

Pengaruh Algoritma Deep Learning dalam Meningkatkan Akurasi Sistem Pendeteksian Kondisi Jalan Raya

W Mellyssa¹, AF Dewi², M Misriana³, S Suryati⁴, R Rachmawati⁵

*Jurusan Teknik Elektro Politeknik Negeri Lhokseumawe
Jln. B.Aceh Medan Km.280 Buketrata 24301 INDONESIA*

¹widdha.mellyssa@pnl.ac.id

Abstrak— Kondisi permukaan badan jalan adalah salah satu factor kunci dalam keamanan dan keselamatan lalu lintas. Kurangnya perawatan dan kondisi lalu lintas yang padat akan mempengaruhi permukaan jalan. Proses pencegahan kerusakan sangat penting dilakukan untuk meminimalisir dampak buruk jalan tersebut. Saat ini perkembangan teknologi dan kemampuan komputasi yang tinggi memungkinkan proses pendeteksian suatu objek dapat dilakukan secara otomatis. Perkembangan deep learning dan kemampuan komputasi yang tinggi memungkinkan untuk melakukan otomatisasi dalam proses pendeteksian sebuah objek. Pada penelitian ini, dilakukan proses deteksi kondisi badan jalan dengan menggunakan jaringan syaraf tiruan dikombinasikan dengan *deep learning* untuk memaksimalkan hasil prediksi. Hasil dari model penelitian ini dapat digunakan secara berkelanjutan untuk proses survei dan pemetaan kondisi jalan raya. Pada pekerjaan ini, dilakukan proses ekstraksi masukan gambar untuk kemudian dipelajari melalui sistem jaringan syaraf tiruan. Proses pembelajaran otomatis akan dijalankan dengan metode deep learning menggunakan jaringan Convolutional Neural Network (CNN). Melalui pendekatan ini, model ini dapat mendeteksi dan mengenali dengan sangat baik perbedaan kondisi jalan. Keefektifan model ini akan diterapkan pada data gambar asli yang sudah di koleksi oleh Pothole dataset dengan tingkat akurasi prediksi mencapai 97% pada tingkat perbandingan pembelajaran fitur 80% dan tingkat pengesanan 20 %.

Kata kunci— convolutional neural network, ekstraksi citra, model deep learning.

Abstract— The condition of the public road surface is one of the key factors in traffic safety and security. Lack of maintenance and heavy traffic condition will affect to the road surface. The process of preventing damage is very important to minimize the bad effect the road. Nowadays, the development of deep learning and high computing capabilities make it possible to automate the process of detecting an object. In this study, we carry out the process of detecting and recognizing road conditions using an artificial neural network combined with deep learning to maximize prediction results. The results of this model can be used continuously for the process of surveying and mapping road conditions. In this work, we extract the input images and then study them through an artificial neural network system. The automatic learning process will be run with a deep learning method using the Convolutional Neural Network (CNN) based on VGG network. Through this approach, this model can detect and recognize differences in road conditions very well. The effectiveness of this model is applied to the original image data that has been collected by the Pothole dataset with a prediction accuracy rate of 97.3% at comparison level 80% and 20% feature extraction during training, validation and testing respectively.

Keywords— Convolutional Neural Network, feature extraction, deep learning model.

I. PENDAHULUAN

Jalan raya merupakan prasarana transportasi darat utama yang mendukung pertumbuhan ekonomi masyarakat. Seiring dengan tingginya penggunaan sebuah jalan beraspal, kerusakan menjadi hal yang tak bisa dihindari. Di saat kerusakan jalan menjadi permasalahan karena dapat membahayakan pengguna jalan. Proses pendataan dan survey menjadi sangat penting sebagai langkah preventif. Proses pendataan saat ini masih dengan pendekatan manual inspeksi. Dibutuhkan sebuah sistem atau model yang memungkinkan pendataan dan proses pendeteksi kerusakan jalan secara otomatis. Dari beberapa penelitian yang telah dikerjakan maka metode pengolahan citra digital dapat dimanfaatkan sebagai solusi dari permasalahan ini [1],[2].

Perkembangan komputasi di era sekarang memungkinkan untuk menjalankan pendekatan otomatis deep learning [3]. Deep learning sendiri merupakan pengembangan dari teknologi yang melibatkan kecerdasan buatan atau Artificial Intelligent(AI). Deep learning adalah salah satu bidang machine learning yang memanfaatkan banyak layer pengolahan informasi nonlinier untuk melakukan ekstraksi fitur, pengenalan pola, dan klasifikasi [4]. Pemanfaatan teknologi ini dibutuhkan agar mampu melakukan pendeteksi dengan akurasi tinggi terhadap inputan gambar yang diinginkan.

Metode yang digunakan untuk mendeteksi citra input adalah Convolutional Neural Network (CNN), juga dikenal sebagai convnets merupakan salah satu algoritma populer yang dapat diterapkan untuk memecahkan berbagai masalah pengenalan gambar. Teknologi telah merevolusi kemampuan komputer, dalam mencapai hasil pengolahan dalam banyak kasus dan model matematis. Algoritma ini juga merupakan kekuatan pendorong di balik berkembangnya aplikasi saraf tiruan yang pertama kali berhasil memecahkan kasus dengan pemodelan matematis. Klasifikasi citra merupakan salah satu pemanfaatan model yang dapat diselesaikan oleh CNN [5].

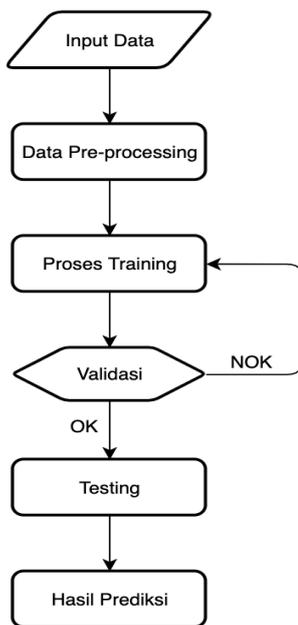
Proses pengenalan jenis kerusakan jalan memanfaatkan teknologi berbasis kecerdasan buatan belum banyak diterapkan pada kendaraan konvensional. Di tengah maraknya perkembangan mobil listrik dan smart car, pengembangan ke arah komputerisasi dan pemanfaatan komputer vision dalam memaksimalkan akurasi menjadi sangat penting. Proses untuk koleksi data, dan pengukuran dengan manual sangat memakan waktu dan tenaga. Jika sebuah pemodelan komputer dapat dilakukan, hal tersebut tentu akan sangat membantu. Pekerjaan secara manual juga dirasa sangat melelahkan dan tidak aplikatif. Tentu saja penggunaan komputer akan sangat membantu.

Memanfaatkan kemampuan pembacaan data citra dari sebuah komputer akan sangat membantu pengembangan sebuah model sesuai dengan kebutuhan. Dalam hal

pendeteksian permukaan jalan, dilakukan penelitian dengan melakukan pemodelan ekstraksi gambar dari sebuah gambar dengan dua kondisi. Kategori jalan kondisi baik dan kondisi jalan yang tidak layak atau jalan yang dikategorikan berlubang. Model ini akan memberikan hasil untuk memberi tahu sebuah gambar apakah mengandung jalan rusak atau tidak. Berbasis VGG network, model ini berhasil mendeteksi inputan dengan akurasi tinggi.

II. METODOLOGI PENELITIAN

Secara umum scenario pemodelan sistem deteksi ini akan mengikuti alur yang pada Gambar 1. Pada penelitian ini semua tahapan dimulai dari input image dan menghasilkan output berupa prediksi gambar sesuai dengan kategori jalan dimaksud.



Gambar 1 Diagram alir proses pemodelan

A. Proses Persiapan Data

Tahapan pertama dari persiapan model ini adalah proses koleksi data. Dimulai dengan persiapan dataset. Dataset yang digunakan pada penelitian ini adalah Pothole-dataset dengan jumlah gambar sebanyak 670 images [6]. Resolusi image dari dataset bervariasi sesuai dengan inputan kamera perekam. Dataset yang digunakan merupakan data image yang diambil dari berbagai macam sumber, jenis jalan, kondisi jalan dan kondisi penerangan.

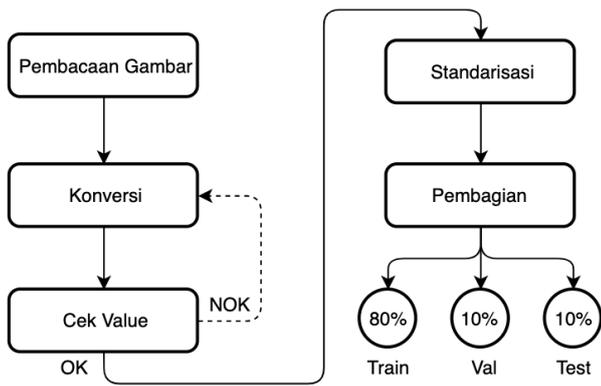
Dataset ini merupakan data real kondisi jalanan aspal di berbagai kondisi dan bentuk jalanan yang sesuai

dengan standar penggunaan jalan. Jenis sample data yang ada dapat dilihat pada Gambar 2. Dalam proses persiapan data, menggunakan bahasa pemrograman Python versi 3 untuk melakukan proses pengolahan data. Dalam pemodelan network ditambahkan python libraries pada proses otomatis pembacaan. Penggunaan library tambahan ini akan meningkatkan kemampuan pengolahan input gambar menjadi lebih cepat. library open source yang digunakan antara lain:

- *Pandas* untuk menggunakan pembacaan data
- *Sci-kit image* sebagai library untuk transformasi gambar
- *NumPy* adalah librai untuk merubah image RGB menjadi vector multi dimensi
- *Matplotlib* untuk graphic visualisasi saat melakukan pengecekan hasil akhir.

Pembacaan image dimulai dengan menyesuaikan jenis image dengan standar yang akan diaplikasikan. Pada penelitian ini standar image yang digunakan adalah format kompresi JPEG. File dengan pengaturan ukuran image ditetapkan pada 224x224 pixels agar dapat menyesuaikan dengan input training. Pada tahap pembelajaran otomatis atau training menggunakan VGG network dengan menetapkan ukuran data 224x224 pixels. Semua image dari dataset sumber akan diformat untuk menyesuaikan dengan target input image yang dimaksud. Proses penyesuaian ini akan menggunakan sci-kit library. Proses dapat dilakukan secara *per-batch* di tahap persiapan maupun di luar proses persiapan. Jika semua image sudah terbaca dengan ukuran dan ketentuan yang sudah diharapkan, selanjutnya persiapan untuk konversi image. Konversi bertujuan untuk menyesuaikan data input pada proses konvolusi di jaringan *Neural Network* (NN). Image akan dikonversi ke dalam vektor bernilai dan berdimensi tiga (RGB).

Matriks vektor dari image yang akan diproses menggunakan numpy library. Numpy digunakan karena sebuah image butuh ditransformasikan kedalam sebuah matriks berpola agar semua operasi convolusi pada proses training tidak mengalami perbedaan dimensi data. Dalam pengkonversi data, layaknya sebuah sebaran data mentah ditemukan nilai yang jauh dari distribusi keseluruhan. Maka dalam proses pengecekan value, dilakukan pembersihan data tersebut agar data lebih rapi dan menghindari data kosong (*empty fields*). Penghapusan data dengan nilai null juga dilakukan pada vector metric agar pembacaan model lebih baik. Ini merupakan strategi umum dalam pengolahan data. Pada tahap pengecekan, jika ada nilai yang masih salah akan segera dilakukann pembersihan kembali secara otomatis. Proses *re-check* untuk mengkonversi ulang data akan sering ditemukan agar keseimbangan data dapat tercapai. Data ini akan diteruskan ke tahapan selanjtnya yaitu standarisai image.



Gambar 2 Proses pengolahan data

Pada tahap standarisasi data, diasumsikan bahwa semua data sudah rapi (*without null*), bersih dan sudah cukup merepresentasikan kondisi sebaran data ideal. Pada proses standarisasi semua data akan diberikan label sesuai kelas yang akan diprediksi. Pada penelitian ini, data dibagi ke dalam dua kondisi yaitu jalan dengan kondisi baik (*class_0*) yang artinya tidak ada lubang. Kelas kedua adalah jalan dengan permukaan dikategorikan rusak (*class_1*). Contoh dari kategori ini dapat dilihat pada contoh Gambar 3. Pada Gambar 3 terlihat jenis kerusakan pada permukaan jalan seperti pada gambar 3(a). Sementara kelas jenis kedua adalah jalan rusak yang menggambarkan kondisi real lapangan dengan berbagai macam jenis kerusakan Gambar 3(b).

Setelah kelas distandarisasi, data dibagi (*split*) dengan pola 80:10:10. Data akan dipecah menjadi 80% sebagai data untuk dipelajari oleh model atau data training, kemudian 10% untuk dijadikan data evaluasi atau *network validation data*. Proses ini sesuai dengan dengan flow chart validasi Gambar 1. Data validasi ini adalah data yang akan menentukan validitas dan efektifitas hasil prediksi tahap awal. Pada tahap pengembangan model, dicari nilai validasi yang memberikan nilai akurasi validasi tertinggi. Pada bagian akhir akan dipersiapkan 10% data untuk pengujian (*testing data*). Kemampuan prediksi model ini akan dinilai dari nilai akurasi oleh data ini. Sebaran data ini adalah nilai yang merepresentasikan kondisi keadaan jalan yang ada. Secara praktis, data ini dapat diganti dengan data real lapangan penunjukan lajur jalan dan kondisi jalan setempat.

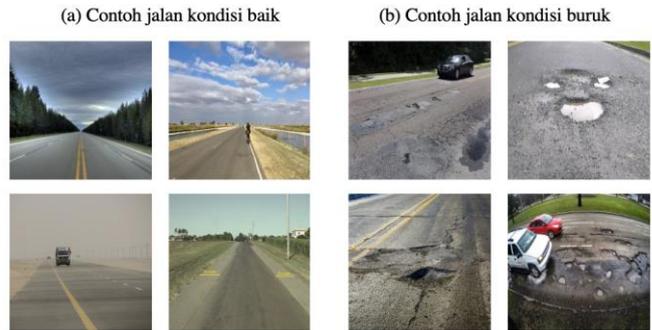
B. Ekstraksi Data

CNN adalah jaringan saraf tiruan yang mengekstrak fitur dari sebuah gambar input. Fitur merupakan nilai representasi dari sesuatu objek yang tengah diamati [7]. Pada penelitian ini, penggunaan CNN dengan model neuron dapat mengamati bentuk dari input jalan yang diberikan. Kriteria (*features*) jalan dengan kondisi normal dan yang dimiliki oleh jalan rusak. Fitur yang didapatkan akan dijadikan sinyal dalam proses transfer dalam setiap neuron pada jaringan

syaraf buatan. Gabungan sinyal yang ditransmisikan dalam jaringan CNN inilah yang akan dipelajari. Ditambahkan dengan nilai bias yang ditentukan secara otomatis dengan konsep machine learning.

Baik dari sebaran probabilitas maupun pendekatan regresi CNN melakukan pemodelan. Fitur yang diekstraksi akan digunakan oleh model untuk melakukan klasifikasi. Klasifikasi pada CNN kemudian bekerja berdasarkan ekstraksi fitur gambar jalan dan menghasilkan output sebuah prediksi. Jaringan CNN dalam melakukan ekstraksi fitur memiliki beberapa lapisan (*layer*) konvolusi dan kumpulan lapisan penyatuan (*pooling*).

Sesuai dengan namanya, lapisan konvolusi mengubah

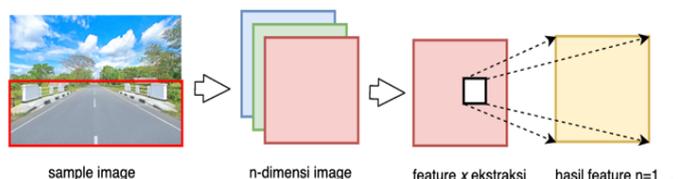


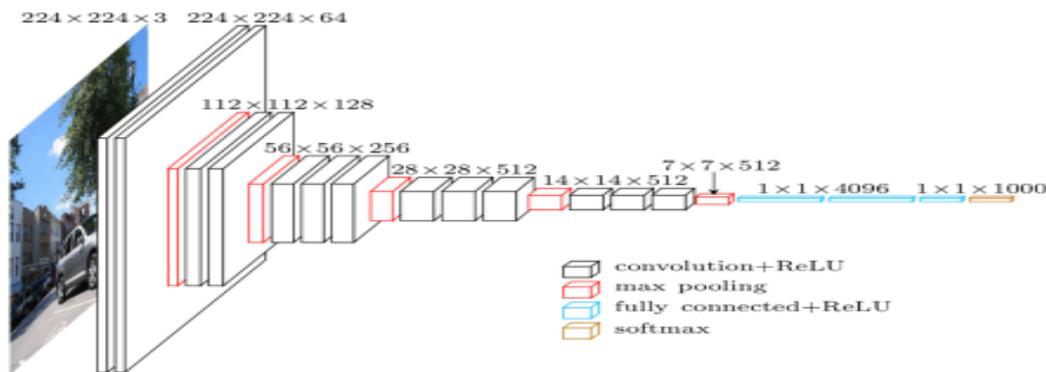
Gambar 3 Sampel perbedaan kelas jalan yang akan dideteksi

gambar menggunakan operasi konvolusi. Ini dapat digambarkan sebagai serangkaian filter digital. Lapisan *pooling* mengubah piksel tetangga menjadi satu piksel. *Pooling layer* kemudian mengecilkan dimensi gambar. Dikarenakan perhatian utama CNN adalah gambar, prosedur lapisan konvolusi dan penyatuan secara intuitif dalam bidang dua dimensi. Proses ilustrasi ekstraksi gambar pada penelitian ini dapat dilihat pada Gambar 4.

Penelitian ini menggunakan jaringan VGG dalam melakukan ekstraksi fitur dan menjalankan training. Model VGG, atau VGGNet, yang menerapkan 16 layers NN juga disebut sebagai VGG16. VGG model merupakan jaringan saraf convolutional yang diusulkan oleh Simonyan, K., & Zisserman, A. (2014) [8]. Input image size pada penelitian ini adalah 224x224 pixel menyesuaikan dengan input VGG model. Gambar 5 merupakan visualisasi dari 16-layers CNN pada VGG. Secara akrsitektur, dapat dijelaskan sebagai berikut:

- Input image: VGGNet mengambil ukuran input gambar 224x224 pixels, jika image melebihi akan dilakukan rezise dengan *sci-kit library* agar sesuai dengan target size.
- *Convolutional Layers*: Convolutional Layers pada VGG memanfaatkan bidang reseptif minimal, yaitu, 3x3 pixel.





Gambar 5 Arsitektur jaringan VGG16

- Ada pula konvolusi 1x1 yang bertindak sebagai transformasi linier dari input image. Tahapan ini diikuti oleh fungsi ReLU. ReLU adalah fungsi linier yang akan menampilkan input jika bernilai positif; jika tidak, outputnya adalah nol. Langkah konvolusi spasial dan pergeseran operasi piksel dipertahankan setelah konvolusi
- *Hidden layers*: adalah semua lapisan tersembunyi di jaringan VGG menggunakan fungsi ReLU. VGG biasanya tidak memanfaatkan Normalisasi Respon Lokal (LRN). Agar menghemat konsumsi memory.
- *Fully-Connected layers*: Pada VGG16 memiliki 3 FCN dengan layer terakhir berdimensi 4096, yang berbeda pada penelitian ini yaitu diggunakannya 2 output karena tipe jalan yang dianalisa adalah jalan rusak dan jalan normal.

C. Proses Training

Dalam proses training, jaringan VGG16, dilakukan beberapa penyesuaian settingan parameter sebagai berikut:

- Epoch: 30
- Learning rate: 0.001

D. Proses Evaluasi dan Testing

Untuk mengevaluasi model pada penelitian ini, digunakan metrik akurasi [9]. Metrik ini memberikan detail informasi tentang kualitas model yang tengah dikembangkan. Penentuan jumlah *True Positive* (TP), *False Positif* (FP), *True Negative* (TN) dan *False Negative* (FN).

$$\text{Akurasi} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{FN} + \text{TN}}$$

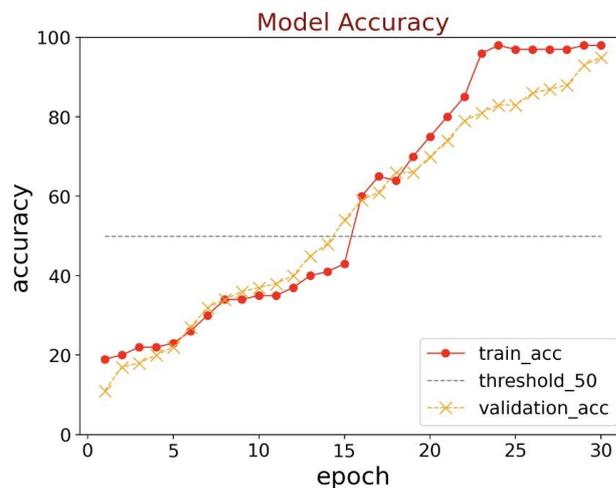
Setiap jenis test data akan dites dan dievaluasi pada tahap akhir pemuktian hasil detecksi. Metriks yang digunakan terlihat pada persamaan di atas. Pengukuran perbandingan antara nilai prediksi benar dan nilai prediksi salah untuk menentukan keefektifitas dari prediksi yang diberikan oleh model ini.

Data yang digunakan ke dalam proses training menggunakan model VGG16 sudah mampu mewakili data real yang ada di lapangan jika dilihat dari variasi kerusakan

jalan. Hal ini diharapkan proses training dapat berjalan lebih maksimal. Proses training menggunakan setidaknya 30 kali (*epochs*) proses evaluasi untuk menentukan proses ekstraksi terbaik sebelum melakukan proses testing. Hasil ekstraksi yang didapat sangat menentukan besar tidaknya tingkat penilaian keberhasilan atau akurasi

III. HASIL DAN PEMBAHASAN

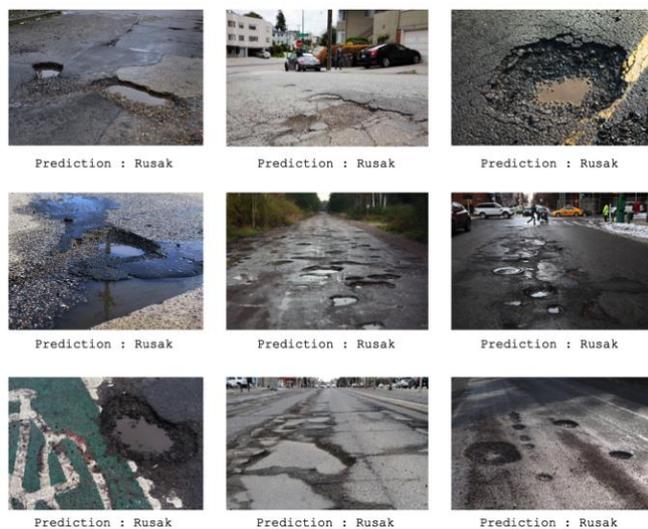
Pada Gambar 6 dapat dilihat peningkatan nilai akurasi model dalam proses training dan pembelajaran. Hasil training dan pembelajaran dari 67 data input didapatkan nilai akurasi sebesar 97.3%. Hampir semua jenis kerusakan jalan yang umum ditemukan dapat dideteksi dengan baik oleh model dengan CNN. Distribusi data juga beragam yang mengindikasikan bahwa data training yang diberikan pada jaringan VGG16 cukup merata dan terdistribusi mendekati ideal.



Gambar 6 Grafik performansi nilai akurasi pada data training dan data uji

Pada Gambar 7 ditampilkan beberapa hasil prediksi dari model yang dikembangkan. Dari gambar tersebut terlihat bahwa model dengan jelas dapat berhasil mengklasifikasikan gambar test yang diberikan. Terdapat beberapa spesifik bentuk kerusakan jalan yang masih memiliki kesalahan prediksi, menurut hasil analisa yang dilakukan, image dengan kualitas kurang baik membuat model menjadi tidak sensitive.

Selanjutnya, bentukan jalan mempengaruhi dalam proses ekstraksi data. Proses pembacaan sebaran training data juga sangat mempengaruhi keakuratan prediksi akhir. Sebagaimana yang ditemukan bahwa pada data training yang akan diekstraksi memiliki beberapa persamaan jenis kerusakan jalan. Keterbatasan ini membuat data test yang diajukan jauh dari distribusi training data. Perbedaan ini akan sedikit mempengaruhi hasil prediksi akhir.



Gambar 7 Hasil deteksi deep learning dengan jaringan VGG16

Ke depannya akan dilakukan pengayaan data dan memperbanyak sampel/jenis kerusakan agar model dapat mengolah proses training dengan lebih baik. Pengembangan ini juga akan memperbanyak proses evaluasi berlanjut agar akurasi deteksi meningkat.

IV. KESIMPULAN

Dari hasil percobaan pada data testing dan evaluasi, ditemukan bahwa dengan menggunakan VGG16 berhasil mendeteksi kerusakan pada image yang diberikan. Dengan basis *deep learning* dan menggunakan CNN untuk ekstraksi fitur image, akan sangat membantu proses training dan penentuan kelas input image. Model ini berhasil menghasilkan akurasi di angka 97.3 % dan error deteksi sebesar 2.7% hal ini terjadi karena kualitas image yang kurang baik seperti warna buram dan tidak kontras. Dengan melihat performa dari model yang dipelajari, dapat diambil kesimpulan bahwa pendeteksian kondisi jalan dengan menggunakan deep learning adalah metode yang menjanjikan. Metode ini mengurangi kemungkinan *human error* sehingga dapat diaplikasikan secara praktis. Pengembangan ke depannya adalah modifikasi model agar lebih sensitive pada sebaran data training kecil.

REFERENSI

[1] Mellyssa, W., Misriana, M., Suryati, S., & Milawarni, M. (2020). Perbandingan Penggunaan Metode Otsu Thresholding dan Adaptive Thresholding pada Proses Binerisasi Sistem Dokumentasi Buku Tugas Akhir.

In *Prosiding Seminar Nasional Politeknik Negeri Lhokseumawe* (Vol. 4, No. 1, pp. 49-54).

[2] MELLYSSA, widdha et al. PENERAPAN METODE OTSU THRESHOLDING DAN KOEFISIEN KORELASI PADA PENDETEKSIAN JUDUL BUKU TUGAS AKHIR. **Jurnal Elektro dan Telekomunikasi Terapan (e-Journal)**, [S.l.], v. 8, n. 1, p. 925 - 933, july 2021. ISSN 2442-4404.

[3] Yan, L. C., Yoshua, B., & Geoffrey, H. (2015). Deep learning. *nature*, 521(7553), 436-444.

[4] Deng, L., & Yu, D. (2014). Deep learning: methods and applications. *Foundations and trends® in signal processing*, 7(3-4), 197-387.

[5] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.

[6] <https://www.kaggle.com/>

[7] Nixon, M., & Aguado, A. (2019). *Feature extraction and image processing for computer vision*. Academic press.

[8] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.

[9] Gunawardana, A., & Shani, G. (2009). A survey of accuracy evaluation metrics of recommendation tasks. *Journal of Machine Learning Research*, 10(12).