

Klasifikasi Citra Lubang Pada Permukaan Jalan Beraspal dengan Metode Convolutional Neural Networks

Potholes Recognition on Paved Road Surfaces using Convolutional Neural Networks

Ni Nyoman Citiriani Sumartha, I Gede Pasek Suta Wijaya, Fitri Bimantoro*, Gibran Satya Nugraha

Program Studi Teknik Informatika, Universitas Mataram

Jl. Majapahit 62, Mataram, Lombok NTB, INDONESIA

Email: citiriani.sumartha@gmail.com, [gpsutawijaya, bimo, gibransn]@unram.ac.id

*Penulis Korespondensi

Abstract A pothole is a less than one-meter-diameter indentation in the road surface that resembles a bowl. Potholes on the highway should be repaired as quickly as possible because they can jeopardize drivers' safety. Potholed road images are quite complicated, with variations in color contrast, hole size, puddle presence or absence, lighting during photoshoots, background, and other aspects. This calls for the development of a method that can identify photos with a lot of variance by identifying the crucial data present in them. Based on the possibility that the Convolutional Neural Networks (CNN) method will be successful in recognizing pothole photographs that will be reported for inclusion in the Public Works Service's road improvement record. From the test results, the highest accuracy is 0.99 with an image size of 128x128 and the number of hidden layers 3 and neurons 128.

Keywords: Pothole, Image, Classification, CNN

I. PENDAHULUAN

Menurut manual pemeliharaan jalan No: 03/MN/B/1983 yang dikeluarkan oleh Direktorat Jenderal Bina Marga, lubang (*pothole*) merupakan bagian dari macam kerusakan jalan yang masuk dalam kategori cacat permukaan (*disintegration*). Sebuah lekukan disebut *pothole* atau lubang jika memiliki diameter kurang dari 1 meter dan berbentuk mangkok di atas permukaan jalan. Lubang terbentuk karena aktivitas lalu lintas yang menyebabkan bagian-bagian kecil permukaan jalan terangkat. Lubang dapat menjadi lebih besar dengan cepat jika terisi oleh air, dan material permukaan yang lepas dari dasar tanahnya[1].

Pada tanggal 15 Juli 2022 diberitakan bahwa terjadi kecelakaan akibat adanya lubang (*pothole*) di salah satu jalan di kota Colchester, UK yang menyebabkan seorang pengendara sepeda mengalami patah tulang selangka di dua tempat. [2]. Selain itu diberitakan di NDTV.com, kecelakaan akibat adanya lubang (*pothole*) di jalan raya juga terjadi di Mumbai, India yang menyebabkan seorang pria tewas saat dia bersama istri dan anaknya hendak pergi ke Pydhoni. [3]. Tidak hanya di luar negeri, kecelakaan serupa yang disebabkan oleh adanya lubang (*pothole*) di

jalan juga terjadi di Indonesia. Pada tanggal 26 April 2022 platform berita regional kompas mengabarkan terjadi kecelakaan tunggal yang dialami seorang pria karena motornya masuk ke lubang jalan yang menyebabkan pria tersebut lumpuh. [4]. Selain itu melalui laman berita detik.com pada tanggal 8 Februari 2022 dikabarkan bahwa seorang warga Sidoarjo tewas karena mengalami kecelakaan akibat adanya lubang jalan di Mojokerto. Dari paparan di atas dapat disimpulkan bahwa adanya lubang (*pothole*) di jalan raya dapat membahayakan keselamatan pengguna jalan sehingga perlu diadakan perbaikan secepatnya. [5].

Menurut Dinas Pekerjaan Umum, proses perbaikan jalan melalui tiga tahanan antara lain pencatatan, proses lelang proyek, dan pelaksanaan perbaikan. Dan langkah pertama dari proses perbaikan merupakan salah satu penyebab lamanya proses perbaikan kerusakan jalan. Pada proses pencatatan, setiap kerusakan jalan harus dideteksi dan dicatat, dimana proses ini masih dilakukan secara manual. Karena proses yang masih konvensional dan manual, tentunya proses ini membutuhkan waktu yang cukup lama dengan tingkat akurasi yang rendah. Sebagai contoh, untuk pencatatan kerusakan jalan sepanjang 1 kilometer membutuhkan waktu hingga dua minggu. Untuk membantu percepatan proses pencatatan jalan rusak ini, dibutuhkan pelaporan dari pengguna jalan, dimana pengguna jalan dapat melaporkan lokasi dan juga mengunggah bukti kerusakan jalan kepada Dinas Pekerjaan umum sebagai dasar pencatatan [6].

Sudah banyak aplikasi yang diluncurkan dengan tujuan untuk memudahkan masyarakat terutama pengguna jalan untuk melaporkan adanya jalan rusak contohnya: Jaki, QlueApp, BucApp dan lain-lain. Jaki (Jalan Kita) merupakan beberapa contoh aplikasi yang membantu masyarakat Indonesia untuk melaporkan kondisi jalan dan jembatan. Aplikasi ini dikembangkan oleh Kementerian Pekerjaan Umum dan Perumahan Rakyat melalui Pusat Litbang Jalan dan Jembatan [7]. QlueApp adalah aplikasi pelaporan publik tidak hanya untuk jalan rusak namun juga untuk melaporkan permasalahan sosial dan lingkungan yang ditemui oleh masyarakat di kota, seperti lampu lalu

lintas yang rusak, limbah, pengemis, parkir ilegal, dan lain-lain. [8]. BucApp merupakan aplikasi yang dikhususkan untuk mencatat pelaporan terkait jalan rusak dan berlubang. Setelah menerima laporan, pihak BucAPP akan meninjau laporan tersebut, yang kemudian dilanjutkan dengan meneruskan laporan ke pemerintah setempat untuk penanganan lebih lanjut [9].

Beberapa karakteristik gambar jalan berlubang yaitu kompleksitasnya yang tinggi, dan juga beberapa variasi berupa kontras, ukuran lubang, adanya genangan air atau tidak, pencahayaan saat mengambil gambar, latar belakang dan lain-lain. Untuk mengatasi hal tersebut perlu dilakukan ekstraksi informasi dari citra masukan secara berlapis-lapis. Salah satu metode yang dapat digunakan untuk melakukan hal tersebut adalah *Artificial Neural Network* (ANN). Metode ini mampu mempelajari pola hubungan layer yang tidak diketahui sebelumnya (*hidden pattern*) antara data input dan output. Salah satu cabang *Machine Learning* yang menerapkan ANN pada data yang besar dengan menggunakan banyak *hidden layer* adalah *Deep Learning*. *Convolutional Neural Networks* (CNN) adalah salah satu jenis model *Deep Learning* yang biasa digunakan pada data gambar. Teknik CNN terinspirasi dari cara manusia menghasilkan persepsi visual. Dilihat dari potensi keberhasilan penggunaan pendekatan CNN dalam mengidentifikasi gambar jalan berlubang yang akan dilaporkan untuk masuk pencatatan perbaikan jalan Dinas Pekerjaan Umum, penulis mengusulkan gagasan "Klasifikasi Citra Lubang pada Permukaan Jalan Beraspal dengan Metode *Convolutional Neural Networks* (CNN)".

II. TINJAUAN PUSTAKA

A. Penelitian Terkait

Penelitian [10] adalah penelitian pertama yang mengembangkan model pendeteksian lubang jalan sekaligus rambu lalu lintas di jalanan India. Fitur gambar rambu lalu lintas diekstraksi menggunakan *Hybrid Features From Accelerated Segment Test* (FAST) dan dicocokkan dengan *Random Sample Consensus* (RANSAC) sedangkan fitur gambar lubang jalan diekstraksi dengan metode *Improved Canny Edge Detector* (ICED) dan *Bio-Inspired Contour Detection* (BCD). Proses klasifikasi menggunakan algoritma *Support Vector Machine* (SVM). Akurasi FAST-RANSAC-SVM adalah 98.47% dan akurasi ICED-BCD: 96.47%.

Penelitian [6] menggunakan *Local Binary Pattern* (LBP) untuk transformasi sebagai tahap awal ekstraksi ciri. Lalu, *K-Nearest Neighbor* (KNN) digunakan untuk klasifikasi citra jalan aspal berlubang atau tidak. Pada penelitian ini didapat akurasi terbaik dari nilai $K=5$ dan $K=7$, dengan total akurasi sebesar 96% dengan FAR sebesar 0% dan FRR sebesar 4,16%.

Jurnal [11] merupakan studi banding menggunakan lima model pembelajaran mesin klasifikasi biner yang dilakukan pada balanced data citra jalan aspal. Lima metode klasifikasi yang digunakan diantaranya: *Naïve Bayes*, Regresi Logistik, SVM, KNN dan *Random Forest Tree*. Metode klasifikasi *Random Forest Tree* dan KNN

menunjukkan kinerja terbaik pada dataset uji dengan akurasi yang sama yaitu sebesar 88,89%. Akurasi model *Random Forest Tree* setelah penyetelan *hyperparameter* adalah 94,44%.

Penelitian [12] merupakan penelitian pertama yang menggunakan *thermal imaging* untuk pendeteksian lubang jalan. Klasifikasi citra jalan berlubang pada penelitian ini menggunakan *Self-built CNN* dan ResNet (18, 34, 50, 101, 152). Dari klasifikasi menggunakan *Self-built CNN* didapatkan hasil rata-rata akurasi pelatihan sebesar 55,74%, akurasi validasi rata-rata sebesar 68,99% dan akurasi pengujian yang dicapai adalah 73,06%. Dari klasifikasi menggunakan ResNet didapatkan rata-rata akurasi pelatihan sebesar 94,64% dan akurasi validasi rata-rata sebesar 95,20% dengan akurasi validasi tertinggi sebesar 97,08%.

Penelitian [13] membahas tentang pendeteksian lubang menggunakan dua pendekatan, yaitu teknik *Spectral Clustering* dan *Deep Learning*. Pada pendekatan dengan Teknik *Spectral Clustering*, input citra diproses dengan *Spectral Clustering* dan operasi morfologi. Lalu lubang pada citra jalan dideteksi menggunakan *threshold classifier*. Metodologi ini tidak memerlukan fase pelatihan untuk mendeteksi lubang. Pada pendekatan dengan *Deep Learning* digunakan CNN dan AlexNet. Pengujian menggunakan kedua pendekatan itu dilakukan pada dataset seimbang yang dibentuk oleh 300 gambar yang berisi gambar RGB *pothole* dan *non-pothole*. Hasil yang didapatkan dari penelitian ini adalah akurasi klasifikasi citra jalan berlubang menggunakan CNN dan AlexNet lebih baik daripada *Spectral Clustering*. Akurasi yang didapatkan dengan metode CNN tanpa Augmentasi Data adalah sebesar 95%, dengan Augmentasi Data sebesar 96% sementara itu AlexNet sebesar 100%.

Penelitian [14] menyajikan model deteksi lubang improved CNN-based yang selanjutnya digunakan untuk memvalidasi perilaku cerdas dari prototipe kendaraan yang diusulkan dalam *driving decision-making*. Penelitian ini menghasilkan akurasi deteksi sebesar 99,02% dengan nilai FScore sebesar 98,33% dan sensitivitas sebesar 99,03% yang mengungguli berbagai teknik state-of-art dalam bidang ini menggunakan dataset publik 'Nienaber Potholes' yang dapat diakses dari platform Kaggle dimana data didapat dari hasil *web scrapping close-up* citra jalan berlubang.

Berdasarkan penelitian-penelitian yang sudah dilakukan sebelumnya, dapat dilihat bahwa CNN dapat bekerja dengan baik untuk pengklasifikasian citra. Oleh karena itu, penulis bermaksud untuk menggunakan metode ini untuk mengklasifikasikan citra jalan berlubang yang diambil dari *dashboard* mobil.

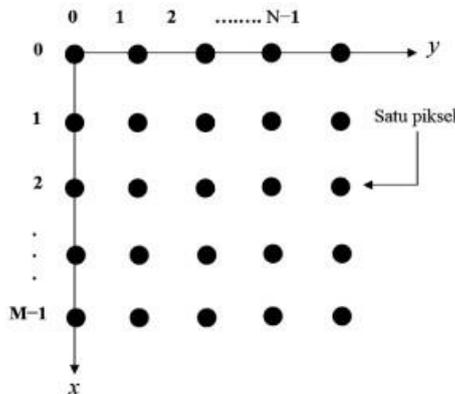
B. Teori Penunjang

B.1. Citra Digital

Citra merupakan representasi dari sebuah objek. Citra analog tidak dapat direpresentasikan dalam komputer, sehingga tidak bisa diproses oleh komputer secara langsung. Citra digital adalah representasi digital dari citra analog yang telah diproses melalui komputer. Karena

peralatan digital langsung memiliki sistem sampling dan kuantisasi, komputer dapat mengolah citra yang dihasilkan oleh peralatan digital langsung. Sistem sampling membagi citra analog menjadi M baris dan N kolom, menghasilkan citra diskrit.

Besar nilai M dan N akan mempengaruhi citra digital yang dihasilkan, Dimana semakin besar nilainya, maka detail dari citra akan semakin baik, atau dengan kata lain citra akan semakin halus. Selanjutnya akan dilakukan kuantisasi untuk mengubah intensitas citra analog ke dalam nilai diskrit yang merepresentasikan Tingkat keabuan atau warna dari citra. Hasil dari sampling dan kuantisasi ini kemudian akan membentuk representasi citra digital dalam bentuk matrik M x N dengan Tingkat warna sesuai kebutuhan. Ini berarti ukuran citra adalah MxN. Secara umum, sistem koordinat yang dipergunakan untuk mewakili citra dalam teori pengolahan citra digambarkan pada Gambar 1. [15].



Gambar 1. Sistem Koordinat Citra (Andono, Sutojo, and Muljono 2017).

Pertemuan antara M baris dan N kolom disebut piksel. Untuk semua piksel, selalu memiliki dua parameter antara lain koordinat atau posisi dan intensitas atau yang disebut juga derajat keabuan atau warna. Formulasi warna pada koordinat (x,y) adalah $f(x,y)$, atau dapat disebut juga besarnya intensitas warna pada koordinat atau pixel (x,y). Gambar 2 merupakan representasi citra digital dalam matriks [15].

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,M-1) \\ f(1,0) & \dots & \dots & f(1,M-1) \\ \dots & \dots & \dots & \dots \\ f(N-1,0) & f(N-1,1) & \dots & f(N-1,M-1) \end{bmatrix}$$

Gambar 2. Representasi citra digital dalam matriks

B.2 Lubang Jalan Beraspal

Kecuali jalur rel dan jalur kabel, jalan adalah prasarana pendukung transportasi darat yang terdiri dari bahu dan bdana jalan, serta prasarana penghubung, pelengkap, dan perlengkapan yang dirancang khusus untuk melayani lalu lintas pada permukaan, di atas, dan di bawah permukaan tanah dan/atau air. Lubang, juga dikenal

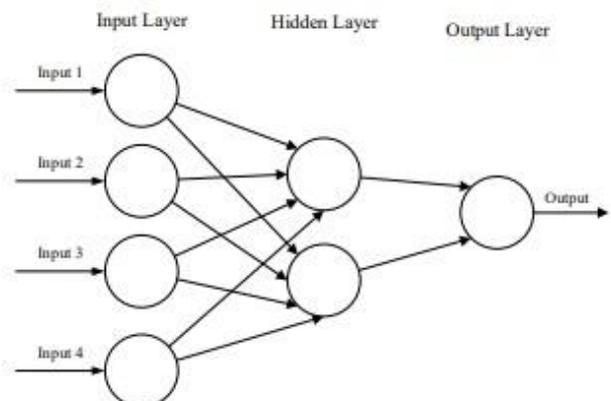
sebagai lubang, termasuk dalam kategori cacat permukaan (disintegrasi), yaitu kerusakan pada lampiran perkerasan secara kimiawi dan mekanis, menurut Manual Pemeliharaan Jalan Nomor: 03/MN/B/1983 yang dikeluarkan oleh Direktorat Jenderal Bina Marga. Pada permukaan perkerasan, lubang dapat berbentuk mangkuk dan berukuran mulai dari kecil hingga besar. Permukaan perkerasan memiliki lubang yang menampung air dan meresapkannya ke dalam lapis permukaan, menyebabkan kerusakan jalan menjadi lebih parah [16].

Menurut Koch & Brilakis, ciri visual lubang jalan beraspal adalah sebagai berikut:

1. Lubang memiliki ciri visual yaitu memiliki bagian bayangan yang lebih gelap dibandingkan permukaan sekitarnya.
2. Lubang memiliki bentuk yang cenderung atau mendekati elips karena distorsi perspektif.
3. Lubang memiliki tekstur yang lebih kasar dibandingkan permukaan jalan sekitarnya yang tidak berlubang.

B.3. Artificial Neural Network (ANN)

Artificial Neural Network (ANN) atau Jaringan Syaraf Tiruan (JST) adalah model komputasi yang mengambil inspirasi dari fungsi sistem saraf biologis, khususnya otak manusia. Terdiri dari node komputasi atau neuron yang saling berhubungan, ANN beroperasi secara terdistribusi untuk secara kolektif belajar dari data masukan dan mengoptimalkan keluaran.. Struktur dasar JST dapat dimodelkan seperti yang ditunjukkan pada Gambar 3. Kita akan memuat input, biasanya dalam bentuk vektor multidimensi ke lapisan input yang akan mendistribusikannya ke lapisan tersembunyi. Lapisan tersembunyi kemudian akan membuat keputusan dari lapisan sebelumnya dan menimbang bagaimana perubahan stokastik dalam dirinya sendiri merugikan atau meningkatkan hasil akhir, dan ini disebut sebagai proses pembelajaran. Memiliki beberapa lapisan tersembunyi yang ditumpuk satu sama lain biasanya disebut pembelajaran mendalam. [17].



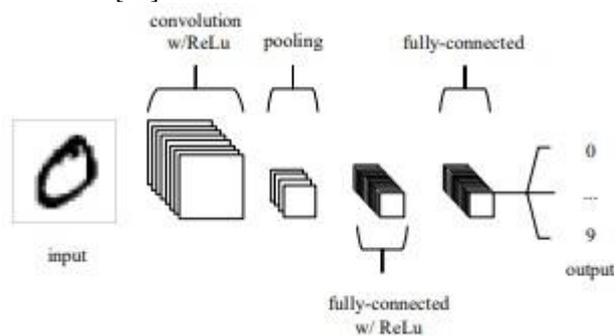
Gambar 3. Contoh Struktur JST [17].

B.4 Convolutional Neural Networks (CNN)

Convolutional Neural Networks (CNN) memiliki kesamaan dengan Jaringan Syaraf Tiruan (JST) tradisional karena keduanya melibatkan neuron yang menjalani pengoptimalan melalui pembelajaran. Setiap neuron di CNN menerima masukan, melakukan operasi (seperti perkalian skalar diikuti dengan fungsi non-linier), dan berkontribusi pada fungsi skor perseptif jaringan secara keseluruhan. Lapisan terakhir CNN mencakup fungsi kerugian yang terkait dengan prediksi kelas, dan strategi serta teknik yang sama yang digunakan dalam ANN tradisional juga dapat diterapkan pada CNN [17].

Salah satu keterbatasan terbesar dari bentuk tradisional ANN adalah bahwa mereka cenderung berjuang dengan kompleksitas komputasi yang diperlukan untuk menghitung data gambar. Kumpulan data perbandingan pembelajaran mesin yang umum seperti database MNIST dari angka tulisan tangan cocok untuk sebagian besar bentuk ANN, karena dimensi gambarnya yang relatif kecil, hanya 28×28 . Dengan kumpulan data ini, satu neuron di lapisan tersembunyi pertama akan berisi 784 bobot ($28 \times 28 \times 1$ di mana saya ingat bahwa MNIST dinormalisasi menjadi nilai hitam dan putih saja), yang dapat dikelola untuk sebagian besar bentuk ANN.

CNN terdiri dari tiga jenis lapisan berbeda: lapisan convolution, lapisan penggabungan, dan lapisan yang terhubung sepenuhnya. Ketika lapisan-lapisan ini digabungkan dalam susunan tertentu, mereka berkontribusi pada arsitektur CNN secara keseluruhan. Contoh arsitektur CNN yang disederhanakan untuk mengklasifikasikan data MNIST diilustrasikan pada Gambar 4 [17].



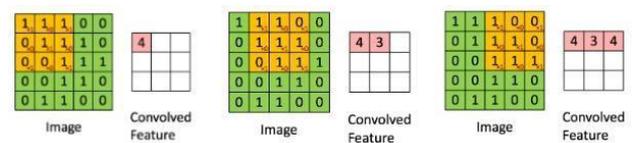
Gambar 4. Arsitektur CNN Sederhana Klasifikasi MNIST.

Contoh CNN yang disajikan pada Gambar 4 dapat dibedah menjadi empat komponen utama. Pertama, lapisan masukan menyimpan nilai piksel gambar, serupa dengan jenis jaringan syaraf tiruan (JST) lainnya. Selanjutnya, lapisan konvolusional menghitung keluaran neuron yang terhubung ke wilayah lokal masukan dengan mengalikan bobotnya dengan wilayah yang terhubung, dan menerapkan fungsi aktivasi seperti ReLu. Lapisan penyatuan kemudian menurunkan sampel masukan secara spasial untuk mengurangi jumlah parameter. Terakhir, lapisan yang terhubung sepenuhnya memproses aktivasi untuk menghasilkan skor kelas untuk klasifikasi, dengan

potensi penyertaan ReLu antar lapisan untuk meningkatkan kinerja.

B.4.1 Convolutional Layer

Lapisan konvolusi dalam jaringan saraf konvolusional (CNN) melakukan operasi konvolusi pada keluaran lapisan sebelumnya, yang berfungsi sebagai komponen dasar arsitektur CNN. Lapisan konvolusi sangat penting dalam desain CNN, karena melibatkan penerapan operasi matematika yang dikenal sebagai konvolusi, di mana kernel (diwakili oleh kotak kuning) diterapkan pada gambar di berbagai posisi. Proses ini, diilustrasikan pada Gambar 5 dengan kotak hijau yang mewakili gambar yang akan dikonvolusi, memerlukan pergerakan kernel dari kiri atas ke kanan bawah gambar, sehingga menghasilkan hasil konvolusi seperti yang digambarkan pada Gambar 5[18].



Gambar 5. Proses Convolution Layer.

B.4.2 Pooling Layer

Tujuan dari lapisan kolaborasi adalah untuk secara bertahap mengurangi dimensi representasi. Ini akan menyebabkan jumlah parameter dan kompleksitas komputasi model secara bertahap berkurang. Hanya ada dua metode maksimum pemotongan yang biasanya dilihat karena sifat destruktif dari lapisan pemotongan. Lapisan pemotongan beroperasi di atas setiap peta aktivasi yang dimasukkan dan menskalakan dimensinya menggunakan fungsi "MAX". Biasanya, langkah dan filter lapisan pooling diatur ke 2×2 , yang memungkinkan lapisan untuk meluas melalui dimensi ruang input secara keseluruhan. Selanjutnya, overlapping pooling dapat digunakan, di mana langkahnya diatur ke 2 dan ukuran kernel disetel ke 3. Karena sifat pooling yang merusak, memiliki ukuran kernel di atas 3 biasanya akan sangat mengurangi kinerja model [17].

B.4.3 Fully-Connected Layer

Fully-Connected layer adalah lapisan Dimana semua neuron aktivasi dari lapisan sebelumnya terhubung satu sama lain di lapisan selanjutnya, sama seperti neural network biasa. Lapisan ini biasanya digunakan pada MLP (Multi-Layer Perceptron) dengan tujuan untuk mengubah dimensi data sehingga data dapat diklasifikasikan secara linear. Neuron yang membedakan lapisan Fully-Connected dari lapisan konvolusi biasa adalah neuron yang terhubung penuh [19].

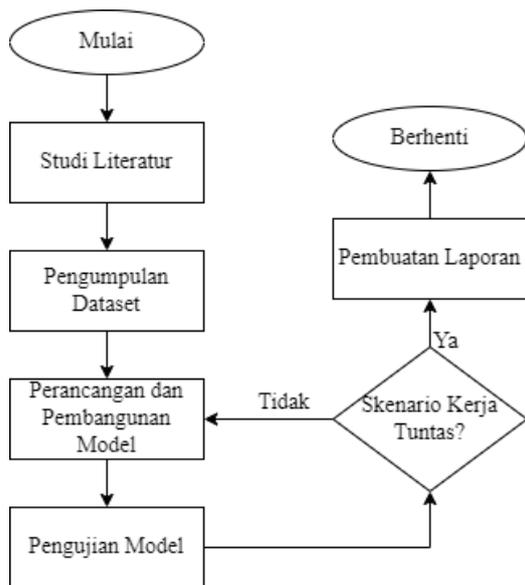
B.4.4 Dropout Regulation

Dropout merupakan salah satu regulasi pada Jaringan syaraf tiruan yang memiliki tujuan untuk mengurangi overfitting. Mekanisme yang dilakukan adalah dengan cara memilih neuron secara acak, kemudian tidak mengaktifkan neuron yang terpilih, dengan kata lain

neuron tersebut tidak digunakan selama proses pelatihan model. Hal ini berarti juga bahwa neuron yang terpilih tidak memiliki kontribusi selama proses pelatihan atau selama terpilih, meskipun neuron tersebut mendapatkan bobot yang baru saat proses backpropagation [19].

III. METODE PENELITIAN

Adapun diagram alur penelitian dari dimulainya penelitian sampai akhir penelitian dapat dilihat pada Gambar 6. Penelitian melalui beberapa tahap dari studi literatur yakni tahap untuk pembelajaran teori yang berkaitan dengan CNN dan juga lubang atau kerusakan jalan, dilanjutkan dengan pengumpulan dataset. Dalam hal ini dataset yang digunakan merupakan dataset MIIA Pothole Image Classification Challenge. Setelah dataset terkumpul, dilakukan perancangan dan pengembangan model yang sesuai. Tahap selanjutnya, pengujian model berdasarkan perancangan sebelumnya. Pada tahap ini akan dicatat performa model yang diujikan dengan beberapa metrik pengukuran, dimana hasil dari pengujian ini akan disajikan dalam bentuk tabel dan dianalisis lebih lanjut.



Gambar 6. Alur Penelitian

C. Studi Literatur dan Pengumpulan Dataset

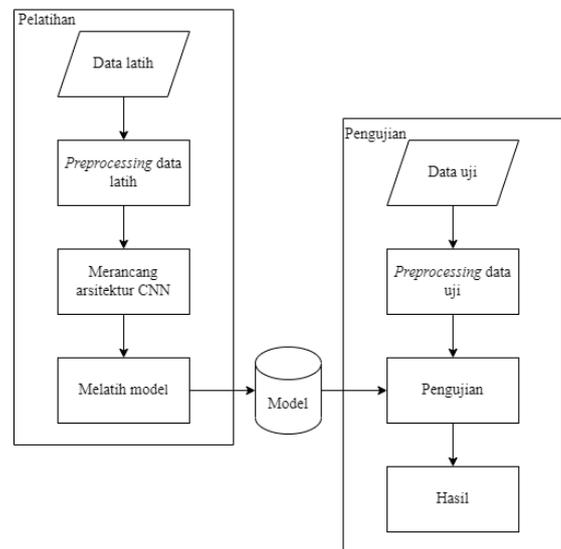
Dataset MIIA Pothole Image Classification Challenge digunakan dalam penelitian ini. Dataset tersebut berisi gambar jalan-jalan di Afrika Selatan yang memiliki lubang (respon positif) atau tidak (respon negatif). Dataset tersebut juga telah dibagi menjadi data latih dan data uji dengan data latih berisi 4.026 gambar dan data uji berisi 1.650 gambar. Pada website zindi.africa tempat dataset ini diunggah tidak ada keterangan bagaimana data gambarnya diambil namun dari datanya sendiri dapat dilihat bahwa pengambilan gambar dilakukan dari dashboard mobil dengan spesifikasi kamera yang juga tidak diketahui [20]. Gambar 7 merupakan contoh data yang digunakan.



Gambar 7. Contoh data pada dataset MIIA Pothole Image Classification Challenge

D. Perancangan dan Pengembangan Model

Pembangunan model dalam penelitian ini dapat dibagi menjadi dua proses utama yaitu pelatihan (*training*) dan pengujian (*testing*) yang dapat dilihat pada Gambar 8.



Gambar 8. Rancangan Pembangunan Model

Convolutional layer mampu secara signifikan mengurangi kompleksitas model melalui optimalisasi outputnya. Untuk pengembangan model pada penelitian ini lapisan *convolutional* akan menggunakan kernel 3x3 dengan variasi jumlah filter konvolusi: 32, 64, dan 128. Apabila dari hasil perhitungan layer konvolusi didapatkan nilai negatif, maka selanjutnya akan dilakukan mekanisme perhitungan tambahan untuk menghilangkan nilai negatif ini. Pada penelitian ini, fungsi aktivasi yang digunakan adalah aktivasi ReLU. Dengan fungsi aktivasi ReLU nilai negatif yang didapatkan pada perhitungan sebelumnya akan diubah menjadi 0. Fungsi aktivasi ReLU sendiri sudah digunakan pada banyak penelitian dan menghasilkan performa yang baik.

Selanjutnya, pada tahapan *Pooling*, penelitian ini menggunakan matriks 2x2 dengan stride sebesar 2. Ini berarti matriks ukuran 2x2 akan bergeser sebanyak 2 langkah, dengan kata lain pergeserannya tidak akan

tumpang tindih dengan matriks 2x2 sebelumnya, dan mekanisme seperti ini disebut dengan *max pooling*. Setelah melalui *pooling layer*, fitur yang terseleksi akan memasuki lapisan khusus yaitu *Flatten*. Tujuan dari *flatten* adalah mengubah fitur yang berbentuk matriks menjadi vektor agar sesuai dengan kebutuhan masukan dari *fully-connected layer*.

Masukan yang telah diubah bentuknya menjadi vektor selanjutnya akan memasuki lapisan *fully-connected*. Pada penelitian ini akan digunakan tiga variasi jumlah hidden layer yang berbeda yaitu 1 *hidden layer*, 2 *hidden layer* dan 3 *hidden layer* untuk mengetahui pengaruh jumlah *hidden layer* dalam penelitian. Untuk inisial awal masing – masing layer akan memiliki 64 neuron dan akan diubah dengan berbagai kombinasi untuk mendapatkan akurasi terbaik. Untuk menghindari terjadinya *overfitting* berlebih, maka *dropout* diterapkan selama pembangunan model ini. Variasi bobot *dropout* yang digunakan pada penelitian ini adalah 0% (*no dropout*), 20% dan 50%.

E. Pengujian Model

Berikut adalah beberapa variasi parameter pelatihan untuk membangun model klasifikasi pada penelitian ini:

1. Ukuran gambar: 128x128, 64x64 dan 32x32.
2. Ukuran filter konvolusi: 32, 64, dan 128.
3. Jumlah hidden layer: 1, 2 dan 3.
4. Jumlah neuron pada hidden layer: 32, 64 dan 128.
5. Bobot *dropout*: *no dropout* (0%), 20 % dan 50%
6. *Learning rate*: 0.01, 0.001, dan 0.0001.

IV. HASIL DAN PEMBAHASAN

A. Pengujian Terhadap Ukuran Matriks Input

TABEL I. PERFORMA MODEL TERHADAP UKURAN MATRIKS INPUT

Ukuran Matriks Input	Akurasi (%)	Loss Function
128x128	96	0.1031
64x64	97	0.1389
32x32	87	0.2767

Tabel I menunjukkan hasil pengujian performa model berdasarkan ukuran citra masukan. Berdasarkan data, didapatkan bahwa citra dengan ukuran 128x128 dan 64x64 memiliki performa yang tidak jauh berbeda yaitu akurasi 0.96 dan 0.97, sedangkan untuk ukuran 32x32 mendapatkan akurasi paling rendah di 0.87. Selain itu, loss yang diperoleh untuk ukuran 128x128 dan 64x64 tidak berbeda jauh namun masih unggul pada citra ukuran 128x128.

B. Pengujian Terhadap Ukuran Filter Konvolusi

TABEL II. PERFORMA MODEL TERHADAP UKURAN FILTER KONVOLUSI

Ukuran Filter Konvolusi	Akurasi (%)	Loss Function
128	96	0.1299
64	96	0.1031
32	94	0.1749

Berdasarkan hasil pengujian pada Tabel II, performa ukuran filter konvolusi 128 dan 64 mempunyai perbedaan sangat sedikit dengan tingkat akurasi sebesar 0.96, namun *Loss* pada ukuran filter konvolusi 64 lebih kecil daripada filter konvolusi berukuran 128.

C. Pengujian Terhadap Jumlah Hidden Layer

Berdasarkan hasil pengujian pada Tabel III, pembangunan menggunakan 3 hidden layer mempunyai performa yang lebih signifikan daripada hanya 2 dan 1 hidden layer dengan tingkat akurasi sebesar 0.99 dan nilai *Loss Function* yang lebih kecil senilai 0.977.

TABEL III. PERFORMA MODEL TERHADAP JUMLAH HIDDEN LAYER

Jumlah Hidden Layer	Akurasi (%)	Loss Function
3	99	0.0977
2	95	0.1582
1	95	0.1167

D. Pengujian Terhadap Jumlah Neuron pada Hidden Layer

TABEL IV. PERFORMA MODEL TERHADAP JUMLAH NEURON PADA HIDDEN LAYER

Jumlah Neuron pada Hidden Layer	Akurasi (%)	Loss Function
128	99	0.0977
64	91	0.24
32	88	0.2791

Berdasarkan hasil pengujian pada Tabel IV, performa jumlah neuron pada *hidden layer* berjumlah 128 mempunyai performa yang lebih signifikan daripada neuron berjumlah 64 dan 32 pada setiap *hidden layer* dengan tingkat akurasi sebesar 0.99 dan nilai *Loss Function* yang lebih kecil senilai 0.977.

E. Pengujian Terhadap Bobot Dropout

TABEL 5. PERFORMA MODEL TERHADAP BOBOT DROPOUT

Persentase Dropout	Akurasi (%)	Loss Function
0%	94	0.1746
20%	99	0.0977
50%	98	0.0903

Berdasarkan hasil pengujian pada Tabel 5, performa dengan variasi bobot *dropout* sebesar 50% dan 20% mempunyai perbedaan sangat sedikit dengan tingkat akurasi 0.98 dan 0.99, namun *Loss* pada variasi bobot *dropout* 50% lebih kecil daripada variasi bobot *dropout* 20%.

F. Pengujian Terhadap Learning Rate Optimizer

TABEL 6. PERFORMA MODEL TERHADAP NILAI α LEARNING RATE

Learning Rate	Akurasi (%)	Loss Function
0.0001	99	0.0977
0.001	91	0.1949
0.01	55	0.6899

Berdasarkan hasil pengujian pada Tabel 6, performa α learning rate bernilai 0.0001 mempunyai performa yang lebih signifikan daripada nilai α 0.01 dan 0.001 dengan tingkat akurasi sebesar 0.99 dan nilai *Loss Function* yang lebih kecil senilai 0.977.

V. KESIMPULAN DAN SARAN

Dari pengujian yang telah dilakukan, model terbaik didapatkan dengan menggunakan input citra dengan ukuran 128x128, ukuran filter konvolusi 64, dengan hidden layer 3, jumlah neuron 128, dropout 50% dan learning rate 0.0001.

Untuk penelitian selanjutnya, pengembangan model perlu dilakukan, selain itu jumlah dataset serta variasinya perlu ditingkatkan. Oleh sebab itu penggunaan augmentasi citra pada dataset dapat digunakan, serta penggunaan metode-metode transfer learning juga dapat diterapkan untuk mendapatkan model terbaik untuk klasifikasi lubang.

REFERENCES

- [1] F. Yudanigrum and I. Ikhwanudin, "Identifikasi Jenis Kerusakan Jalan (Studi Kasus Ruas Jalan Kedungmundu-Meteseh)," *Teknika*, vol. 12, no. 2, pp. 16–23, 2017, doi: 10.26623/teknika.v12i2.638.
- [2] T. Dalby, "Colchester pensioner taken to hospital after pothole crash," *gazette-news.co.uk*. Accessed: Aug. 05, 2022. [Online]. Available: <https://www.gazette-news.co.uk/news/20273278.colchester-pensioner-taken-hospital-pothole-crash/>
- [3] Press Trust of India, "Motorcyclist Dies After Falling Into Pothole In Mumbai," *ndtv.com*. Accessed: Aug. 05, 2022. [Online]. Available: <https://www.ndtv.com/mumbai-news/motorcyclist-dies-after-falling-into-pothole-in-mumbai-2667807>
- [4] Firmansyah, "Usman Lumpuh karena Jatuh di Lubang Jalan, Polisi Periksa Pejabat PU Kota Bengkulu," *Kompas.com*. Accessed: Aug. 05, 2022. [Online]. Available: <https://regional.kompas.com/read/2022/04/26/152003478/usman-lumpuh-karena-jatuh-di-lubang-jalan-polisi-periksa-pejabat-pu-kota?page=all>
- [5] E. E. Budianto, "Potret Jalan Berlubang di Mojokerto yang Telan Korban Jiwa," *detik.com*. Accessed: Aug. 05, 2022. [Online]. Available: <https://www.detik.com/jatim/berita/d-5933955/potret-jalan-berlubang-di-mojokerto-yang-telan-korban-jiwa>
- [6] P. P. Arhandi, M. Mentari, and F. Romadhon, "Kombinasi Metode Logical Binary Pattern dan K-Nearest Neighbor untuk Identifikasi Lubang pada Jalan Aspal," *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 10, no. 1, p. 11, 2021, doi: 10.23887/janapati.v10i1.30999.
- [7] R. Humas Jateng, "Laporkan Jalan Rusak Melalui Aplikasi Jalan Kita (Jaki)," *jatengprov.go.id*. Accessed: Aug. 05, 2022. [Online]. Available: <https://jatengprov.go.id/publik/laporkan-jalan-rusak-melalui-aplikasi-jalan-kita-jaki/>
- [8] PT. Qlue Performa Indonesia, "About Qlue Smart City," *qlue.co.id*. Accessed: Aug. 05, 2022. [Online]. Available: <https://www.qlue.co.id/>
- [9] A. Strange, "Finally, an APP to Report Potholes. BUCAPP - but it's Only in ITALY!," *visordown.com*. Accessed: Aug. 05, 2022. [Online]. Available: <https://www.visordown.com/news/general/finally-app-report-potholes-bucapp-it-s-only-italy>
- [10] S. K. Satti, S. D. K., P. Maddula, and N. V. V. Ravipati, "Unified approach for detecting traffic signs and potholes on Indian roads," *Journal of King Saud University - Computer and Information Sciences*, no. xxxx, 2021, doi: 10.1016/j.jksuci.2021.12.006.
- [11] O. A. Egaji, G. Evans, M. G. Griffiths, and G. Islas, "Real-time machine learning-based approach for pothole detection," *Expert Systems with Applications*, vol. 184, p. 115562, 2021, doi: 10.1016/j.eswa.2021.115562.
- [12] Aparna, Y. Bhatia, R. Rai, V. Gupta, N. Aggarwal, and A. Akula, "Convolutional neural networks based potholes detection using thermal imaging," *Journal of King Saud University - Computer and Information Sciences*, vol. 34, no. 3, pp. 578–588, 2022, doi: 10.1016/j.jksuci.2019.02.004.
- [13] G. Srinidhi and R. D. SM, "Pothole Detection using CNN and AlexNet," *SSRN Electronic Journal*, 2020, doi: 10.2139/ssrn.3648822.
- [14] D. K. Dewangan and S. P. Sahu, "PotNet: Pothole detection for autonomous vehicle system using convolutional neural network," *Electronics Letters*, vol. 57, no. 2, pp. 53–56, 2021, doi: 10.1049/el12.12063.
- [15] "Pengolahan Citra Digital - Pulung Nurtantio Andono, T.Sutojo, Muljono - Google Books." Accessed: Jul. 12, 2024. [Online]. Available: https://books.google.co.id/books?id=zUJRDwAAQBAJ&printsec=frontcover&source=gbs_ge_summary_r&ad=0#v=onepage&q&f=false
- [16] F. Yudanigrum and I. Ikhwanudin, "IDENTIFIKASI JENIS KERUSAKAN JALAN (Studi Kasus Ruas Jalan Kedungmundu-Meteseh)," *Teknika*, vol. 12, no. 2, 2017, doi: 10.26623/teknika.v12i2.638.
- [17] A. Saxena, "An Introduction to Convolutional Neural Networks," *Int J Res Appl Sci Eng Technol*, vol. 10, no. 12, 2022, doi: 10.22214/ijraset.2022.47789.
- [18] M. I. Mardiyah, "Implementasi Deep Learning untuk Image Classification Menggunakan Algoritma Convolutional Neural Network (CNN) Pada Citra Kebun dan Sawah," *Universitas Islam Indonesia*, no. June, 2020, doi: 10.13140/RG.2.2.10880.53768.
- [19] T. Nurhikmat, "Implementasi Deep Learning Untuk Image Classification Menggunakan Algoritma Convolutional Neural Network (Cnn) Pada Citra Wayang Golek," *Universitas Islam Indonesia*, vol. 10, no. 2, 2018.
- [20] Machine Intelligence Institute of Africa, "MIIA Pothole Image Classification Challenge," *zindi.africa*. Accessed: Oct. 01, 2022. [Online]. Available:

<https://zindi.africa/competitions/miia-pothole-image-classification-challenge>