

**IDENTIFIKASI KERUSAKAN JALAN MENGGUNAKAN METODE *DEEP LEARNING (DL) MODEL CONVOLUTIONAL NEURAL NETWORKS (CNN)***

Yoga Triardhana <sup>\*</sup>, Bandi Sasmito, Firman Hadi

Departemen Teknik Geodesi Fakultas Teknik Universitas Diponegoro  
 Jl. Prof. Sudarto, SH, Tembalang, Semarang Telp.(024)76480785, 76480788  
 Email: [yogatriardhana@student.undip.ac.id](mailto:yogatriardhana@student.undip.ac.id)

**ABSTRAK**

Jalan merupakan infrastruktur yang penting untuk keberlangsungan kehidupan manusia sehari-hari dalam transportasi darat. Semua kegiatan transportasi di darat berjalan di atas jalan sehingga jalan mempunyai manfaat yang besar bagi kehidupan manusia. Jaringan jalan memiliki peranan strategis dalam pembangunan, untuk itu harus dikelola sebaik mungkin agar dapat dirasakan fungsinya seperti yang diharapkan (Direktorat Pekerjaan Umum, 2005). Semua kegunaan jalan tersebut sangat menguntungkan bagi kelancaran kegiatan manusia namun terdapat risiko kecelakaan yang dapat terjadi di jalan. Salah satu penyebabnya adalah karena kondisi jalan yang tidak layak untuk digunakan dikarenakan kondisi jalan yang rusak. Sebanyak 10 sampai 20 persen dari kecelakaan di jalan disebabkan oleh kerusakan jalan (Bambang Susanto kepada Kompas, 2016). Pengawasan kondisi jalan memiliki hambatan karena jumlah jalan yang telah dibangun berjumlah banyak sehingga dapat memperlambat waktu yang diperlukan untuk mengetahui kondisi jalan terkini. Penggunaan DL untuk identifikasi objek telah banyak dilakukan, salah satunya penerapan model CNN untuk identifikasi kerusakan jalan (Maeda, 2018). Model CNN yang dihasilkan pada penelitian ini digunakan untuk mengidentifikasi kerusakan jalan di sepanjang Jalan Karangrejo sampai Jalan Lamongan Raya dan Jalan Setia Budi sampai Jalan Perintis Kemerdekaan. Hasil identifikasi model lalu dilakukan analisis akurasi hasil dari model CNN dengan data validasi. Keluaran yang dihasilkan berupa jenis kerusakan jalan beserta lokasi keberadaan kerusakan tersebut. Model CNN yang dihasilkan mampu mengidentifikasi sebanyak 205 titik kerusakan jalan dari lokasi penelitian sepanjang 11,7 kilometer beserta kelas kerusakannya. Hasil penerapan model CNN ini berdasarkan hasil validasi memiliki ketelitian spasial dengan nilai RMSE sebesar 8,38 meter serta memiliki nilai *overall accuracy* sebesar 85,34% dan *kappa* sebesar 82,36% dengan menggunakan *confusion matrix*. Hal tersebut menunjukkan bahwa model identifikasi kerusakan jalan yang dihasilkan layak digunakan dan mampu membantu efisiensi dalam pemantauan kondisi jalan terkini sehingga perbaikan jalan dapat segera dilakukan.

**Kata Kunci :** *Convolutional Neural Networks, Deep Learning, Identifikasi*

**ABSTRACT**

*Roads are an important infrastructure for daily human life in land transportation. All land transportation activities run on roads so that roads have great benefits for human life. The road network has a strategic role in development, for that it must be managed as well as possible so that its function can be felt as expected (Directorate of Public Works, 2005). All of these road uses are very beneficial for the smooth running of human activities, but there is a risk of accidents that can occur on the road. One of the reasons is because the road conditions are not suitable for use due to damaged road conditions. As many as 10 to 20 percent of road accidents are caused by road damage (Bambang Susanto to Kompas, 2016). Monitoring of road conditions has obstacles because the number of roads that have been built is so many that it can slow down the time needed to find out the current road conditions. The use of DL for object identification has been widely used, one of which is the application of the CNN model to identify road damage (Maeda, 2018). The CNN model generated in this study was used to identify road damage along Jalan Karangrejo to Jalan Lamongan Raya and Jalan Setia Budi to Jalan Perintis Kemerdekaan. The results of model identification are then analyzed for the accuracy of the results from the CNN model with validation data. The resulting output is the type of road damage and the location of the damage. The CNN model produced was able to identify as many as 205 road damage points from the research location along 11.7 kilometers along with the damage class. The results of the application of this CNN model based on the validation results have spatial accuracy with an RMSE value of 8.38 meters and have an overall accuracy value of 85.34% and a kappa of 82.36% using a confusion matrix. This shows that the resulting road damage identification model is feasible to use and is able to help efficiency in monitoring current road conditions so that road repairs can be carried out immediately.*

**Keywords :** *Convolutional Neural Networks, Deep Learning, Identification*

<sup>\*</sup>) Penulis Penanggung Jawab

## I. Pendahuluan

### I.1 Latar Belakang

Jaringan jalan memiliki peranan strategis dalam pembangunan, untuk itu harus dikelola sebaik mungkin agar dapat dirasakan fungsinya seperti yang diharapkan (Direktorat Pekerjaan Umum, 2005). Sebanyak 10 sampai 20 persen dari kecelakaan di jalan disebabkan oleh kerusakan jalan (Bambang Susanto kepada Kompas, 2016). Jaringan jalan supaya dapat bertahan kondisinya perlu dilakukan pengelolaan pemeliharaan sepanjang waktu dikarenakan penggunaannya setiap hari sebagai infrastruktur utama dalam transportasi darat. Pengawasan terhadap kondisi jalan menjadi penting untuk mengurangi angka kecelakaan akibat kondisi jalan yang tidak layak bagi para pengemudi kendaraan. Jaringan jalan yang berjumlah sangat banyak menjadi masalah jika harus melakukan pengawasan sepanjang waktu terlebih pada suatu wilayah yang sangat luas. Identifikasi kerusakan jalan secara manual yang selama ini dilakukan membutuhkan waktu yang lama dikarenakan harus dilakukan survei lapangan ke seluruh lokasi jaringan jalan.

Pemantauan kondisi jalan secara manual dengan tenaga manusia yang digunakan saat ini membutuhkan waktu dan tenaga yang cukup besar padahal seharusnya dapat dilakukan otomatisasi dalam pekerjaan tersebut. Inovasi untuk metode pemantauan kondisi jalan yang lebih efektif dan efisien sangat diperlukan. Perkembangan teknologi komputasi sekarang ini yang sedang banyak diteliti salah satunya adalah mengenai penggunaan kecerdasan buatan dalam melakukan pekerjaan yang dapat dilakukan oleh manusia, termasuk pemantauan kondisi jalan.

Penemuan konsep kecerdasan buatan telah lama ditemukan namun menjadi lebih banyak dibahas oleh umum terakhir ini dikarenakan penerapannya yang sudah terdapat di banyak bidang. Penggunaan model CNN (*Convolutional Neural Networks*) untuk identifikasi kerusakan jalan melalui kamera *smartphone* berhasil dilakukan (Maeda, 2018). Hasil model CNN yang digunakan dapat mengidentifikasi pada kerusakan jalan namun tidak memiliki informasi lokasi dari kerusakan yang didapatkan sehingga tidak dapat digunakan untuk analisis secara spasial.

Penelitian ini menggunakan teknologi pengolahan citra digital dengan penerapan model CNN pada beberapa jalan di wilayah Kota Semarang yaitu sepanjang Jalan Setia Budi sampai Jalan Perintis Kemerdekaan serta Jalan Karangrejo sampai Jalan Lamongan Raya. Penggunaan metode ini lebih efektif dan efisien dibandingkan pemantauan jalan secara manual karena dengan metode ini dapat dijalankan secara otomatis dan tanpa perlu tenaga manusia dalam penggunaannya. Penerapan model CNN dengan menggunakan kamera dan *receiver* GNSS akan mampu mendapatkan hasil identifikasi jenis kerusakan jalan beserta lokasinya sehingga dapat dilakukan analisis secara spasial oleh pihak berwenang sehingga perbaikan jalan yang rusak tersebut bisa cepat dilaksanakan supaya dapat mengurangi kerugian akibat jalan yang rusak.

### I.2 Rumusan Masalah

Penelitian ini mengangkat beberapa rumusan masalah dari sebagai berikut:

1. Bagaimana hasil penerapan model CNN untuk identifikasi kerusakan jalan?
2. Bagaimana hasil analisis validasi dari penerapan model CNN untuk identifikasi kerusakan jalan yang dihasilkan?

### I.3 Tujuan Penelitian

Maksud dan tujuan akhir dilakukan penelitian ini adalah:

1. Menerapkan model CNN untuk identifikasi objek berupa kerusakan jalan.
2. Mengetahui akurasi hasil identifikasi objek dari model CNN untuk kerusakan jalan.

### I.4 Batasan Penelitian

Batasan dalam penelitian ini digunakan agar fokus pada penelitian dan tidak terlalu luas. Batasan penelitian ini adalah:

1. Penelitian ini mengambil lokasi studi di sepanjang Jalan Karangrejo sampai Jalan Lamongan Raya serta di sepanjang Jalan Setia Budi sampai Jalan Perintis Kemerdekaan.
2. Pengambilan data video menggunakan kamera *smartphone*.
3. Data lokasi kerusakan jalan didapatkan dengan menggunakan *receiver* GNSS yang terkoneksi dengan CORS Badan Informasi Geospasial menggunakan metode NTRIP.
4. Model CNN yang digunakan pada penelitian ini adalah model YOLOv4 Tiny.
5. Kerusakan jalan yang dilakukan identifikasi pada penelitian ini berdasarkan sumber data dari IEEE Road Damage Dataset.
6. Analisis validasi menggunakan *confusion matrix* dan RMSE dari model CNN yang telah dibuat dibandingkan dengan hasil validasi dari survei lapangan.

## II. Tinjauan Pustaka

### II.1 Konsep Jalan

Kamus Besar Bahasa Indonesia mengartikan jalan sebagai suatu sarana atau tempat untuk lalu lintas kendaraan. Jalan adalah sarana transportasi darat baik berupa jalanan itu sendiri maupun bangunan pendukung yang digunakan untuk lalu lintas kecuali untuk lori, kereta api, maupun jalur kabel. Jalan sesuai dengan fungsinya dibagi menjadi jalan khusus dan jalan umum. Jalan khusus merupakan jalan yang dibangun dan digunakan untuk kepentingan suatu instansi atau organisasi tertentu, sedangkan jalan umum merupakan jalan yang dapat digunakan untuk kepentingan lalu lintas kendaraan umum. Pengelompokan jenis jalan berdasarkan statusnya dibagi menjadi sebagai berikut (Pasal 9 Undang-Undang Nomor 38 Tahun 2004 tentang Jalan):

1. Jalan Nasional, yaitu jaringan jalan yang menjadi penghubung antar ibukota provinsi, serta jalan tol.
2. Jalan Provinsi, yaitu jaringan jalan primer yang menjadi penghubung antar ibukota kabupaten/kota
3. Jalan Kabupaten, yaitu jaringan jalan lokal dan primer yang menjadi penghubung antar ibukota kabupaten dengan ibukota kecamatan dan antar kecamatan.
4. Jalan Kota, yaitu jaringan jalan umum dan sekunder yang menjadi penghubung antar pusat kota dan kecamatan lingkup kota.
5. Jalan Desa, merupakan jalan yang menjadi penghubung antar daerah permukiman di desa.

**II.2 Kerusakan Jalan**

Kerusakan jalan merupakan suatu kerusakan pada lapis perkerasan jalan yang dibagi menjadi dua macam (Direktorat Pekerjaan Umum, 2005), yaitu:

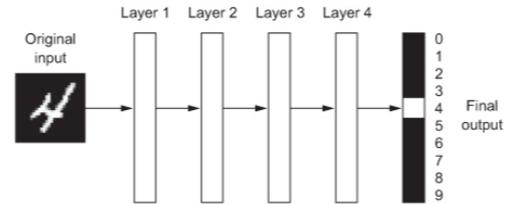
1. Kerusakan Struktural  
Kerusakan jenis ini merupakan kerusakan yang terjadi pada struktur jalan sehingga jalan tidak mampu lagi menopang beban lalu lintas yang lewat di atasnya. Perlu dilakukan perbaikan untuk memperkuat struktur jalan supaya dapat menopang beban lalu lintas.
2. Kerusakan Fungsional  
Kerusakan jenis ini terdapat pada permukaan jalan yang membuat fungsi jalan tidak optimal. Perkerasan jalan masih dapat menopang beban lalu lintas di atasnya tetapi kenyamanan pengguna lalu lintas menjadi terganggu.

**II.3 Deep Learning (DL)**

Deep Learning adalah bagian spesifik dari Machine Learning dimana dianggap lebih dalam karena banyaknya layer yang digunakan dalam model dari data. Pada DL representasi dari layer dipelajari dari model yang bernama neural networks yang memiliki asal nama dari referensi jaringan syaraf biologis. DL adalah sebuah model matematis untuk belajar representasi data yang tersedia jika berdasarkan tujuan analisis data (Francois Chollet, 2017).

Penggunaan DL memiliki kegunaan utama untuk klasifikasi suatu gambar adalah dengan penggunaan lapisan ganda yang mampu menyaring data yang dimasukkan seperti pada Gambar 1. Data masukan yang telah disaring lalu akan menghasilkan hasil akhir yang sesuai berdasarkan tingkat akurasi yang didapatkan.

Ditinjau dari kegunaannya untuk analisis citra, DL dapat digunakan untuk klasifikasi gambar (single object), mengetahui lokasi objek (hasil berupa bounding box objek yang terdapat pada citra, serta identifikasi objek (mengetahui lokasi dan memberi nama kelas objek tersebut). Tingkatan selanjutnya dari semua itu adalah segmentasi objek dimana objek yang diidentifikasi akan diberikan blok pada piksel objek tersebut sebagai ganti dari dibuatnya bounding box.



**Gambar 1** Klasifikasi dengan Deep Learning (Francois Chollet, 2017)

**II.4 Convolutional Neural Networks (CNN)**

CNN merupakan salah satu jenis neural networks dalam Machine Learning yang memiliki paling sedikit satu convolutional layer pada modelnya. CNN sukses banyak digunakan untuk menyelesaikan beberapa permasalahan terutama dalam analisis gambar. Model ini menggunakan convolutional layer yaitu layer yang akan digunakan untuk melakukan filter pada matrik masukan. Misalkan terdapat matrik input 5x5 seperti pada Gambar 2 dan menggunakan convolutional layer matrik 3x3 seperti pada Gambar 3. Matrik convolutional layer tersebut akan melakukan proses convolutional filtering terhadap matrik masukan (Google Developers, 2019).

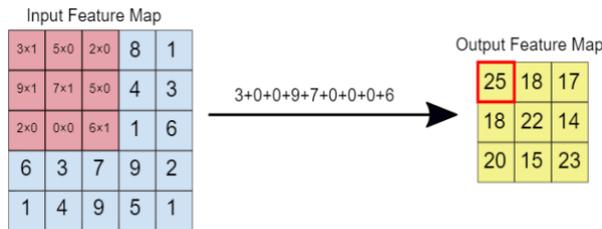
3	5	2	8	1
9	7	5	4	3
2	0	6	1	6
6	3	7	9	2
1	4	9	5	1

**Gambar 2** Data Masukan (Google Developer, 2019)

1	0	0
1	1	0
0	0	1

**Gambar 3** Convolutional Filter (Google Developer, 2019)

Proses penyaringan dengan menggunakan convolutional filter dilakukan secara merata pada setiap grid piksel. Pada Gambar 4 data masukan setelah melalui proses filtering akan menghasilkan matrik ukuran 3x3. Proses filtering ini dilakukan dengan cara melakukan perkalian pada data masukan pada piksel yang terkena proses filtering oleh convolutional filter. Hasil perkalian keduanya kemudian dilakukan penjumlahan untuk kemudian dimasukkan ke dalam matrik luaran pada pada grid yang diproses.



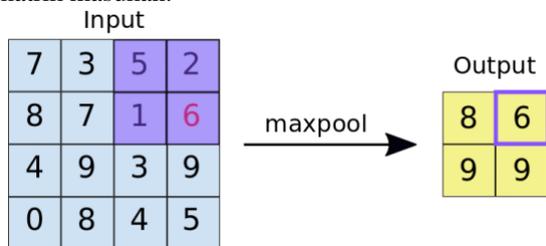
**Gambar 4 Convolutional Filtering**  
(Google Developer, 2019)

Hasil dari proses *filtering* didapatkan matrik yang telah disaring kemudian diproses dengan menggunakan transformasi *Rectified Linear Unit* (ReLU). Transformasi ini memiliki fungsi sebagai berikut:

$$F(x) = \max(0, x)$$

Fungsi ini memisahkan  $x$  adalah semua nilai pada hasil proses *filtering*, kemudian untuk nilai  $x > 0$  maka nilai akan tetap sama menjadi nilai tersebut dan untuk nilai  $x < 0$  maka nilai tersebut akan menjadi 0.

Transformasi ReLU dilakukan kemudian model CNN akan mengambil sampel dari nilai terbesar dari sebuah proses penyaringan atau biasa disebut Max Pooling. Proses ini memiliki kemiripan dengan proses *convolutional filtering* yaitu pada penggunaan matrik untuk penyaringannya. Matrik penyaringan pada proses ini disebut dengan istilah *size*. Pada **Gambar 5** ukuran matrik berupa matrik 2x2 dan menyaring matrik masukan. Perbedaan proses ini dengan proses *convolutional filtering* adalah proses penyaringan dilakukan menyeluruh ke semua grid tetapi grid yang telah disaring tidak dilakukan penyaringan ulang. Hasil penyaringan ukuran matrik berupa nilai terbesar dari matrik masukan.



**Gambar 5 Proses Max Pooling**  
(Google Developer, 2019)

Semua *layer* akan dihubungkan secara penuh setelah proses *Max Pooling* selesai. Hubungan antar *layer* ini yang kemudian akan menentukan hasil proses identifikasi. Secara umum hasil dari hubungan antar *layer* ini berupa probabilitas dengan nilai antara 0 sampai 1 untuk setiap label kelasnya.

### II.5 YOLO (You Only Look Once)

YOLO merupakan sebuah sistem deteksi objek pada waktu sebenarnya (Redmon, 2018). YOLO dikenal sebagai model deteksi objek yang sangat cepat dan akurat. Sistem menggunakan *single neural network* untuk mengolah satu citra utuh. Sistem jaringan ini membagi citra menjadi beberapa bagian dan memprediksi kotak batas dan probabilitas pada setiap bagian. Hasil prediksi menggunakan YOLO lebih cepat daripada model CNN lain seperti R-CNN maupun Faster R-CNN. Proses *training* dan prediksi dengan

menggunakan model YOLO menggunakan perangkat lunak Darknet yang ditulis dalam bahasa C++ dengan *backend* bahasa Python.

### II.6 IEEE Road Damage Dataset

IEEE *Road Damage Dataset* merupakan kumpulan seluruh data berupa gambar kerusakan jalan yang dikumpulkan oleh *Institute of Electrical and Electronic Engineers*. Kumpulan data tersebut didapatkan dari berbagai sumber dan bersifat *open source* untuk deteksi kerusakan jalan. Kumpulan data tersebut berasal dari data kerusakan jalan di Jepang, Ceko, dan India dengan 13376 gambar yang dikumpulkan. Data kerusakan jalan ini terdapat delapan kelas kerusakan yang akan digunakan seperti pada **Tabel 1**.

**Tabel 1 Kelas Kerusakan Jalan (Arya dkk, 2020)**

Tipe Kerusakan			Detail	Kode
Crack	Linear	Longitudinal	Retak memanjang, bekas roda kendaraan	D00
			Sambungan konstruksi	D01
	Lateral	Retak melintang	D10	
		Sambungan konstruksi	D11	
	Alligator Crack	Retak tidak beraturan	D20	
Kerusakan lainnya		Benjolan dan lubang	D40	
		Zebra cross pudar	D43	
		Marka jalan pudar	D44	

### II.7 Confusion Matrix

*Confusion Matrix* dalam bidang ML disebut juga dengan matrik kesalahan. Matrik tersebut berupa tabel yang digunakan untuk mendeskripsikan kemampuan model klasifikasi terhadap data yang tersedia (Sharma, 2020). Jumlah prediksi benar dan salah disimpulkan dengan jumlah nilai setiap kelas. Matrik tersebut dibagi menjadi hasil prediksi model dan kenyataan di lapangan. Nilai TP (*True Positive*) berupa banyaknya objek dalam suatu kelas yang pada kenyataan positif termasuk dalam kelas 1 dan hasil dari model yang dibuat juga memprediksi secara benar. Nilai FN (*False Negative*) merupakan banyak objek dari kelas 1 yang pada kenyataan positif termasuk dalam kelas 1 namun model memprediksi salah. Nilai FP (*False Positive*) merupakan banyaknya objek dari kelas 2 yang pada kenyataan termasuk dalam kelas 2 namun model memprediksi sebagai kelas 1. Nilai TN (*True Negative*) merupakan banyaknya objek dalam kelas 2 yang pada kenyataannya termasuk dalam kelas 2 dan model benar dalam memprediksinya.

**II.8 Uji Akurasi**

Uji geometri sebagai validasi pada koordinat hasil identifikasi dilakukan dengan cara melakukan uji RMSE (*Root Mean Square Error*). Pada pengukuran ini juga menggunakan standar akurasi relatif, dimana pengukuran ini membandingkan satu dengan lainnya secara proporsional. Maka uji geometri ini hanya menggunakan koordinat dari hasil model dan hasil validasi lapangan.

RMSE didapatkan dari proses antara nilai akar kuadrat total selisih ukuran kuadrat dengan jumlah ukuran yang digunakan. Definisi matematis dari RMSE mirip dengan simpangan baku, yaitu akar kuadrat dari rata – rata jumlah kuadrat residual (Soeta'at. 1994). Rumus menghitung RMSE dapat dilihat pada persamaan berikut:

$$RMSE = \sqrt{\frac{\sum(R-R_1)}{n}}$$

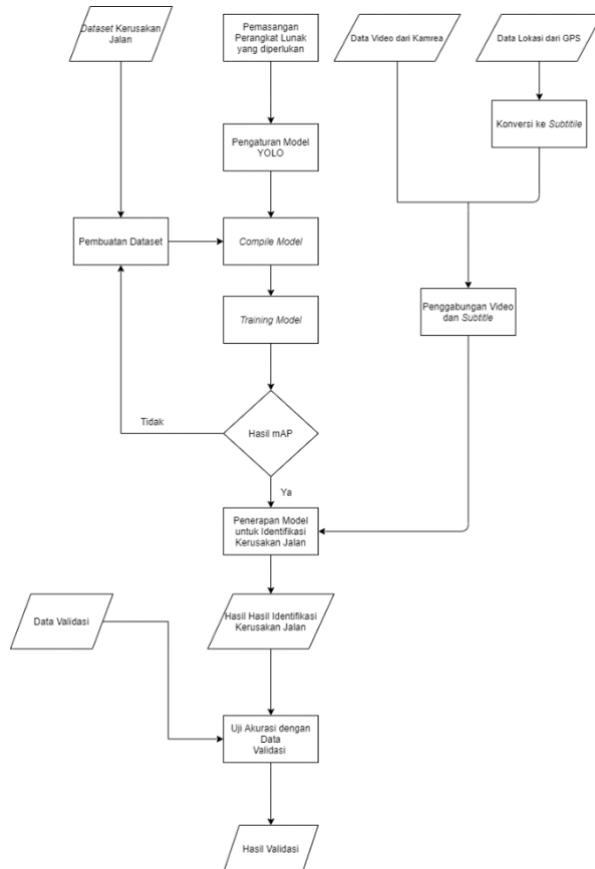
Keterangan:

- RMSE : *Root Mean Square Error*.
- R : Nilai yang dianggap benar.
- R<sub>1</sub> : Nilai hasil ukuran validasi.
- N : Banyak ukuran yang digunakan.

**III. Metodologi Penelitian**

**III.1 Diagram Alir Penelitian**

Diagram alir identifikasi kerusakan jalan dengan model CNN dapat dilihat pada **Gambar 6**.



**Gambar 6** Diagram Alir Penelitian

**III.2 Alat dan Bahan Penelitian**

Peralatan yang digunakan dalam penelitian ini sebagai berikut:

1. Perangkat Keras
  - a. Komputer dengan spesifikasi sebagai berikut:
    - OS : Ubuntu 18.04 LTS
    - Prosesor : Intel Core i7 3,4 GHz
    - RAM : 16 GB
    - GPU : NVIDIA GeForce GTX 1060
  - b. *Smartphone* Xiaomi Redmi Note 8
  - c. Topcon Hiper SR
2. Perangkat Lunak
  - a. Microsoft Office 2016
  - b. Darknet
  - c. OpenCV 4.5.1
  - d. GPSTabel
  - e. Tesseract
  - f. CUDA Toolkit 10.1
  - g. NTRIP Client

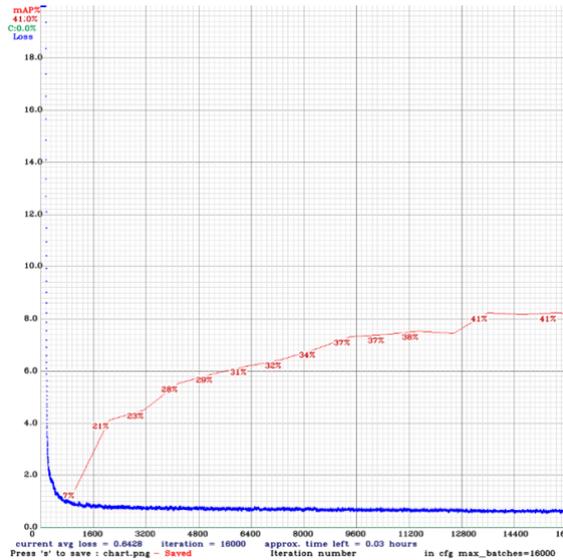
Data yang menunjang penelitian ini yaitu:

1. *Dataset* berupa gambar kerusakan jalan dari IEEE *Road Damage Detection Challenge 2020*.
2. Video perekaman sepanjang jalan yang menjadi lokasi pengamatan.
3. Data spasial diperoleh dengan menggunakan *receiver* GNSS.

**IV. Hasil dan Analisis**

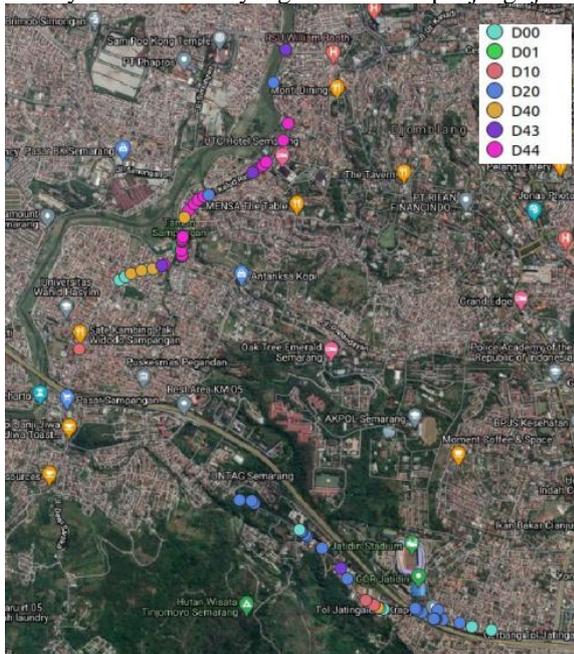
**IV.1 Hasil dan Analisis Model Identifikasi Kerusakan Jalan**

Model CNN yang digunakan menggunakan YOLOv4 Tiny untuk mengidentifikasi kerusakan jalan. Model yang dihasilkan menggunakan dataset yang bersumber dari IEEE Road Damage Dataset. Proses training dilakukan dengan 16000 iterasi dan didapatkan hasil dengan grafik seperti pada **Gambar 7**. Ketelitian model hasil dari proses *training* pada sebuah model DL dapat dinilai dari hasil mAP (*mean Average Precision*). Secara umum nilai *Average Precision* merupakan area di bawah kurva *precision-recall*. Nilai mAP merupakan standar presisi dalam kompetisi Pascal VOC yang sering digunakan sebagai pembandingan kualitas antar model DL yang dibuat. Nilai *mean Average Precision* (mAP) yang didapatkan yaitu 41% dengan *average loss* sebesar 0,6428. Nilai minimal model YOLOv4 Tiny sesuai standar kompetisi Pascal VOC yaitu mAP sebesar 40,2% (Bochkovsky, 2020) sehingga model yang didapat layak untuk digunakan.



**Gambar 7** Grafik Hasil Training Model YOLO

Hasil dari identifikasi melalui video tersebut kemudian digabungkan dengan data spasial dari receiver GNSS dan didapatkan persebaran titik kerusakan jalan seperti pada **Gambar 8** dan **Gambar 9**. Jumlah titik kerusakan jalan yang teridentifikasi yaitu sebanyak 205 titik yang tersebar sepanjang jalan..

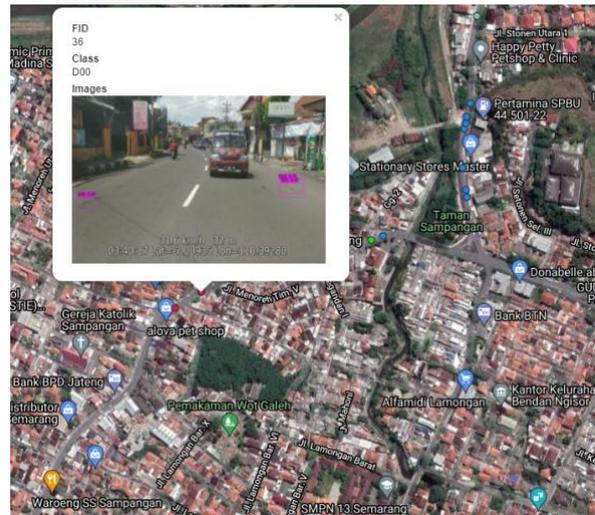


**Gambar 8** Persebaran Hasil Identifikasi Kerusakan Jalan di Jalan Karangreja sampai Jalan Lamongan Raya



**Gambar 9** Persebaran Hasil Identifikasi Kerusakan Jalan di Jalan Setia Budi sampai Jalan Perintis Kemerdekaan

Hasil persebaran titik kerusakan jalan juga dapat diakses secara *online* seperti pada **Gambar 10** dengan mengakses halaman berikut: <https://git.io/JOZAI>. Pada halaman tersebut terdapat titik-titik hasil identifikasi kerusakan jalan yang dapat dipilih untuk melihat kelas kerusakan jalan beserta gambar kerusakan jalan yang teridentifikasi.



**Gambar 10** Persebaran Hasil Identifikasi Kerusakan Jalan Secara Online

**IV.2 Hasil Uji Akurasi**

**IV.2.1 Uji Akurasi Spasial**

Analisis akurasi model yang dihasilkan menggunakan *confusion matrix* dengan sampel berupa titik pada jalan yang diamati. Jumlah sampel yang digunakan sesuai dengan rumus Slovin dengan derajat kepercayaan 90% menghasilkan sampel berjumlah 116 titik. Analisis akurasi spasial dilakukan dengan membandingkan lokasi spasial hasil dari model CNN dengan data validasi. Data validasi didapatkan dengan menggunakan smartphone baik untuk mendapatkan data video maupun data lokasi. Kerusakan jalan yang didapatkan menggunakan visual secara manual oleh penulis. Data perbandingan koordinat hasil model dengan data validasi dapat dilihat pada **Tabel 2**.

**Tabel 2 Nilai RMSE Koordinat**

RMSE X (m)	6,86
RMSE Y (m)	4,81
RMSE X, Y (m)	8,38

Berdasarkan nilai di atas maka perbedaan titik hasil model DL dengan data validasi sebesar 8,38 meter sehingga nilai ini memenuhi terhadap nilai akurasi GPS *smartphone* yaitu 10 meter.

**IV.2.2 Confusion Matrix**

Validasi dilakukan dengan mengambil data kerusakan jalan secara manual lalu membandingkan dengan hasil model. Hasil kelas identifikasi kerusakan jalan terbagi menjadi delapan kelas seperti pada *dataset* kerusakan jalan yang digunakan. Kelas tambahan berupa tidak terdapat kerusakan jalan diberi kode D45. Hasil perhitungan *confusion matrix* dapat dilihat pada **Tabel 3**.

**Tabel 3 Confusion Matrix**

Kelas	Komisi	Omisi	User Accuracy (%)	Producer Accuracy (%)
D00	0.26	0,08	73,33	91,67
D01	0	0.44	100	55.56
D10	0.7	0	30	100
D11	.	1	.	0
D20	0	0,06	100	93,75
D40	0,12	0	87,5	100
D43	0	0,17	100	83,33
D44	0	0,04	100	95,83
D45	0,17	0,04	83,33	96,15
Overall Accuracy (%)	85,34			
Kappa (%)	82,36			

Hasil validasi tersebut telah memenuhi standar akurasi dari syarat klasifikasi dimana nilai *Overall Accuracy* lebih besar dari 85% dan nilai Kappa lebih besar dari 80% (Congalton dan Green, 2008).

**V. Kesimpulan dan Saran**

**V.1 Kesimpulan**

Kesimpulan dari penelitian ini adalah:

1. Model CNN yang dihasilkan bermanfaat untuk identifikasi kerusakan jalan dari video maupun gambar. Hasil identifikasi dari model tersebut setelah digabungkan dengan data spasial dari *receiver* GNSS mampu menghasilkan titik persebaran kerusakan jalan beserta kelas kerusakannya yang kemudian dapat dilakukan analisis untuk penanganannya. Kelas kerusakan jalan yang mampu diidentifikasi oleh model yaitu D00 (retak memanjang). D01 (sambungan konstruksi memanjang). D10 (retak melintang). D11 (sambungan konstruksi melintang). D20 (retak tidak beraturan). D40 (lubang dan benjolan). D43 (*zebra cross* pudar). dan D44 (marka jalan pudar). Hasil kerusakan jalan yang didapatkan sejumlah 205 titik sepanjang Jalan Setia Budi sampai Jalan Perintis Kemerdekaan dan Jalan Karangrejo sampai Jalan Lamongan Raya yang dapat diakses secara *online* melalui halaman <https://git.io/JOZAI>.
2. Hasil titik persebaran kerusakan jalan jika dibandingkan dengan validasi manual menggunakan GPS *smartphone* memiliki nilai RMSE sebesar 7,82 meter. Nilai akurasi model yang didapat dengan membandingkan hasil dari model dan dari data hasil validasi dengan menggunakan *confusion matrix* pada setiap kelas kerusakan jalan memiliki nilai *overall accuracy* sebesar 85,34% dan nilai *kappa accuracy* sebesar 82,36%. Nilai akurasi tersebut menunjukkan bahwa metode ini memiliki akurasi yang baik dan layak digunakan untuk digunakan dalam pengamatan kerusakan jalan.

**V.2 Saran**

Hasil penelitian ini ditemukan beberapa saran yang dapat dijadikan masukan untuk penelitian selanjutnya. Berikut adalah beberapa saran yang dapat disampaikan.

1. Penggunaan metode dalam penelitian ini direkomendasikan untuk inovasi dalam pengamatan kerusakan jalan karena mampu dilakukan secara otomatis tanpa bantuan manusia. cepat dalam pengolahannya serta memiliki akurasi yang baik.
2. Pengolahan DL menggunakan kekuatan GPU komputer yang besar dan sebaiknya menggunakan GPU keluaran terbaru dengan *cuda core* yang besar.
3. Penelitian selanjutnya bisa menggunakan metode CNN lainnya untuk identifikasi obyek.

4. Penggunaan dataset yang lebih baru dan sesuai dengan kondisi jalan di Indonesia sangat direkomendasikan.
5. Penggunaan cloud computing mampu dijadikan pilihan jika perangkat keras komputer kurang mencukupi.
6. Pengambilan sampel validasi dapat menggunakan standar peraturan yang lebih akurat.
7. Perhitungan presisi dari hasil deteksi perlu dilakukan untuk mengetahui presisi dari lokasi terdeteksinya kerusakan jalan.
8. Penggunaan offset atau jarak antara kamera dan receiver GNSS perlu digunakan sehingga hasil posisi yang dihasilkan lebih akurat.

#### DAFTAR PUSTAKA

- Arya, D., Maeda, H., Ghosh, S., dkk. (2020). Transfer Learning-based Road Damage Detection for Multiple Countries. arXiv.
- Bernad. R., dan Syafaruddin. A. S. (2016). Analisis Kondisi Kerusakan Jalan Raya Pada Lapis Permukaan (Studi Kasus : Jalan Raya Desa Kapur. Desa Kapur. Kecamatan Sungai Raya. Kabupaten Kubu Raya. Provinsi Kalimantan Barat). *Analisis Kondisi Kerusakan Jalan Raya Pada Lapisan Permukaan*. 1–10.
- Bochkovskiy, A., Wang, C. dan Liao, H. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. arXiv.
- Bochkovskiy, A., Wang, C. dan Liao, H. (2020). Scaled-YOLOv4: Scaling Cross Stage Partial Network. arXiv
- Chollet. Francois. (2017). *Deep Learning With Python*. Manning
- Congalton. Russel G. dan Green. K. (2008). *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices* (2nd Editio). CRC Press. Taylor and Francis Group.
- Coulibaly. I. Lepage. R., dan Saint-Jacques. M. (2015). Road Damage Detection From High Resolution Satellite Images Based on *Machine Learning. MultiTemp 2015. July*. 1–5.
- Developers. Google. (2019). *Machine Learning Glossary*. <https://developers.google.com>. Diakses pada tanggal 12 April 2020
- Departemen Pekerjaan Umum. (2005). *Teknik Pengelolaan Jalan*.
- Hajian, M., Lu, N., Ge, L., dkk (2013). Automatic Road Damage Detection Using High-Resolution Satellite Images And Road Maps. 1 National Earthquake Infrastructure Service . Beijing . 10036 . China 2 Institute of Remote Sensing and GIS . Peking University . Beijing . 100871 . China 3 School of Ci. (2013). 3718–3721.
- Irawan. A., Pratomo. A., Risa, M., dan Negeri Banjarmasin, P. (2016). Perancangan Sistem Identifikasi Kerusakan Aspal Jalan Melalui Video Menggunakan Fast Fourier Transform. *Prosiding SNRT (Seminar Nasional Riset Terapan)*. 5662. 111–119.
- Ivanov, Slav. (2020). Reasons Why Your Neural Networks Not Working. <https://www.kdnuggets.com/2017/08/37-reasons-neural-network-not-working.html>. Diakses pada 1 Juni 2021.
- Maeda, H., Sekimoto, Y., Seto. T., Kashiyama. T., dan Omata, H. (2018). Road Damage Detection and Classification Using Deep Neural Networks with Smartphone Images. *Computer-Aided Civil and Infrastructure Engineering*. 33(12). 1127–1141. <https://doi.org/10.1111/mice.12387>
- Missing Link Team. (2020). Python Convolutional Neural Networks. <https://missinglink.ai/guides/convolutional-neural-networks/python-convolutional-neural-network-creating-cnn-keras-tensorflow-plain-python>. Diakses pada 14 April 2020.
- Nayazr, Ghulam Muhammad. (2016). Kenali Faktor Utama Penyebab Kecelakaan di Jalan Raya. <https://sains.kompas.com/read/2016/02/22/084500830/Kenali.Faktor.Utama.Penyebab.Kecelakaan.di.Jalan.Raya.Diakses.pada.7.Mei.2020>
- Pan. Y., Zhang. X., Cervone. G., dan Yang, L. (2018). Detection of Asphalt Pavement Potholes and Cracks Based on the Unmanned Aerial Vehicle Multispectral Imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 11(10). 3701–3712. <https://doi.org/10.1109/JSTARS.2018.2865528>
- Pemerintah Indonesia. (2004). Undang-Undang Nomor 38 Tahun 2004 tentang Jalan. Sekretariat Negara. Jakarta.
- Pemerintah Indonesia. (2009). Undang-Undang Nomor 22 Tahun 2009 tentang Lalu Lintas dan Angkutan Jalan. Sekretariat Negara. Jakarta
- Pemerintah Kota Semarang. (2019). Website Kota Semarang. <https://www.semarangkota.go.id>. Diakses pada tanggal 14 April 2020
- Redmon, Joseph dan Farhadi, Ali. (2018). YOLOv3: an Incremental Improvement. arXiv.
- Sharma, Abhisek. (2020). *Confusion Matrix in Machine Learning*. <https://www.geeksforgeeks.org/confusion-matrix-machine-learning/>. Diakses pada 1 Juli 2020.
- Xu. J. Z., Lu, W., Li, Z., Khaitan, P., dan Zaytseva. V. (2019). *Building Damage Detection in Satellite Imagery Using Convolutional Neural Networks. NeurIPS*. <http://arxiv.org/abs/1910.06444>
- Zhao, X., dan Li, S. (2018). *Convolutional neural networks-based crack detection for real concrete surface*. 143. <https://doi.org/10.1117/12.2296536>