

## Deteksi Kerusakan Jalan Menggunakan Pengolahan Citra *Deep Learning* di Kota Semarang

Bandi Sasmito\*<sup>1,2</sup>, Bagus Hario Setiadji<sup>1</sup>, Rizal Isnanto<sup>1,3</sup>

<sup>1</sup> Program Doktor Teknik Sipil Fakultas Teknik, Universitas Diponegoro,

<sup>2</sup> Departemen Teknik Geodesi Fakultas Teknik, Universitas Diponegoro,

<sup>3</sup> Departemen Teknik Komputer Fakultas Teknik, Universitas Diponegoro,  
Jl. Prof. Soedarto, SH, Kampus UNDIP Tembalang, Semarang, Indonesia 50275

### Abstrak

Jalan adalah kebutuhan krusial dalam aktivitas masyarakat. Jalan mempermudah akses transportasi dari tempat asal ke tujuan. Jalan juga penting sebagai infrastruktur transportasi darat untuk manusia dan barang. Namun, kondisi jalan yang tidak layak dapat menyebabkan kecelakaan. Pelacakan kondisi jalan sulit karena banyaknya jalan yang harus diperiksa. Penelitian ini menggunakan prinsip penginderaan jauh dengan teknologi Jaringan Syaraf Tiruan *Deep Learning*. *YOLO* (*You Only Look Once*) digunakan untuk deteksi kerusakan jalan. Hasil pendeteksian ditambahkan posisi atau lokasi dengan menggunakan *Global Navigation Satellite System* (*GNSS*), sehingga nantinya hasil deteksi dapat memberikan posisi atau lokasi yang akurat. Penelitian ini menghasilkan model identifikasi kerusakan jalan dengan nilai *overall accuracy* sebesar 88% dan nilai *kappa accuracy* sebesar 86% dan lokasi sebaran kerusakan yang memiliki koordinat posisi dengan akurasi *RMSE* sebesar  $\pm 5,6$  meter.

**Kata kunci:** jaringan syaraf tiruan; *deep learning*; penginderaan jauh; identifikasi kerusakan jalan; transportasi jalan; *YOLO* (*You Only Look Once*)

### Abstract

[*Title: Road Damage Detection Using Deep Learning Image Processing in Semarang City*] Roads are a crucial necessity in community activities. They facilitate transportation access from a particular place to the destination. Furthermore, roads are important as land transportation infrastructure for both people and goods. However, inadequate road conditions can lead to accidents. Tracking road conditions is challenging due to the large number of roads that need to be inspected. This research utilizes remote sensing principles with *Deep Learning Artificial Neural Network* technology. *YOLO* (*You Only Look Once*) is employed for road damage detection. The detection results are enhanced with precise positioning or location using the *Global Navigation Satellite System* (*GNSS*), allowing for accurate detection results. This study produces a road damage identification model with an *overall accuracy* of 88% and a *kappa accuracy* of 86%, as well as location distribution of damages with positional coordinates accuracy of  $\pm 5.6$  meters (*RMSE*).

**Keywords:** artificial neural networks; *deep learning*; remote sensing; road damage identification; road transport; *YOLO* (*You Only Look Once*)

### 1. Pendahuluan

Jaringan jalan memainkan peran strategis yang penting dalam pembangunan sehingga perlu dikelola

secara efektif. Namun jalan juga memiliki potensi bahaya bagi kehidupan, baik kehidupan manusia dan hewan (Zimmermann *et al.*, 2017). Dengan demikian, mitigasi bahaya di jalan diperlukan. Kajian mitigasi bahaya di jalan telah banyak dilakukan (Wegman, 2017).

Bagian mitigasi bahaya ini adalah pemeliharaan jaringan jalan. Pemeliharaan jaringan jalan membutuhkan

---

\*) Penulis Korespondensi.

E-mail: bandisasmito@live.undip.ac.id

manajemen pemeliharaan sepanjang waktu, mengingat jalan merupakan infrastruktur transportasi darat yang penting. Pemantauan kondisi jalan diperlukan untuk meminimalisir frekuensi kecelakaan yang disebabkan oleh keadaan jalan yang buruk. Namun, tantangan dari sistem pemantauan adalah jaringan jalan yang sangat besar jumlahnya. Pengawasan secara kontinyu tentu menimbulkan kesulitan tersendiri, terutama untuk wilayah yang luas. Sementara itu, pendeteksian kerusakan jalan secara manual memakan waktu lama karena survei lapangan harus dilakukan di semua lokasi jaringan jalan.

Sistem kerja manual seperti ini berpeluang untuk ditingkatkan dengan memanfaatkan teknologi. Kemajuan teknologi komputasi kini sudah merambah pada penerapan kecerdasan buatan untuk melakukan tugas-tugas yang dapat dilakukan manusia. Kecerdasan buatan diterapkan di banyak bidang termasuk *surveillance* dan mitigasi (Rego *et al.*, 2018; Biros, Sharma and Biros, 2019).

Riset ini mengaplikasikan pengolahan citra secara digital dengan algoritma model *Convolutional Neural Networks* (CNN). Algoritma CNN sering dipakai untuk pengenalan objek pada citra digital terestial permukaan tanah (Kamilaris and Prenafeta-Boldú, 2018; Kiranyaz *et al.*, 2021). Penggunaan kamera dan penerapan model CNN dapat mempersingkat waktu yang dibutuhkan untuk kegiatan survei lapangan di jalan dalam identifikasi kerusakan. Hal ini memungkinkan perbaikan jalan rusak dapat diselesaikan dengan singkat, sehingga dapat mengurangi jumlah kecelakaan yang disebabkan oleh kerusakan jalan.

Metode spasial dapat digunakan untuk mengkaji suatu wilayah dengan cepat, efektif, dan efisien dengan berbasis keruangan. Adapun aplikasi yang digunakan adalah penginderaan jauh dan Sistem Informasi Geografis. Metode ini mengandalkan data keruangan berbasis digital berformat raster maupun vektor. Kajian mencakup daerah yang terdistribusi dan dapat digabungkan dengan informasi lain yang diperlukan sehingga dapat disebut sebagai Model Spasial (Pisharoty, 1983; Lillesand and Kiefer, 2008).

Berbagai penelitian tentang penggunaan algoritma *Deep Learning* telah dilakukan oleh peneliti di banyak bidang. Demikian halnya dengan deteksi objek termasuk kerusakan jalan baru berdasarkan metode segmentasi peta disparitas un-supervised dilakukan oleh (Fan and Liu, 2020). Pada penelitian tersebut peta disparitas yang ditransformasi kemudian disegmentasi menggunakan metode *thresholding* Otus. Hasil uji coba menunjukkan bahwa algoritma yang diusulkan bekerja secara akurat dan efisien. Akurasi deteksi kerusakan jalan tingkat piksel sekitar 97,56%.

Dari sisi pengolahan citra kamera, sudah dilakukan kajian oleh (Chen *et al.*, 2020). meneliti

pengolahan citra kamera untuk mendeteksi kerusakan jalan otomatis. Metode ini berbasis pada jaringan saraf tiruan yang digunakan untuk mengatasi kendala dalam klasifikasi dan deteksi kerusakan jalan. Menggunakan Algoritma Mask R-CN untuk mengekstrak fitur gambar.

(Pan *et al.*, 2021) menggunakan rekaman citra perkerasan yang diperoleh oleh kendaraan udara tak berawak (UAV). Data digunakan untuk membedakan antara perkerasan jalan normal dan perkerasan jalan rusak (misalnya, retakan dan lubang). Hasil studi menunjukkan bahwa sistem penginderaan jauh UAV menawarkan alat baru untuk memantau kondisi perkerasan jalan aspal, yang dapat digunakan sebagai pendukung keputusan untuk praktik pemeliharaan jalan.

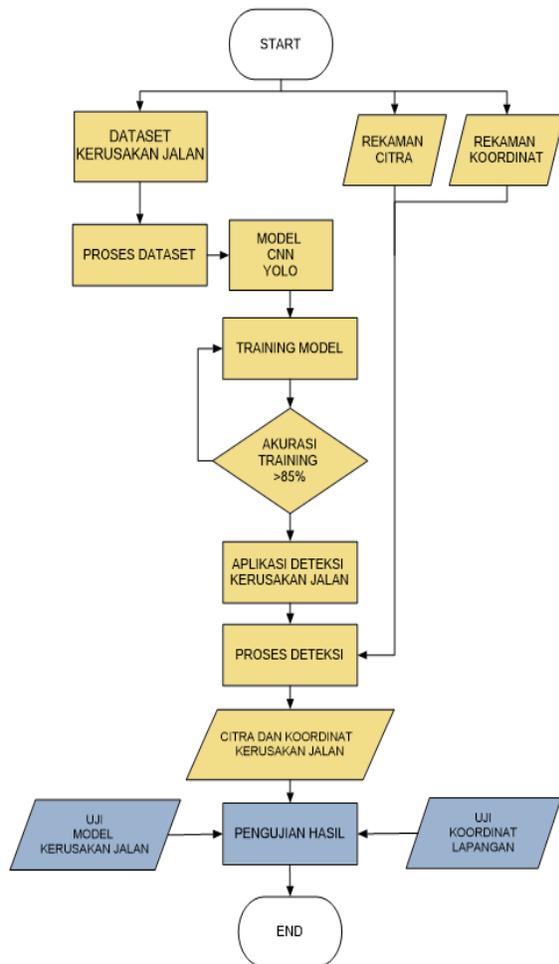
(Maeda *et al.*, 2018) membahas tentang deteksi kerusakan permukaan jalan dengan menggunakan teknik pengolahan citra. Citra diambil menggunakan kamera smartphone yang dipasang pada kendaraan. Hasil uji coba menunjukkan bahwa jenis kerusakan dapat diklasifikasikan menjadi delapan jenis dengan menerapkan metode deteksi objek yang diusulkan.

Kajian ini bertujuan untuk merancang sistem deteksi kerusakan jalan dari hasil perekaman citra kamera. Citra yang digunakan merupakan video hasil rekaman dari kamera kendaraan, baik mobil atau sepeda motor. Jenis kerusakan yang dideteksi adalah retakan dan lubang serta tambahan berupa garis putih jalan. Hal ini diharapkan memperbaiki metode survey manual dan efisiensi dalam hal waktu dan sumberdaya.

## 2. Metode Penelitian

Metode yang digunakan dalam penelitian ini merupakan hasil pengembangan dari beberapa metode yang dilakukan oleh (Chen *et al.*, 2020) dan (Maeda *et al.*, 2018), seperti yang tergambar pada diagram alir penelitian (Gambar 1). Pengambilan data video kerusakan jalan dilakukan dengan kamera video yang diambil menggunakan kamera mirrorless DSLR. Kamera, yang dipasang di mobil. Kamera resolusi tinggi DSLR digunakan untuk mendapatkan rekaman detail objek berupa gambar kerusakan jalan, baik berupa lubang atau retakan. Dengan demikian, proses pengenalan objek akan lebih akurat daripada kamera dengan resolusi lebih rendah.

Secara bersamaan digunakan alat Global Navigation Sattelite System (GNSS) untuk menentukan posisi perekaman citra. Diharapkan agar posisi kerusakan jalan yang terdeteksi dapat dicari kembali di lapangan dengan cepat. Data lokasi dapat diambil menggunakan *receiver* GNSS yang dipasang pada atap mobil. Konfigurasi pemasangan kedua alat tersebut diilustrasikan melalui Gambar 2. *Receiver* GNSS dan kamera dipasang pada atap mobil supaya tidak terjadi bias dalam menangkap sinyal dari satelit geodesi. Kamera yang digunakan diposisikan di belakang mobil dengan



Gambar 1. Diagram Alir Penelitian

menghadap ke arah jalan supaya gambaran jalan yang saat itu telah dilalui oleh mobil langsung terekam pada hasil video.

Dataset kerusakan jalan dari *Global Road Damage Detection Challenge (GRDDC)* digunakan untuk membangun sampling deteksi objek. Data 26336 buah citra jalan yang dikumpulkan dari India, Jepang, dan Republik Ceko untuk deteksi kerusakan jalan biasa dalam gambar digital (Zhang *et al.*, 2020). Dataset kerusakan jalan ini merupakan kumpulan data dari berbagai anggota forum dan dinyatakan bebas akses (*open source*). Kelas anotasi kerusakan jalan pada dataset GRDDC secara detail terlihat pada Tabel 1. Dataset ini akan digunakan sebagai *sampling* pengenalan objek real time di dalam aplikasi YOLO. YOLO adalah singkatan dari *You Only Look Once* yang merupakan sebuah aplikasi *Open Source* yang digunakan untuk mendeteksi objek secara *realtime* dari data citra. Aplikasi YOLO sudah dikembangkan dengan banyak versi. Riset ini akan menggunakan YOLO versi 4 yang dikenal dengan sebutan YOLO-V4.

YOLO-V4 (*You Only Look Once*) telah banyak digunakan sebagai algoritma dalam mendeteksi objek dalam suatu citra dengan cepat serta akurat. YOLO merupakan sebuah algoritma aplikasi open source. Ia merupakan sistem deteksi objek secara *real time* pada gambar atau video (Redmon *et al.*, 2016). Sistem jaringan ini membagi citra menjadi beberapa bagian dan memprediksi batas wilayah dan probabilitas setiap bagian. Hasil prediksi YOLO lebih cepat dari model CNN lainnya seperti R-CNN dan Faster R-CNN.

### 3. Hasil dan Pembahasan

#### 3.1 Deteksi Kerusakan Jalan

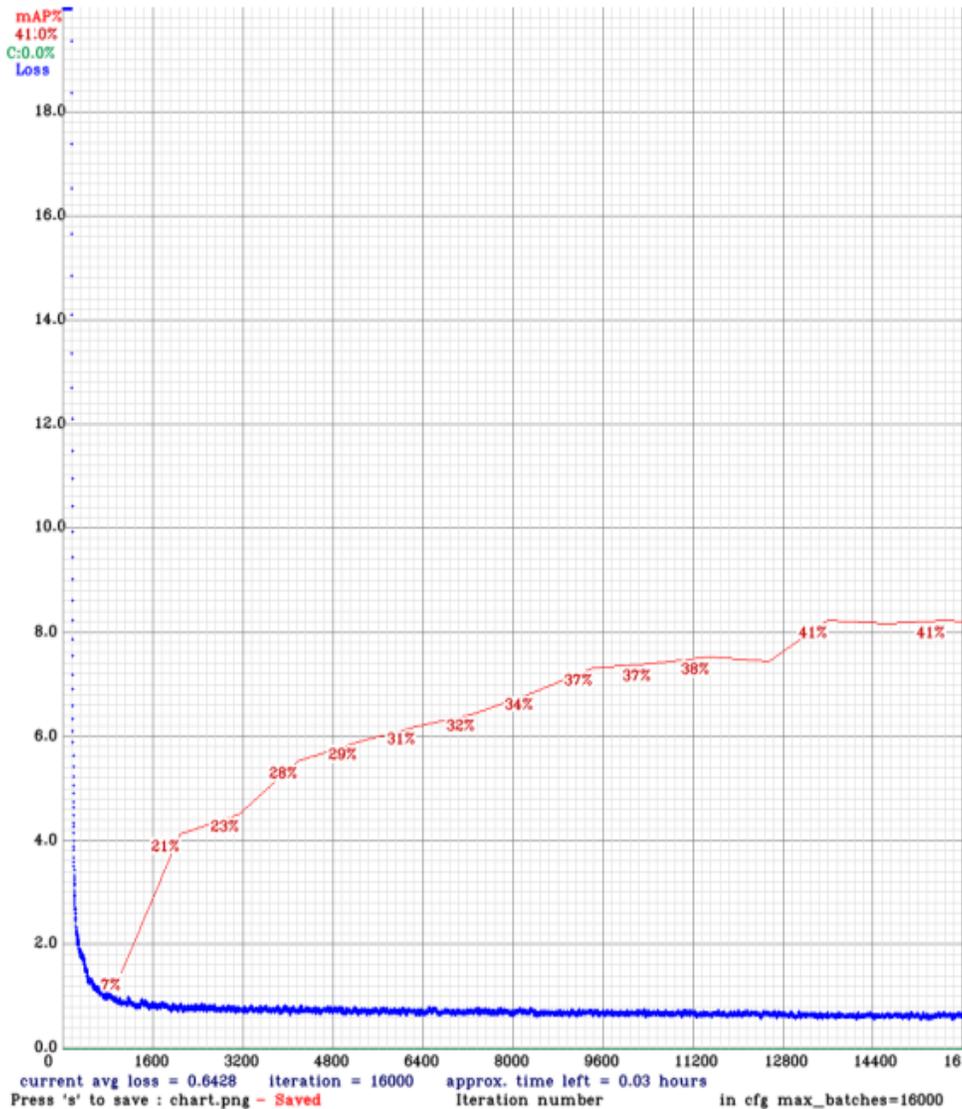
Model *Deep Learning* menggunakan algoritma YOLOv4-Tiny. Algoritma ini bersifat bebas akses untuk mendeteksi kelas kerusakan jalan dari citra terekam. Model kelas kerusakan jalan dibangun dengan dataset



Gambar 2. Pemasangan Alat akuisisi data lapangan

Tabel 1. Kategori Kerusakan Jalan dan Kode Dataset GDDRC (Maeda *et al.*, 2018)

	Tipe Kerusakan		Detail	Kode
Retak	Linier	Longitudinal	Bekas roda kendaraan	D00
		(membujur)	Sambungan konstruksi	D01
		Lateral (melintang)	Interval sama	D10
			Sambungan konstruksi	D11
	Retak Buaya	parsial dan menyeluruh pada perkerasan	D20	
Kerusakan lainnya			Benjolan, lubang	D40
			Zebra Cross Kabur	D43
			Garis putih Kabur	D44

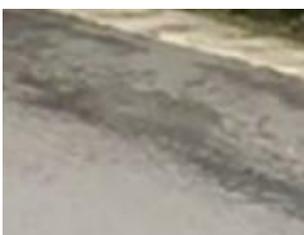
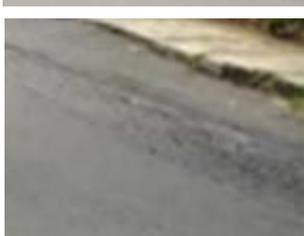


Gambar 3. Grafik Hasil Training Model YOLO

GRDDC yang diunduh dari *IEEE Road Damage Dataset*, sebanyak 10.250 gambar. Proses training dataset dilakukan dengan 16.000 iterasi dalam YOLOv4-Tiny.

Jumlah iterasi yang digunakan untuk model YOLO sebanyak 2.000 kali jumlah kelas yang akan diidentifikasi (Bochkovskiy, Wang and Liao, 2020).

**Tabel 2.** Sebagian sampel data perbandingan model dan lapangan untuk Matriks Konfusi

Kelas YOLO	Gambar YOLO	Kelas Validasi	Gambar Validasi	Keterangan
D00		D00		Jalan retak memanjang, kerusakan ringan
D20		D20		Jalan retak memanjang, perlu perbaikan
D20		D20		Jalan berlubang memanjang, perlu ditambal
D20		D20		Jalan retak memanjang, perlu perbaikan
D20		D20		Jalan retak memanjang, perlu perbaikan

Model dataset yang dihasilkan terlihat pada Gambar 3. Model ini memiliki besaran *mean Average Precision* (mAP) sebesar 41% dan nilai *average loss* sebesar 0,6428. Nilai mAP yang didapat sebesar 41% kerna dataset yang digunakan sedikit sulit dikenali oleh mesin. Hasil training dari model yang telah dibuat kemudian digunakan untuk mengidentifikasi kerusakan jalan dari rekaman video.

Pada tahapan selanjutnya, model *Deep learning* YOLOv4-Tiny menggunakan GRDDC IEEE *Road Damage Dataset* mampu mendeteksi kerusakan jalan berdasarkan kelas yang ada pada dataset yang digunakan. Hal tersebut dapat dilihat pada salah satu citra hasil deteksi pada Gambar 4. Kelas kerusakan jalan di deskripsikan dengan kode sesuai Tabel 1 yang berkaitan dengan Kategori Kerusakan Jalan dan Kode Dataset GDDRC (Maeda et al., 2018).



Gambar 4. Identifikasi kerusakan jalan dengan model yang dihasilkan



Gambar 5. Persebaran Kerusakan Jalan Sepanjang Jalan Setiabudi Sampai Jalan Perintis Kemerdekaan Kota Semarang

Hasil identifikasi kerusakan jalan dengan citra video pada Gambar 4 selanjutnya dilengkapi informasi tambahan hasil pengukuran receiver GNSS berupa kecepatan, jarak, waktu, dan koordinat. Dengan demikian, posisi persebaran titik kerusakan jalan yang terdeteksi dapat diplot di peta, seperti terlihat pada Gambar 5.

Data kerusakan jalan yang di dapatkan menjadi dasar tindakan selanjutnya. Jalan yang mengalami kerusakan dapat didatangi kembali secara sekilas. Lokasi jalan sendiri sudah tertandai sebarannya di peta (Gambar 5) karena memanfaatkan GoogleMap.

Data yang telah diperoleh inilah yang dapat digunakan sebagai dasar analisa penanganan yang

**Tabel 3.** Sebagian sampel data perbandingan koodinat deteksi kerusakan pada model dan lapangan

YOLO X	YOLO Y	VALIDASI X	VALIDASI Y	DELTA X	DELTA Y
435322,97	9222848,96	435317,28	9222852,93	5,69	-3,97
435203,68	9222866,49	435191,60	9222876,53	12,08	-10,04
435118,42	9222897,74	435111,87	9222900,28	6,55	-2,54
435005,91	9222919,56	435014,38	9222918,81	-8,47	0,75
434837,42	9222987,04	434840,40	9222986,51	-2,98	0,53
434829,91	9222989,76	434831,90	9222988,71	-1,99	1,05
434956,96	9222921,57	434958,19	9222921,71	-1,23	-0,14
434948,17	9222924,49	434948,54	9222924,82	-0,37	-0,33
.....	.....	.....	.....	.....	.....
.....	.....	.....	.....	.....	.....
.....	.....	.....	.....	.....	.....
434619,94	9222986,20	434624,21	9222981,04	-4,27	5,16
432897,82	9225150,88	432904,81	9225149,04	-6,99	1,84
432934,22	9225174,18	432937,33	9225173,55	-3,11	0,63

diperlukan. Penanganan lanjut terhadap kerusakan didasarkan pada jenis dan jumlah kerusakan ada. Penanganan kerusakan tidak dibahas di penelitian ini, hanya sebagai rekomendasi ke pemangku kebijakan.

3.2 Uji Hasil Deteksi

Hasil identifikasi dari model yang dibuat kemudian dibandingkan dengan kenyataan di lapangan. Analisis akurasi model yang dilakukan menggunakan *Confusion Matrix*. Matriks Konfusi disebut juga dengan matriks *error*, matriks tersebut dibuat dalam tabel yang berisi data untuk menggambarkan nilai akurasi model kelas deteksi terhadap data uji (Sharma, 2018). Jumlah nilai benar atau salah dibandingkan dengan seluruu jumlah nilai dalam kelas. Sehingga matriks konfusi dapat memberikan prediksi akurasi model yang dibuat terhadap validasi di lapangan. Pada Tabel 2 disusun sampel perbandingan untuk matriks konfusi deteksi model Deep learning YOLOv4-Tiny dengan GRDDC IEEE Road Damage Dataset yang dibuat di penelitian ini.

Analisis matriks konfusi di penelitian ini diambil 85 sampel, jumlah sampel dengan derajat kepercayaan 90%. Hasil matriks konfusi di penelitian ini adalah:

$$\begin{aligned} \text{Overall Accuracy} &= 0,8823529412 = 88\% \\ \text{Kappa Accuracy} &= 0,8600131752 = 86\% \end{aligned}$$

Hasil akurasi matriks konfusi telah memenuhi standar dari Congalton and Green (2019) dimana syarat akurasi nilai *Overall Accuracy* lebih besar dari 85% dan nilai *Kappa Accuracy* lebih besar dari 80%.

Analisis berikutnya adalah uji validasi posisi (koordinat) atau dapat disebut analisis akurasi keruangan.

Pengujian dilakukan dengan menghitung selisih lokasi dari model deteksi dengan lokasi validasi. Hasil perbandingan posisi koordinat berupa RMSE (*root-mean-square error*).

Definisi secara matematis RMSE bisa dikatakan sebagai simpangan baku, yang rumusnya adalah akar kuadrat dari rata – rata jumlah kuadrat residual (Charles D. Ghilani, 2018).

$$\sigma = \sqrt{\frac{\sum_{i=0}^n E_i^2}{n}} \tag{1}$$

Persamaan (1) dimana  $\sigma$  adalah RMSE (*root-mean-square error*) atau juga disebut *standard error*;  $\sum_{i=0}^n E_i^2$  adalah jumlah kuadrat kesalahan dalam suatu pengamatan; dan  $n$  adalah jumlah pengukuran yang dilakukan.

Penghitungan terhadap 85 sampel posisi koordinat dilakukan. Sebagian sampel tersaji pada Tabel 3. Penghitungan menghasilkan nilai seperti berikut:

$$\begin{aligned} \text{RMSE X} &= 4,75203622 \text{ meter} \\ \text{RMSE Y} &= 2,988408981 \text{ meter} \\ \text{RMSE Jarak} &= 5,6135939 \text{ meter} \end{aligned}$$

Dari nilai nilai yang didapatkan, terdapat perbedaan titik hasil model dengan data uji lapangan sebesar 5,6 meter. Dengan demikian sa dikatakan akurasi spasial untuk sebaran lokasi titik kerusakan jalan adalah  $\pm 5,6$  meter.

4. Kesimpulan

Uji coba deteksi kerusakan jalan berbasis *Deep Learning* telah dilakukan menggunakan model YOLOv4Tiny dengan memanfaatkan dataset IEEE Road

*Damage Detection.* Model deteksi ini memiliki besaran *mean Average Precision* (mAP) sebesar 41% dan *average loss* sebesar 0,6428. Besaran mAP yang didapat sebesar 41%. Dengan demikian model ini dapat digunakan untuk identifikasi kerusakan jalan dari video maupun gambar, dengan menambahkan data spasial. Dengan kombinasi ini, maka bisa didapatkan titik persebaran kerusakan jalan yang teridentifikasi model. Uji akurasi model dengan matriks konfusi dengan 85 sampel. Model memiliki nilai *overall accuracy* sebesar 88% dan nilai *kappa accuracy* sebesar 86%. Secara tinjauan akurasi hasil ini sudah sangat baik. Lokasi kerusakan jalan dalam model di uji dengan validasi posisi menggunakan GPS tangan (*hand-held*) menghasilkan nilai RMSE sebesar 5,6 meter. Hasil ini sudah cukup baik karena perbedaan lokasi  $\pm 5,6$  meter masih bisa dilihat secara visual disekitar lokasi.

#### Ucapan Terima Kasih

Penghargaan sebesar-besarnya dari penulis disampaikan kepada Program Doktor Teknik Sipil, Teknik Geodesi, dan Fakultas Teknik UNDIP yang secara langsung maupun tidak telah membantu penulis menyelesaikan tulisan ini.

#### Daftar Pustaka

- Biros, D., Sharma, M. and Biros, J. (2019) 'Vulnerability and risk mitigation in AI and machine learning', *Cutter business technology journal*, 32(8).
- Bochkovskiy, A., Wang, C.Y. and Liao, H.Y.M. (2020) 'YOLOv4', *CVPR Workshop on The Future of Datasets in Vision* [Preprint].
- Charles D. Ghilani (2018) *Adjustment Computations : Spatial Data Analysis*. Sixth Edit. Hoboken, New Jersey: John Wiley & Sons, Inc.
- Chen, Q. *et al.* (2020) 'Road damage detection and classification using mask R-CNN with DenseNet backbone', *Computers, Materials and Continua*, 65(3). Available at: <https://doi.org/10.32604/cmc.2020.011191>.
- Congalton, R.G. and Green, K. (2019) 'Analysis of Differences in the Error Matrix', in *Assessing the Accuracy of Remotely Sensed Data*. Available at: <https://doi.org/10.1201/9780429052729-9>.
- Fan, R. and Liu, M. (2020) 'Road Damage Detection Based on Unsupervised Disparity Map Segmentation', *IEEE Transactions on Intelligent Transportation Systems*, 21(11), pp. 4906–4911. Available at: <https://doi.org/10.1109/TITS.2019.2947206>.
- Kamilaris, A. and Prenafeta-Boldú, F.X. (2018) 'A review of the use of convolutional neural networks in agriculture', *Journal of Agricultural Science*. Available at: <https://doi.org/10.1017/S0021859618000436>.
- Kiranyaz, S. *et al.* (2021) '1D convolutional neural networks and applications: A survey', *Mechanical Systems and Signal Processing*, 151. Available at: <https://doi.org/10.1016/j.ymssp.2020.107398>.
- Lillesand, T.M. and Kiefer, R.W. (2008) *Remote sensing and image interpretation, Distribution*.
- Maeda, H. *et al.* (2018) 'Road Damage Detection and Classification Using Deep Neural Networks with Smartphone Images', *Computer-Aided Civil and Infrastructure Engineering*, 33(12). Available at: <https://doi.org/10.1111/mice.12387>.
- Pan, Y. *et al.* (2021) 'Monitoring Asphalt Pavement Aging and Damage Conditions from Low-Altitude UAV Imagery Based on a CNN Approach', *Canadian Journal of Remote Sensing*, 47(3), pp. 432–449. Available at: <https://doi.org/10.1080/07038992.2020.1870217>.
- Pisharoty, P.R. (1983) 'Introduction to remote sensing', *Proceedings of the Indian Academy of Sciences Section C: Engineering Sciences* [Preprint]. Available at: <https://doi.org/10.1007/BF02842927>.
- Redmon, J. *et al.* (2016) 'You only look once: Unified, real-time object detection', *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-Decem, pp. 779–788. Available at: <https://doi.org/10.1109/CVPR.2016.91>.
- Rego, A. *et al.* (2018) 'An Intelligent System for Video Surveillance in IoT Environments', *IEEE Access*, 6. Available at: <https://doi.org/10.1109/ACCESS.2018.2842034>.
- Sharma, A. (2018) 'Confusion Matrix in Machine Learning', *Www.Geeksforgeeks.Org* [Preprint].
- Wegman, F. (2017) 'The future of road safety: A worldwide perspective', *IATSS Research*, 40(2), pp. 66–71. Available at: <https://doi.org/10.1016/j.iatssr.2016.05.003>.
- Zhang, X. *et al.* (2020) 'Exploring the Tricks for Road Damage Detection with A One-Stage Detector', in *2020 IEEE International Conference on Big Data (Big Data)*. IEEE, pp. 5616–5621. Available at: <https://doi.org/10.1109/BigData50022.2020.9377923>.
- Zimmermann, T. *et al.* (2017) 'When road-kill hotspots do not indicate the best sites for road-kill mitigation', *Journal of Applied Ecology*, 54(5). Available at: <https://doi.org/10.1111/1365-2664.12870>.