berhasil membangun sistem deteksi kerusakan jalan (retak dan lubang) berbasis YOLOv8 dengan pelatihan di *Google Colab*. Pemanfaatan *Google Colab* dan *Roboflow* mempermudah implementasi, memungkinkan model YOLOv8 diunduh dan ditrain tanpa infrastruktur lokal yang besar. Sistem yang dibangun memiliki performa yang tinggi pada pelatihan menggunakan *epoch* 100. Sistem memiliki nilai F1 score tertinggi pada 88,7% dan nilai presisi sebesar 86.7% dan recall 90.8% pada saat perbandingan data latih 90% dan data validasi 10%. Sistem juga mampu mendeteksi dengan nilai *confidence* yang tinggi yaitu 88%. Sehingga sistem sudah mampu mengenali kerusakan jalan dengan baik walaupun dengan jumlah data yang terbatas dan *epoch* rendah. Penulis menyarankan penambahan jumlah data dan peningkatan *epoch* untuk peningkatan kinerja lebih lanjut

REFERENSI

- [1] F. Yudaningrum and I. Ikhwanudin, "Identifikasi Jenis Kerusakan Jalan (Studi Kasus Ruas Jalan Kedungmundu-Meteseh)," *Teknika*, vol. 12, no. 2, pp. 16–23, Oct. 2017, doi: 10.26623/teknika.v12i2.638.
- [2] A. Irawan, A. Pratomo, M. Risa, and Heldiansyah, "Perancangan Sistem Deteksi Kerusakan Aspal Jalan Melalui Video Menggunakan Fast Fourier Transform," in *Prosiding SNRT (Seminar Nasional Riset Terapan)*, Banjarmasin: Politeknik Negeri Banjarmasin, Nov. 2016, pp. A111–A119.
- [3] PUPR, "Pemeliharaan Perkerasan Aspal," https://simantu.pu.go.id/epel/edok/dede9_Modul_3_Pemel._Perkerasan_Aspal.pdf. Accessed: Jun. 19, 2025. [Online]. Available: https://simantu.pu.go.id/epel/edok/dede9_Modul_3_Pemel._Perkerasan_Aspal.pdf
- [4] B. Sasmito, B. H. Setiadji, and R. Isnanto, "Deteksi Kerusakan Jalan Menggunakan Pengolahan Citra Deep Learning di Kota Semarang," *TEKNIK*, vol. 44, no. 1, pp. 7–14, May 2023, doi: 10.14710/teknik.v44i1.51908.
- [5] D. I. Mulyana and I. Wahyudi, "Deteksi Kerusakan Jalan Berdasarkan Citra Digital Menggunakan Convolutional Neural Network (CNN)," *Jurnal Indonesia : Manajemen Informatika dan Komunikasi*, vol. 6, no. 1, pp. 294–302, Jan. 2025, doi: 10.35870/jimik.v6i1.1192.
- [6] A. Wibowo and Y. Yulianto, "Deteksi Keretakan Jalan Aspal Menggunakan Metode Convolutional Neural Network," *Jurnal Teknik Sipil Cendekia (JTSC)*, vol. 4, no. 2, pp. 581–593, Jul. 2023, doi: 10.51988/jtsc.v4i2.132.
- [7] R. H. Pramestya, "Deteksi dan Klasifikasi Kerusakan Jalan Aspal Menggunakan Metode YOLO berbasis Citra Digital," Thesis, Institut Teknologi Sepuluh November, Surabaya, 2018.
- [8] R. F. A. Pratama, "Deteksi Dan Klasifikasi Jalan Rusak Di Bandar Lampung Menggunakan YOLOv8," Skripsi, Universitas Lampung, Bandar Lampung, 2024.
- [9] San Gabriel Vanness Kenrick Erwi and Hafiz Irsyad, "Implementasi Deteksi Objek Pada Jalan Rusak Menggunakan Metode YOLOv8," *Buletin Ilmiah Informatika Teknologi*, vol. 3, no. 1, pp. 1–9, Oct. 2024, doi: 10.58369/biit.v3i1.76.
- [10] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las
- [11] Hydra Amnur, A. K. Vadreass, and M. Ridwan, "Aplikasi Pendeteksi Kematangan Tanaman Menggunakan Metode Transformasi Ruang Warna HSI (Hue, Saturation, Intensity) dan K-NN (K- Nearest Neighbor)," *jitsi*, vol. 5, no. 4, pp. 161–167, Dec. 2024.
- [12] J. Redmon and A. Farhadi, "YOLO9000: Better, Faster, Stronger," in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu: IEEE, Jul. 2017, pp. 6517–6525. doi: 10.1109/CVPR.2017.690.

- [13] G. Li and D. Zhu, "Research on road defect detection based on improved YOLOv8," in 2023 IEEE 11th Joint International Information Technology and Artificial Intelligence Conference (ITAIC), Chongqing: IEEE, Dec. 2023, pp. 143–146. doi: 10.1109/ITAIC58329.2023.10408744.
- [14] Y. Xiao, C. Wan, J. Lin, S. Dong, W. Gao, and L. Mei, "Research on Road Damage Detection Based on an Improved YOLOv8 Model," in 2024 4th International Conference on Computer Science, Electronic Information Engineering and Intelligent Control Technology (CEI), Guangzhou, China: IEEE, Nov. 2024, pp. 634–637. doi: 10.1109/CEI63587.2024.10871691.
- [15] P. Yanfei and J. Yue, "Road Crack Detection Algorithm Based on Improved YOLOv8," in 2023 5th International Conference on Artificial Intelligence and Computer Applications (ICAICA), Dalian, China: IEEE, Nov. 2023, pp. 28–32. doi: 10.1109/ICAICA58456.2023.10405428.
- [16] A. R. Wasril, M. S. Ghozali, and M. B. Mustafa, "Pembuatan Pendeteksi Obyek Dengan Metode You Only Look Once (YOLO) Untuk Automated Teller Machine (ATM)," *Majalah Ilmiah UNIKOM*, vol. 17, no. 1, pp. 69–76, Sep. 2019, doi: 10.34010/miu.v17i1.2240.
- [17] R. S. Passa, S. Nurmaini, and Di. P. Rini, "YOLOv8 Based on Data Augmentation for MRI Brain Tumor Detection," *Scientific Journal of Informatics*, vol. 10, no. 3, pp. 363–370, Aug. 2023.
- [18] N. N. Hasibuan, M. Zarlis, and S. Efendi, "Detection and Tracking Different Type of Cars With YOLO model combination and deep sort algorithm based on computer vision of traffic controlling," *Sinkron*, vol. 5, no. 2B, pp. 210–221, Dec. 2021, doi: 10.33395/sinkron.v6i1.11231.
- [19] Prediksi. 2025. *JalanRusak Dataset*. Roboflow Universe. Roboflow. Tersedia secara daring di: <https://universe.roboflow.com/prediksi/jalanrusak-zofhk-w0e7u> [diakses 02 Februari 2025]