



DETEKSI KERETAKAN JALAN ASPAL MENGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK

Yusup Yulianto¹ Ari Wibowo²

¹Teknik Sipil Universitas Subang, ²Teknik Arsitektur Universitas Subang
¹yusupyulianto@unsub.ac.id, ²ariwibowo@unsub.ac.id

ABSTRACT

Road conditions determine the comfort of road users, the comfort of these road users is the responsibility of the Public Works and Spatial Planning Office in each region. Roads are of course an important aspect because roads are the main supporting factor in the social, cultural, environmental fields which are developed in order to achieve an equitable distribution of development between regions and sustainability with regional and economic development approaches. The first step that must be taken by policy makers in seeking comfort for users is to evaluate the quality of roads, including in Indonesia. The evaluation in question includes estimating repairs, required construction, estimating quality. These aspects can be calculated based on compliance, micro-texture, macro-texture and surface degradation if there are defects on the road. The strategic step in making road quality evaluation steps is to detect road cracks on the surface. One of them is by implementing an intelligent system method in detecting road damage using the Convolutional Neural Network (CNN) algorithm. The input is an image of the road surface in RGB format. The image is obtained from kaggle as many as 2074 images. Then, image preprocessing is performed which includes converting RGB images to grayscale, image resizing, and edge detection. After preprocessing the image, the next step is to reconfigure and train the dataset. In the training process there are test parameters including Optimizer, validation split epoch, and batch size. Based on the results of the tests and evaluations that have been carried out, it can be concluded that the system built has succeeded in producing very good data as evidenced by an accuracy rate of 92.9%.

Keywords: Asphalt Road Conditions; Road Crack Detection; CNN.

ABSTRAK

Kondisi jalan menentukan kenyamanan dari pengguna jalan, kenyamanan pengguna jalan tersebut menjadi tanggung jawab dari Dinas Pekerjaan Umum dan Penataan Ruang di setiap daerah. Jalan tentunya sebagai aspek penting karena jalan adalah factor pendukung utama dalam bidang social, budaya, lingkungan yang dikembangkan agar tercapai suatu pemerataan pembangunan antara daerah dan kesinambungan dengan pendekatan pengembangan daerah dan ekonomi. Langkah pertama yang harus dilakukan oleh pemangku kebijakan dalam mengupayakan kenyamanan oleh pengguna adalah evaluasi kualitas jalan termasuk di Indonesia. Evaluasi yang dimaksud antara lain memperkirakan reparasi, konstruksi yang diperlukan, memperkirakan kualitas. Aspek-aspek tersebut dapat diperhitungkan berdasarkan kepatuhan, tekstur mikro, tekstur makro dan degradasi permukaan jika terdapat kecacatan pada jalan. Adapun langkah strategis dalam membuat langkah evaluasi kualitas jalan yaitu dengan mendeteksi keretakan jalan yang ada pada permukaan. Salah satunya dengan penerapan metode system cerdas dalam mendeteksi kerusakan jalan menggunakan algoritma Convolutional Neural Network (CNN). Input berupa gambar permukaan jalan dengan format RGB. Citra tersebut diperoleh dari kaggle sebanyak 2074 citra. Kemudian dilakukan Preprocessing image yang meliputi konversi citra RGB ke grayscale, resize image, dan edge detection. Setelah dilakukan preprocessing image langkah berikutnya adalah melakukan konfigurasi ulang dan training dataset. Pada proses training terdapat parameter pengujian meliputi Optimizer, validation split epoch, dan batch size. Berdasarkan hasil pengujian dan evaluasi yang telah dilakukan, dapat disimpulkan bahwa sistem yang dibangun berhasil menghasilkan suatu data yang sangat baik dengan dibuktikan dari tingkat akurasi sebesar 92,9%.

Kata Kunci: Kondisi jalan aspal; Deteksi Keretakan Jalan; CNN.

1. PENDAHULUAN

Jalan merupakan prasarana transportasi darat yang meliputi segala bagian jalan dari badan jalan, termasuk bangunan pelengkap dan perlengkapannya yang tentu prasarana ini diperuntukkan bagi pengguna lalu lintas (Setiadi, E., Wibowo, A., 2023). Apabila melihat dari undang-undang mengenai jalan yang berlaku, hingga saat ini menyatakan bahwa jalan merupakan suatu prasarana yang berada pada permukaan tanah, di atas permukaan tanah, di bawah permukaan tanah dan/atau air, serta di atas permukaan air, kecuali kereta api, jalan lori, dan jalan kabel.

Selain itu, jalan merupakan media transportasi darat dan menjadi penghubung antara satu daerah dengan daerah yang lain (Regitha, A.,P., et al., 2019). Pengertian jalan menurut peraturan pemerintah Republik Indonesia nomor 34 tahun 2010 bab 1 pasal 1 ayat 1 merupakan suatu transportasi darat yang meliputi segala bagian jalan serta bangunan pelengkap, dan perlengkapannya yang digunakan untuk lalu lintas, yang terletak pada permukaan tanah, berada di atas permukaan tanah, berada di bawah permukaan tanah atau air, serta berada di atas permukaan air, terkecuali jalan lori, jalan kabel, dan jalan kereta api. Jalan sebagai transportasi nasional dibangun karena merupakan factor pendukung utama dalam bidang social, budaya, lingkungan yang dikembangkan agar tercapai suatu pemerataan pembangunan antar daerah dan kesinambungan dengan pendekatan pengembangan daerah dan ekonomi.

Melihat pentingnya kondisi jalan, maka sudah selayaknya pemerintah untuk melakukan tindak lanjut dalam mengusahakan agar jalan dapat digunakan sebagaimana mestinya. Baik dalam membuat jalan di beberapa akses antar daerah yang belum mendapatkan fasilitas jalan yang baik, memperbaiki kerusakan jalan yang sudah dibuatkan sebelumnya. Karena selain kebermanfaatan jalan yang sudah dikemukakan pada pernyataan di atas. Apabila kondisi jalan mengalami kerusakan tidak hanya menghambat laju perekonomian, dan segala bidang yang memungkinkan, tapi juga akan berpengaruh pada keamanan dan kenyamanan dari penggunaannya. Mahardika menyebutkan seperti yang ada pada pernyataan dari Dinas Pekerjaan Umum (DPU) salah satu factor lamanya proses perbaikan jalan yaitu disebabkan oleh proses pencatatan kondisi kerusakan jalan yang masih dilakukan secara manual (Mahardika, A, et al, 2018). Proses pendeteksian dan pencatatan secara manual oleh tenaga kerja manusia sepenuhnya bisa memakan waktu dua minggu untuk jalan sepanjang 1 km, belum lagi tingkat keakuratan yang rendah (Idestio et al., 2013).

Perhatian, pemeliharaan dari pemerintah dalam mengelola dan memperbaiki kondisi jalan yang rusak wajib dilakukan. Sehingga fungsi dari keberadaan jalan dapat dimanfaatkan dengan baik. Adapun tahapan yang bisa dilakukan dalam pemeliharaan seperti yang dimaksud, tahapan awal adalah dengan mengidentifikasi kerusakan pada suatu jalan, sehingga dari tahapan ini dapat menentukan tindakan apa yang perlu dilakukan. Metode yang digunakan

untuk mengidentifikasi kondisi kerusakan jalan dapat dilakukan secara manual dan otomatis. Metode manual dilakukan dengan menyusuri jalan, mengambil gambar kerusakan jalan dengan kamera, mengukur area kerusakan, menentukan tingkat kerusakan sesuai dengan jenis kerusakan jalan, lalu menghitung dan menuliskannya dalam bentuk laporan. Metode ini sangatlah menyita waktu, tenaga dan biaya. Terlebih petugas harus menyusuri lalu lintas, hal tersebut tentunya dapat membahayakan petugas. Metode ini juga rawan subjektivitas, sehingga dapat memberikan akurasi yang rendah tentang kerusakan jalan (Departemen Pekerjaan Umum, 1995). Sedangkan metode secara otomatis adalah seperti penelitian yang dilakukan yaitu dengan menggunakan website sebagai pengumpul data untuk di ujikan, dan dari website ini tertera informasi yang dibutuhkan seperti lokasi kerusakan jalan, maupun hasil klasifikasi dari gambar yang diunggah oleh masyarakat setempat. Selain itu, website ini juga dapat dioptimalkan untuk meneruskan data ke dalam database. Agar data yang tersimpan ini dapat digunakan untuk dikembangkan atau untuk keperluan lainnya.

Berdasarkan latar belakang di atas, maka tujuan penelitian ini adalah untuk mendapatkan informasi dari kondisi suatu jalan melalui klasifikasi dan deteksi kerusakan jalan berupa keretakan yang ada pada permukaan jalan. Diharapkan dari penelitian ini mampu membuat suatu sistem yang digunakan untuk mendeteksi kerusakan jalan yang disertai nilai akurasi berdasarkan hasil pelatihan uji data test maupun uji validasi menggunakan metode Convolutional Neural Network (CNN) dan disertai program website yang digunakan untuk mengunggah foto, mengetahui hasil klasifikasi kondisi jalan, mengetahui informasi letak kerusakan jalan yang dikirimkan, dan untuk keperluan penyimpanan data.

2. TINJAUAN PUSTAKA

Pada bab ini akan dijelaskan pengantar teori sebagai landasan untuk penelitian. Seperti pengertian dan jenis kerusakan jalan, metode *Convolutional Neural Network* (CNN). Yang masing-masing diantaranya adalah:

2.1 Jalan

Menurut peraturan pemerintah nomor 34 tahun 2006, jalan adalah prasaranan transportasi darat yang meliputi segala bagian jalan, termasuk bangunan pelengkap dan perlengkapannya yang diperuntukkan bagi lalu lintas, yang berada pada permukaan tanah, di atas permukaan tanah, di bawah permukaan tanah dan/atau air, serta di atas permukaan air, kecuali jalan kereta api, jalan lori, dan jalan kabel.

2.2 Survei kondisi jalan

Menurut Yudaningrum, Ikhwanudin (2017) dalam Rahmawati, Pangesti (2021), menyatakan bahwa survei kondisi adalah survei yang dimaksudkan untuk menentukan kondisi perkerasan pada waktu tertentu. Tipe survei

semacam ini tidak mengevaluasi kekuatan perkerasan. Survei kondisi bertujuan untuk menunjukkan kondisi perkerasan pada saat waktu dilakukan survei. Jadi, survei ini sifatnya kualitatif. Informasi yang diperoleh akan digunakan untuk menetapkan: macam studi, penilaian prioritas dan program pemeliharaan. Survei kondisi juga berguna untuk persiapan analisis structural secara detail, dan untuk rahabilitas. Jika area-area secara baik direferensikan dalam stasiun-stasiun, maka area yang membutuhkan pengumpulan data yang lebih intensif dapat didefinisikan.

2.3 Survei kerusakan perkerasan

Survei kerusakan secara detail dibutuhkan sebagai bagian dari perencanaan dan perancang suatu proyek rahabilitas. Survei kerusakan perkerasan adalah kompilasi dari berbagai tiper kerusakan, tingkat keparahan kerusakan, lokasi, dan luas penyebarannya. Perhatian harus diberikan terhadap konsistensi dari personil penilai kerusakan baik secara individual maupun kelompok-kelompok yang melakukan survei. Tujuan dilakukannya survei kinerja perkerasan. Adalah untuk menentukan perkembangan dari kerusakan perkerasan, sehingga dapat dilakukan estimasi biaya dari pemeliharaan. Informasi ini sangat berguna untuk instansi yang terkait dalam pengalokasian dana untuk pemeliharaan. Pekerjaan ini sangat penting dan umumnya diprioritaskan sehingga banyaknya biaya yang dibutuhkan untuk pemeliharaan dapat diestimasi dari tahun ke tahun. Selain itu, survei kinerja perkerasan juga berguna untuk menentukan sebab-sebab dan pengaruh dari kerusakan perkerasan. Penentuan sebab-sebab kerusakan harus diketahui sebelum penanganan pemeliharaan yang memadai dapat dilakukan. Demikian pula penyebab kegagalan perkerasan harus juga diketahui, sehingga hal ini dapat diperhitungkan dalam perancangan di kemudian hari.

Secara garis besar kerusakan dapat dibedakan menjadi dua bagian, yaitu kerusakan structural, mencakup kegagalan perkerasan atau kerusakan dari satu atau lebih komponen perkerasan yang mengakibatkan perkerasan tidak dapat lagi mengganggu beban lalu lintas, dan kerusakan fungsional yang mengakibatkan keamanan dan kenyamanan pengguna jalan menjadi terganggu. Sehingga biaya operasi kendaraan semakin meningkat (Putra, W. K. et al. 2022).

Menurut manual pemeliharaan jalan No: 03/MN/B/1983 yang dikeluarkan oleh direktorat jenderal bina marga, kerusakan jalan dapat dibedakan menjadi (Yudaningrum, 2017):

2.3.1 Retak (*cracking*)

Retak yang terjadi pada lapisan permukaan jalan dapat dibedakan atas: 1) retak halus, 2) retak kulit buaya, 3) retak pinggir, 4) retak sambungan bahu, 5) retak sambungan jalan, 6) retak sambungan pelebaran jalan, 7) retak refleksi (*reflection cracks*), 8) retak susut (*shrinkage cracks*), 9) retak slip (*slippage cracks*).

2.3.2 Distorsi (*distortion*)

Distorsi/perubahan bentuk dapat terjadi akibat lemahnya tanah dasar, pemadatan yang kurang pada lapis pondasi, sehingga terjadi tambahan pemadatan akibat beban lalu lintas. Distorsi (*Distortion*) dapat dibedakan atas; 1) Alur (*ruts*), 2) Keriting (*corrugation*), 3) Sungkur (*shoving*), 4) Amblas (*grade depressions*), 5) Jembul (*upheaval*).

2.3.3 Cacat permukaan (*disintegration*)

Cacat permukaan yang mengarah kepada kerusakan secara kimiawi dan mekanis dari lapisan perkerasan. Adapun cacat permukaan ini dapat dibedakan menjadi: 1) Lubang (*potholes*), 2) Pelepasan butir (*raveling*), 3) Pengelupasan lapisan permukaan (*stipping*).

2.3.4 Pengausan (*polished aggregate*)

Permukaan jalan menjadi licin, sehingga membahayakan kendaraan. Pengausan terjadi karena agregat berasal dari material yang tidak tahan aus terhadap roda kendaraan, atau agregat yang dipergunakan berbentuk bulat dan licin, tidak berbentuk cubical. Dan kerusakan pada jenis ini dapat diatasi dengan menutup lapisan dengan latasir, buras atau latasbun.

2.3.5 Kegemukan (*bleeding of flushing*)

Kerusakan jenis kegemukan diakibatkan karena permukaan jalan yang licin, pada permukaan tertentu. Jika temperaturnya tinggi, aspal menjadi lunak dan akan terjadi jejak roda. Kegemukan (*bleeding*) dapat disebabkan pemakaian kadar aspal yang tinggi pada campuran aspal, pemakaian terlalu banyak aspal pada pekerjaan *prime coat* atau *tack coat*. Dapat diatasi dengan menaburkan agregat panas dan kemudian dipadatkan atau lapis aspal diangkat dan kemudian diberi lapisan penutup.

2.3.6 Penurunan pada bekas penanaman utilitas

Kerusakan pada tipe ini terjadi di sepanjang bekas penanaman utilitas. Hal ini bisa terjadi karena pemadatan yang tidak memenuhi syarat. Dapat diperbaiki dengan dibongkar kembali dan diganti dengan lapis yang sesuai.

2.4 *Convolutional Neural Network* (CNN)

Convolutional Neural Network atau yang disingkat sebagai CNN merupakan salah satu algoritma yang ada pada *deep learning* (Qotrunnada, F.N., 2022). CNN digunakan untuk mengklasifikasi gambar ataupun video juga digunakan untuk mendeteksi objek yang ada pada gambar atau bahkan wilayah yang ada di dalam gambar (Moolayil, 2019). CNN tersusun dari layer yang memiliki susunan neuron 3D yaitu ; lebar, tinggi, dan kedalaman yang mana susunan lebar dan tinggi merupakan ukuran layer, dan kedalaman merupakan jumlah layer (Zufar et al., 2016).

2.5 Tensorflow

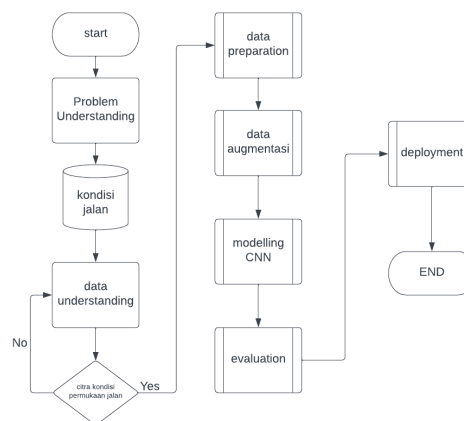
Tensorflow merupakan salah satu *library open source* yang dikembangkan oleh tim google brain. Dalam deep learning, tensorflow digunakan untuk menjalankan secara otomatis manajemen memori yang sama pada data yang digunakan. Tensorflow dapat menjalankan serta melatih jaringan untuk klasifikasi.

2.6 Klasifikasi

Klasifikasi merupakan suatu proses untuk menemukan fitur yang dapat membedakan atau mendeskripsikan ke dalam kategori kelas data. Klasifikasi bertujuan untuk memberikan perkiraan suatu objek yang belum diketahui labelnya ke dalam suatu kelas.

3. METODOLOGI PENELITIAN

Pada penelitian ini metode yang digunakan adalah dengan menggunakan metode *Convolutional Neural Network*. Proses perancangan dan implementasi terdiri atas beberapa tahap. Adapun tahapan penelitian disajikan pada gambar 1 di bawah ini.



Gambar 1 : Tahapan Penelitian

Alur pengerjaan penelitian ini dimulai dari pemilihan data sampel yang *digunakan* sebagai input untuk data training, validasi dan pengujian/tes. Kemudian merancang jaringan dengan metode CNN untuk melakukan klasifikasi dan deteksi pada citra kondisi permukaan jalan. Rancangan jaringan CNN diaplikasikan dengan data training, agar computer dapat belajar mengenali objek. Apabila pembelajaran jaringan diperoleh hasil yang baik dalam membedakan jenis kondisi permukaan jalan, maka jaringan tersebut kemudian dilakukan uji coba terhadap data validasi. Apabila data validasi juga menunjukkan hasil yang baik maka jaringan dapat digunakan untuk klasifikasi dan deteksi pada data tes.

3.1 Pengumpulan data

Pengumpulan data berupa gambar kondisi jalan dengan tipe dan kelas yang diantaranya terdiri atas data gambar *good*, *poor*, *satisfactory*, dan *very poor*. Adapun data tersebut kami ambil dari katalog kaggle untuk masing-masing jumlah data yang kami gunakan dalam membuat sistem sebanyak 2074 citra. Dimana citra tersebut terdiri atas data gambar kondisi *good* sebanyak 845 gambar, *poor* sebanyak 396 gambar, *satisfactory* sebanyak 515 gambar, dan *very_poor* sebanyak 318 gambar. Adapun contoh gambar di masing-masing citra dapat dilihat pada gambar 2 di bawah ini.



Gambar 2

Input data yang digunakan dalam jaringan ini berupa sampel gambar dari empat jenis gambar kondisi permukaan jalan yaitu berupa kondisi sangat bagus (*good*), baik (*satisfactory*), jelek (*poor*), dan parah (*very poor*) sedangkan data yang digunakan dalam penelitian ini, diambil dari katalog kaggle. Secara keseluruhan citra yang diambil dari katalog kaggle sebanyak 2074 gambar. Dengan rincian 70% untuk data latih, dan 20% untuk data tes sedangkan untuk data validasi sebesar 10% dari total keseluruhan data. Adapun selengkapnya dapat di lihat pada tabel 1 di bawah ini.

Tabel 1 Pembagian Data Penelitian

Jenis permukaan jalan	Jumlah data latih	Jumlah data uji	Data prediksi
Good	845	150	40
Satisfactory	515	100	
Poor	396	70	
Very poor	318	60	

Data training digunakan untuk melakukan proses pembelajaran jaringan, kemudian dievaluasi. Apabila akurasi pada proses training model jaringan belum naik maka perlu dilakukan modifikasi pada lapisan CNN, parameter jaringan dan pada sampel datanya. Apabila hasil akurasi sudah baik maka dilakukan proses selanjutnya yaitu pengujian dengan data validasi. Data validasi adalah data yang tidak digunakan pada proses training. Apabila akurasi dari data validasi ini kurang baik, ada kemungkinan terjadi overfitting, oleh karena itu jaringan perlu dimodifikasi kembali. Sehingga hasilnya sudah baik atau ada peningkatan maka jaringan ini dapat digunakan untuk memproses data tes. Data tes berisi sekumpulan sampel data yang ingin diketahui jenis klasifikasinya.

3.2 Preprocessing data

Preprocessing citra dengan mengubah ukuran citra jalan retak dan non-retak menjadi ukuran yang sama dan merubah citra dari gambar RGB menjadi citra *Canny Edge Image*. Langkah selanjutnya dilakukan pembagian data yang telah dikumpulkan menjadi dua, yaitu data latih (*training*) dan data uji (*testing*). Dilanjutkan proses pelabelan pada masing-masing data citra gambar permukaan retak maupun non-retak. Dimana hasil pelabelan ini dilakukan dengan menggunakan angka 0 hingga 3. Angka 0 untuk label citra good, angka 1 untuk label citra poor, angka 2 untuk label citra satisfactory, dan angka 3 untuk label citra very poor.

3.3 Perancangan CNN

Penelitian ini mengusulkan metode untuk deteksi kondisi jalan berdasarkan jenis kondisi dari jalan yang terdiri dari 4 kelas seperti yang sudah dijelaskan pada bab sebelumnya. Dalam proses deteksi layer convolution dilakukan di dalam server hingga selesai (*finish*). Gambar atau dataset akan ditraining ulang untuk mendapatkan model CNN yang akan digunakan seperti ukuran kernel, filter dan layer. Layer yang digunakan sejumlah 2 layer konvolusi beserta filter maxpooling, dan ekstraksi fitur. Layer pertama memiliki ukuran 128 x 128 piksel dan tiga dimensi warna. Hasil konvolusi pertama menciptakan 127 x 127 piksel dengan jumlah filter 64. Selain itu, piksel bergeser (*stride*) sejauh satu kolom menggunakan aktivasi ReLU. Selanjutnya, konvolusi dilakukan pada layer kedua dengan lebar dan tinggi kernel 3 x 3. Selain itu, piksel bergeser (*stride*) sejauh satu kolom dan menghasilkan 126 x 126 dan jumlah filter sebanyak 92. Maxpooling dan dropout ditambahkan untuk menghilangkan fitur informasi yang tidak dibutuhkan seperti pada tabel 2.

Tabel 2 Struktur Model CNN

Lapisan	Ukuran Piksel	Node
rescaling_1 (Rescaling)	(None, 200, 200, 3)	0
conv2d_16 (Conv2D)	(None, 200, 200, 16)	448
max_pooling2d_5 (Max Pooling 2D)	(None, 100, 100, 16)	0
conv2d_17 (Conv2D)	(None, 100, 100, 32)	4640
max_pooling2d_6 (Max Pooling 2D)	(None, 50, 50, 32)	0
conv2d_18 (Conv2D)	(None, 50, 50, 64)	18496
max_pooling2d_7 (Max Pooling 2D)	(None, 25, 25, 64)	0
flatten_1 (Flatten)	(None, 40000)	0
dense_4 (Dense)	(None, 128)	5120128
dense_5 (Dense)	(None, 4)	516
Total params: 5,144,228		
Trainable params: 5,144,228		
Non-trainable params: 0		

Pada lapisan input, data yang digunakan adalah data training. Kemudian data input diproses pada lapisan konvolusi pertama dengan menggunakan maxpooling dan fungsi aktivasi ReLU. Output pada lapisan konvolusi pertama dijadikan sebagai input pada proses konvolusi kedua. Kemudian hasil dari proses konvolusi dikumpulkan pada lapisan fully connected. Pada lapisan ini ditentukan fitur yang memiliki korelasi dengan kelas tertentu sehingga hasil akhir dari proses ini adalah fitur yang terklasifikasi dalam empat kelas.

4. ANALISIS DAN PEMBAHASAN

4.1 Implementasi CNN

Terdapat tiga tahap dalam mengimplementasikan CNN, yaitu training, validasi dan tes. Tahap training adalah tahap utama untuk melatih jaringan mempelajari data input. Kemudian jaringan tersebut diuji pada data validasi. Apabila memberikan hasil yang baik, maka jaringan tersebut dapat digunakan untuk melakukan klasifikasi data dengan data tes.

4.2 Data latih (Data Training)


Data latih yang digunakan adalah 70% dari total keseluruhan data sehingga didapat data latih sebanyak 1694 dengan masing-masing kelas beragam diantaranya kondisi sangat baik (*good*) 695, kondisi baik (*satisfactory*) 415, kondisi jelek (*poor*) 326 dan kondisi jelek (*very poor*) 258 sampel. Komputasi dilakukan menggunakan mode single GPU. Proses training menggunakan parameter sebagai berikut:

Learning rate : 0,0001
Mini-batch size : 16
Epoch : 10

Hasil training disajikan pada tabel 3. Training jaringan memberikan akurasi yang baik. Grafik dari akurasi dan kesalahan proses training disajikan pada gambar 3.

Tabel 3 Hasil Training jaringan CNN

```
accuracy
  training      (min: 0.700, max: 0.999, cur:
0.999)
  validation    (min: 0.876, max: 0.947, cur:
0.935)
Loss
  training      (min: 0.004, max: 0.825, cur:
0.004)
  validation    (min: 0.193, max: 0.369, cur:
0.330)
43/43 [=====] - 1s 33ms/step - loss:
0.0040 - accuracy: 0.9993 - val_loss: 0.3299 - val_accuracy:
0.9349
```



Gambar 3 Grafik Akurasi Dan Kesalahan Training


4.3 Data validasi

Proses validasi jaringan menggunakan 338 data untuk menguji jaringan dengan masing-masing kelas beserta jumlah di tiap kelas adalah ; kondisi sangat baik (*good*) 139, kondisi baik (*satisfactory*) 65, kondisi jelek (*poor*) 83 dan kondisi jelek jelek (*very poor*) 51 sampel. Dari proses ini didapatkan akurasi yang baik yaitu 94,67%.


4.4 Data tes

Interpreter dapat memasukkan sampel data yang ingin diketahui jenis klasifikasinya pada jaringan, kemudian jaringan akan mengeluarkan label jenis tanaman berdasarkan data yang dimasukkan. Hasil label klasifikasi yang keluar dari jaringan dapat untuk bahan pertimbangan interpreter dalam menentukan jenis objek tanaman yang sulit dibedakan secara visual. Pada penelitian ini scenario data tes menggunakan 380 data dengan masing-masing kelas berbeda-beda dengan rincian adalah ; kondisi sangat baik (*good*) 149, kondisi baik (*satisfactory*) 106, kondisi jelek (*poor*) 65 dan kondisi parah (*very poor*) 60 sampel. Pengujian ini menghasilkan akurasi yang baik yaitu 94,73% dengan jumlah benar sebanyak 360 data. Hasil akurasi klasifikasi pada data tes digambarkan pada confusion matrix di gambar 4 dan hasil klasifikasi semantic pada tes juga kami ujikan sebagai proses deteksi pada suatu gambar kondisi

retak, dan hasil deteksinya adalah sebagaimana terdapat pada gambar 5. Sedangkan untuk menguji ketepatan sistem jaringan yang dibuat, maka dipilih salah satu gambar untuk dideteksi, dan hasilnya data atau gambar tersebut termasuk ke dalam kelas very poor dengan *confidence* sebesar 99,93% dan kenyataannya memang betul sudah sesuai dengan yang seharusnya. Adapun contoh gambar yang dimaksud seperti terlihat pada gambar 4.



Gambar 4 Matriks Konfusi Dari Data Tes



(A)



(B)

Gambar 5 Hasil klasifikasi semantik pada data tes (A) dan sampel data tes pada salah satu data di data tes (B).

Pada hasil pengujian data tes, kesalahan terbanyak terdapat pada

pengklasifikasian satisfactory. Jaringan memprediksi objek satisfactory sebagai objek poor dan very poor. Dari 106 data sampel objek satisfactory, 10 diantaranya diprediksi sebagai objek poor dan 2 diantaranya diprediksi sebagai objek very poor. Jaringan sulit membedakan objek tersebut karena ketiga gambar objek memiliki karakter fisik khususnya warna yang hampir sama.

5. KESIMPULAN DAN SARAN

Hasil implementasi metode CNN untuk klasifikasi dan prediksi jenis kondisi permukaan pada jalan raya menunjukkan bahwa arsitektur CNN dapat mengklasifikasikan dan memprediksikan 4 jenis kondisi permukaan secara otomatis dengan memberikan label pada data. Evaluasi kerja terhadap arsitektur jaringan CNN pada data tes menghasilkan akurasi 95%. Untuk scenario data tes dengan jumlah masing-masing kelas sebanyak 380 sampel, metode CNN dapat memberikan hasil yang cukup baik dalam melakukan proses pengenalan objek dan klasifikasi jenis permukaan jalan raya. Namun masih terdapat kesalahan. Kesalahan prediksi paling banyak terdapat pada kelas satisfactory yang diprediksi sebagai kelas poor dan very poor. Dari tampilan citra pada kelas satisfactory ini memiliki karakteristik penampakan yang hampir mirip sehingga menyebabkan jaringan salah memprediksi. Hal ini diperkuat dengan melihat hasil prediksi pada kondisi poor yang memiliki kesalahan prediksi sebesar 6 data dan data tersebut masuk ke dalam kelas satisfactory.

Ketersediaan objek jenis permukaan jalan raya dalam jumlah banyak, yang dipakai untuk pemrosesan jaringan dan kondisi karakter fisik dari citra juga berpengaruh dalam ketepatan proses prediksi gambar. Sehingga apabila data yang disediakan lebih banyak, dapat dimungkinkan untuk mendapatkan nilai akurasi yang tinggi dan dapat digunakan untuk mengurangi kesalahan dalam memprediksi suatu data. Namun konsekuensinya diperlukan peralatan komputasi yang lebih besar untuk melakukan proses training jaringan pada data yang banyak.

Pada dasarnya penelitian ini hanya digunakan untuk menentukan klasifikasi semantic untuk membantu interpreter dalam menentukan jenis permukaan jalan raya. Interpreter memasukkan sampel data objek yang ingin diketahui klasifikasinya, kemudian jaringan memberikan jawaban nama objek tersebut. Sehingga dapat membantu interpreter yang tidak mengetahui kondisi jenis tanaman di lapangan sebagai bahan pertimbangan dalam melakukan digitasi objek jalan untuk kemajuan di bidang transportasi.

DAFTAR PUSTAKA

Departemen-pekerjaan-umum (1995), Manual Pemeliharaan Rutin untuk Jalan Nasional dan Jalan Provinsi, Jilid Ii: Metode Perbaikan Standar,

Departemen Pekerjaan Umum Direktorat Jendral Bina Marga Direktorat Bina Teknik.

Idestio, B.D., Agung, T., dan Wirayuda, B. (2013), 'Pengukuran Luas Lubang Jalan Berbasis Data Video Menerapkan Threshold-Based Marking dan GLCM', *INKOM*, Vol. 7, No. 2, p. 235, November 2013, DOI:<https://dx.doi.org/10.14203/j.inkom.235>.

Mahardika, A., Sari, Y. A., dan Dewi, C. (2018), 'Sistem Temu Kembali Citra Lubang Jalan Aspal Berdasarkan Tingkat Kerusakan Menggunakan Ekstraksi Fitur Gray Level Co-Occurrence Matrix', *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Computer*, Vol. 2, No. 10, p. 3811-3821, ISSN 2548-964X, Februari 2018.

Peraturan pemerintah nomor 34 tahun 2006 tentang jalan (lembaran negara republik indonesia tahun 2006 nomor 86, tambahan lembaran negara republik indonesia nomor 4655).

Regitha, F., et al. (2018), 'Rekomendasi Prioritas Perbaikan Jalan Dengan Metode AHP-SAW-TOPSIS (Studi kasus: Dinas Pekerjaan Umum Dan Penataan Ruang Kota Malang)', *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Computer*, Vol. 3, No. 3, p. 2960-2969, ISSN 2548-964X, Januari 2019.

Setiadi, E., dan Wibowo, A. (2023), 'Klasifikasi dan Deteksi Keretakan pada Trotoar Menggunakan Metode Convolutional Neural Network', *JTSC*, Vol. 4, No. 1, pp 412-427, Februari 2023, DOI:<https://doi.org/10.51988/jtsc.v4i1.116>.

Rahmawati, R., Pangesti, R. D., dan Abdillah, R. A. (2021), 'Pemetaan Kondisi Jalan Berdasarkan IRI Roadroid Di Kabupaten Gresik Wilayah Selatan', *Jurnal Riset Rekayasa Sipil*, Vol. 4, No. 2, Maret 2021, DOI : <https://doi.org/10.20961/jrrs.v4i2.44230>

Yudaningrum, F., dan Ikhwanudin (2017), 'Identifikasi jenis kerusakan jalan (studi kasus ruas jalan kedungmundu-meteseh)', *Teknika*, Vol. 12, No. 2, p 16-23 DOI: <https://doi.org/10.26623/teknika.v12i2>.

Putra, W.K., Nurdin, A., Bahar, F.F. (2022), 'analisis kerusakan jalan perkerasan lentur menggunakan metode pavement condition index (PCI)', *Jurnal Teknik*, Vol. 16, No. 1, pp. 41-50, April 2022.

Qotrunnada, F. M., dan Utomo, P. H. (2022), 'Metode Convolutional neural network untuk klasifikasi wajah bermasker', *PRISMA, Prosiding seminar nasional matematika*, Vol. 5, pp. 799-807, Retrieved from <https://journal.unnes.ac.id/sju/index.php/prisma/article/view/54602>.

- Moolayil, J.,J. (2019), Learn keras for deep neural networks: A fast-track approach to modern deep learning with python. British columbia: Apress.
- Zufar, M. Dan Setiyono, B. (2016), 'Convolutional neural network untuk pengenalan wajah secara real-time', Jurnal Sains dan Seni ITS, 2337-3520.
- Anisarida, A. A., Hafudiansyah, E., & Kurniawan, E. (2020). Perencanaan Tebal Perkerasan Ruas Jalan A Di Kabupaten Lebak. Jurnal Teknik Sipil Cendekia (JTSC), 1(1), 1-14.
- Hernawan, H., & Anisarida, A. A. (2022). ANALISIS FAKTOR PENYEBAB KECELAKAAN RUAS JALAN LIMBANGAN MALANGBONG KABUPATEN GARUT. JURNAL TEKNIK SIPIL CENDEKIA (JTSC), 3(2), 353-358.
- Anisarida, A. A., Prabowo, S., & Seran, E. N. B. (2023). METODE MEKANISTIK-EMPIRIS UNTUK MENGEVALUASI TEBAL PERKERASAN LENTUR MENGGUNAKAN PROGRAM (STUDI KASUS: JALAN CIBADAK-CIKIDANG-PELABUHAN RATU). JURNAL TEKNIK SIPIL CENDEKIA (JTSC), 4(1), 554-569.
- Rusmayadi, D., & Anisarida, A. A. (2021). ANALISIS KINERJA JALAN MOHAMMAD TOHA DENGAN ATAU TANPA MARKA JALAN. JURNAL TEKNIK SIPIL CENDEKIA (JTSC), 2(1), 152-181.
- Setiawan, F., & Janizar, S. (2021). Percepatan Jadwal Konstruksi dan Pengaruhnya Terhadap Biaya Penyelesaian Proyek Konstruksi. JURNAL TEKNIK SIPIL CENDEKIA (JTSC), 2(1), 90-126.