

IDENTIFIKASI KECACATAN PADA JALUR REL KERETA API BERBASIS PENGOLAHAN CITRA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK

DEFECTIVE IDENTIFICATION OF RAILWAY BASED ON IMAGE PROCESSING USING CONVOLUTIONAL NEURAL NETWORK

Yuliansyah Adhi Prayoga¹, Rita Magdalena², Nor Kumalasari Caecar P³

^{1,2,3} Universitas Telkom, Bandung

adhiprayoga@sudent.telkomuniversity.ac.id¹, ritamagdalen@telkomuniversity.ac.id²,
caecarnkcp@telkomuniversity.ac.id³

Abstrak

Keselamatan dalam menggunakan transportasi adalah hal yang sangat penting, begitu juga dengan menggunakan kereta api sebagai moda transportasi massal. Salah satu bagian penting dalam keselamatan perjalanan kereta api adalah kondisi jalur rel kereta api yang baik. Namun, kecelakaan kereta api akibat anjlokkan masih saja terjadi di Indonesia, maka dari itu diperlukan pengawasan prasarana jalur rel kereta api. Hanya saja, pengawasan prasarana jalur rel kereta api masih menggunakan sistem manual. Penelitian Tugas Akhir ini bertujuan untuk membuat suatu sistem yang dapat digunakan untuk mendeteksi dan mengklasifikasikan kerusakan pada jalur rel kereta api dengan menggunakan metode *Convolutional Neural Network* (CNN). Klasifikasi dibagi menjadi 2 kelas, yaitu *defective* dan *non-defective*. Skenario pengujian pada Tugas Akhir ini menggunakan sejumlah 384 citra. Performansi sistem akan diukur dengan menganalisis nilai parameter *resize*, *learning rate*, dan *batch size*, dengan hasil *output* berupa akurasi, presisi, *recall*, *f1-score*. Didapatkan hasil terbaik dengan nilai akurasi 80%, untuk *defective* didapatkan nilai presisi 81%, *recall* 74%, dan *f1-score* 77%, untuk *Non-Defective* didapatkan nilai presisi 80%, *recall* 85%, *f1-score* 83%.

Kata kunci: *Rel Kereta Api, Convolutional Neural Network (CNN), Defective, Non-Defective*

Abstract

Safety in using transportation is very important, as is using trains as a mode of transportation. One of the important parts in the safety of train travel is the condition of a good railroad track. However, train accidents due to derailment still happen in Indonesia, therefore it is necessary to monitor the railway infrastructure. However, the supervision of railroad infrastructure still uses a manual system. This Final Task aims to create a system that can be used to detect and classify damage to railroads using the Convolutional Neural Network (CNN) method. Classification are divided into 2 classes, namely defective and non-defective. The test scenario in this final project uses a number of 384 images. System performance will be measured by analyzing the parameter values of resize, learning rate, and batch size, with the output results of accuracy, precision, recall, f1-score. The best results are obtained with an accuracy value of 80%, for defective the precision value is 81%, recall is 74%, and F1-score is 77%, for Non-Defective the precision value is 80%, recall is 85%, F1-score is 83%.

Keywords: Railroad, Convolutional Neural Network (CNN), Defective, Non-Defective

1. Pendahuluan

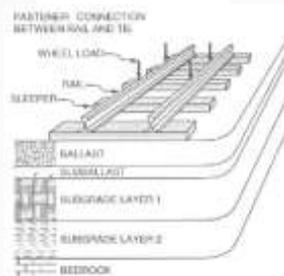
Salah satu moda transportasi massal yang banyak digunakan adalah kereta api. Ada berbagai jenis kereta api yang dirancang untuk tujuan tertentu. Kereta api bisa terdiri dari kombinasi satu atau lebih dari lokomotif dan gerbong kereta terpasang, atau beberapa unit yang digerakan. Umumnya

kereta api yang digunakan di Indonesia adalah kereta api rel konvensional, menggunakan rel yang terdiri dari dua batang baja yang diletakkan di bantalan kayu jati yang keras. Keselamatan dalam menggunakan transportasi adalah hal yang sangat penting, begitu juga dengan menggunakan kereta api sebagai moda transportasi. Menurut “Buku Statistik Bidang Perkeretaapian Tahun 2015-2020” Dalam rentang waktu tahun 2015 sampai dengan tahun 2020 semester awal kecelakaan kereta api akibat anjlok terjadi hingga 149 kecelakaan, angka tersebut harus diwaspadai karena kereta adalah salah satu moda transportasi yang digunakan oleh masyarakat umum. Salah satu bagian penting dalam keselamatan perjalanan kereta api adalah kondisi jalur rel kereta api yang baik. Namun, kecelakaan kereta api akibat anjlok masih saja terjadi di Indonesia, maka dari itu diperlukan pengawasan prasarana jalur rel kereta api. Hanya saja, pengawasan prasarana jalur rel kereta api masih menggunakan sistem manual. Adapun tujuan dan manfaat dari penelitian tugas akhir ini adalah merancang sistem yang dapat mengklasifikasikan jalur rel kereta api kedalam 2 kelas yaitu *defective* dan *non-defective*, menganalisa performansi sebuah sistem dengan metode klasifikasi yang digunakan dengan *Convolutional Neural Network*, dan menganalisa parameter apa saja yang dapat mempengaruhi performansi. Pada penelitian Tugas Akhir ini menggunakan data citra yang diambil dari www.kaggle.com, dimana peneliti menguji beberapa parameter berupa pengaruh *resize*, *learning rate*, dan *batch size* terhadap *output* akurasi, presisi, *recall*, dan *f1-score*.

2. Kereta Api

Kereta api merupakan alat transportasi berupa kendaraan dengan tenaga gerak, baik berjalan sendiri ataupun dirangkaikan dengan kendaraan lainnya, yang bergerak di rel. Kereta api umumnya terdiri dari lokomotif yang dikemudikan oleh seorang masinis dengan bantuan mesin dan rangkaian kereta atau gerbong sebagai tempat pengangkutan barang dan atau penumpang. Perkeretaapian adalah sebuah sistem yang terdiri dari prasarana, sarana, dan sumber daya manusia, serta norma, kriteria, persyaratan, dan prosedur untuk penyelenggaraan transportasi kereta api. Prasarana perkeretaapian adalah jalur kereta api, stasiun kereta api, dan fasilitas operasi kereta api agar kereta api dapat dioperasikan.

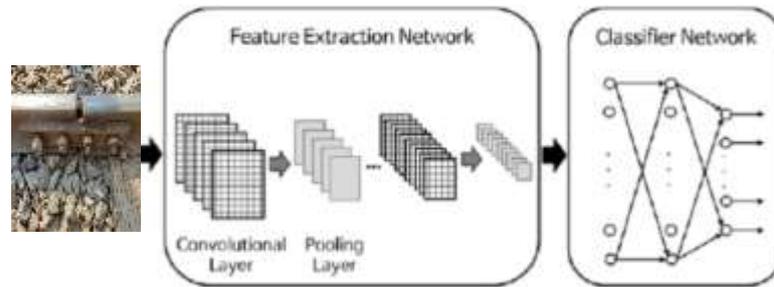
Komponen struktur rel kereta api dibagi menjadi dua bagian yaitu *superstructure* yang terdiri dari rel, penambat, dan bantalan, bagian lainnya yaitu *substructure* yang terdiri atas subbalas, balas, tanah dasar.



Gambar 1. Komponen Struktur Rel

3. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan jaringan *deep neural network* yang dikhususkan untuk mengolah struktur dua dimensi seperti gambar. Teknik ini bisa menunjukkan peningkatan yang sangat signifikan pada *deep layers* untuk memberi informasi pada *image processing*. Sebenarnya, CNN adalah teknik lama yang dikembangkan pada 1980-an dan 1990-an. Namun, teknik ini telah dilupakan untuk sementara waktu, karena tidak praktis untuk pengaplikasian di dunia nyata dengan gambar yang rumit. Sejak 2012 ketika dihidupkan kembali, CNN telah memberikan dampak besar di bidang *computer vision* dan berkembang dengan pesat.

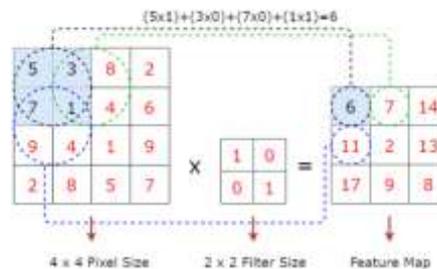


Gambar 2. Arsitektur CNN secara umum.

Arsitektur CNN sama seperti jaringan saraf pada umumnya, CNN terdiri dari *neuron* yang memiliki fungsi bobot, bias, dan aktivasi. CNN dibagi menjadi fitur ekstraksi dan klasifikasi. Pada bagian fitur ekstraksi terdapat tiga tahapan yaitu *convolutional layer*, aktivasi *Rectified Linear Unit (ReLU)* dan *pooling*. Bagian klasifikasi juga memiliki dua tahapan operasi, yaitu *Fully Connected Layer* dan fungsi aktivasi.

3.1 Convolutional Layer

Convolution layer merupakan komponen yang sangat penting dari arsitektur CNN, bagian ini yang melakukan fitur ekstraksi, yang biasanya terdiri dari kombinasi operasi linier dan nonlinier seperti pada operasi konvolusi dan fungsi aktivasi. Bentuk layer ini adalah sebuah filter dengan Panjang (piksel), tinggi (piksel), dan tebal sesuai dengan data input *channel image*. Dari ketiga filter ini akan bergeser keseluruhan bagian gambar dan melakukan operasi “dot” antar input dan nilai dari filter tersebut sehingga dapat menghasilkan output yang disebut sebagai *activatin map* atau *feature map*, seperti yang ditunjukkan pada gambar 2.



Gambar 3. Ilustrasi Proses Konvolusi.

3.2 Rectified Linear Units (ReLU)

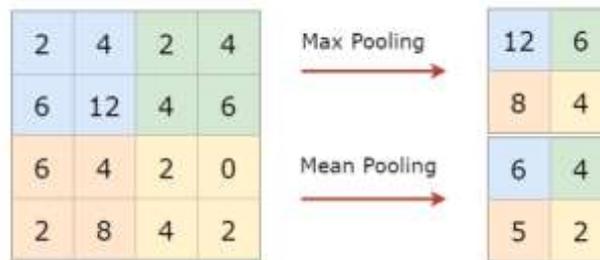
Rectified Linear Units (ReLU) merupakan lapisan aktivasi pada CNN yang menggunakan fungsi seperti yang ditunjukkan pada persamaan (2.1). ReLU digunakan untuk meningkatkan tahap pelatihan pada jaringan saraf tiruan yang memiliki kelebihan bisa melatih jaringan saraf berkali-kali lebih cepat. Selain itu untuk meningkatkan kinerja jaringan, fungsi aktivasi *Sigmoid* digunakan di akhir pada lapisan terakhir.

$$f(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (1)$$

3.3 Pooling Layer

Pooling layer merupakan layer yang menerima output dari *convolutional layer*, dimana ukuran sebuah data citra akan direduksi. Keuntungan *pooling layer* yang secara progresif dapat mengurangi ukuran *volume output* dan *feature map* sehingga bisa mengendalikan *Overfitting*. Metode *pooling* menggunakan *max pooling* atau *mean pooling*, dimana Sebagian besar arsitektur CNN menggunakan *max pooling*. *Max pooling* membagi *output* dari *convolutional layer* menjadi beberapa grid, selanjutnya setiap pergeseran *filter* akan mengambil nilai terbesar dari setiap grid.

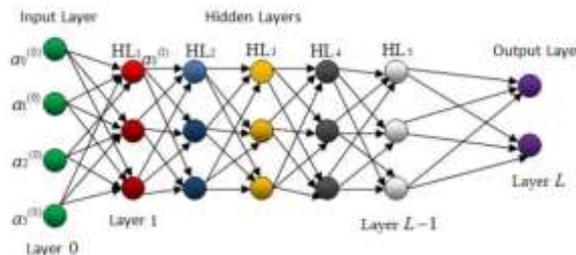
Gambar yang dihasilkan akan sesuai dengan panjang langkah yang dilakukan dimana sebagian kecil dari ukuran aslinya dapat berguna untuk mengurangi sebuah dimensi data, sehingga mengurangi jumlah parameter pada langkah selanjutnya. Gambar 3 menampilkan proses yang ada pada *pooling layer*.



Gambar 4. Ilustrasi Proses *Pooling*

3.4 Fully Connected Layer

Fully connected layer merupakan layer terakhir dari proses konvolusi atau *pooling* yang diratakan menjadi *feature map* kemudian layer akan ditransformasikan menjadi deretan angka (*vector*) atau satu dimensi untuk memudahkan proses klasifikasi. Setelah fitur diekstraksi oleh lapisan konvolusi dan di *downsampled* oleh *pooling layer* telah dibuat, maka akan dipetakan oleh bagian dari *fully connected layer* ke keluaran akhir jaringan, seperti probabilitas untuk setiap kelas dalam tugas klasifikasi. Layer terakhir *fully connected layer* biasanya memiliki jumlah *node* keluaran yang sama dengan jumlah kelas. Setiap lapisan *fully connected layer* diikuti oleh fungsi nonlinier, seperti ReL-U. Gambar 4 menampilkan proses yang ada dalam *fully connected layer*.



Gambar 5. Proses *Fully Connected Layer*.

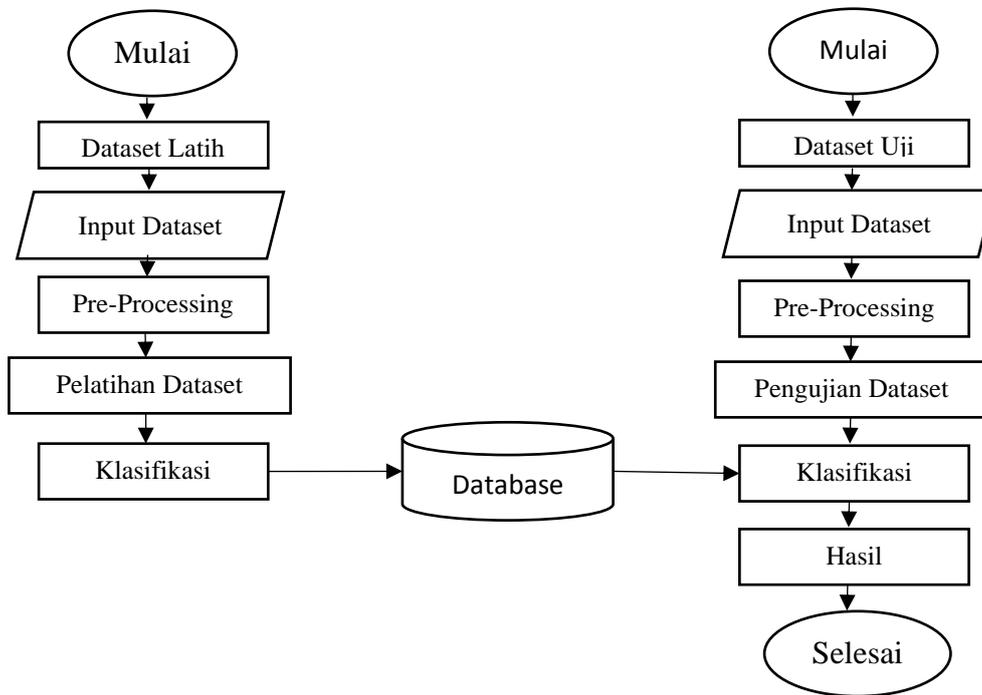
3.5 Aktivasi Sigmoid

Sigmoid merupakan proses terakhir yang digunakan untuk mendapatkan hasil keluaran dari CNN. Persamaan *Sigmoid* bisa dilihat pada persamaan (1).

$$S(x) = \frac{1}{1 + e^{-x}} \tag{2}$$

4. Desain Sistem

Pada gambar 5 merupakan gambaran diagram alir sistem yang akan digunakan pada penelitian ini untuk proses klasifikasi *defective* dan *non-defective* pada jalur rel kereta api.



Gambar 6. Diagram Alir Sistem

Pada penelitian ini data input diperoleh dari *www.kaggle.com* berupa data citra sebanyak 384 citra terbagi menjadi 2 yaitu untuk *defective* sebanyak 192 citra dan *non-defective* sebanyak 192 citra. Data citra akan diuji dengan nilai *resize 16*, *resize 32*, *resize 64*, *resize 128*. Tahap selanjutnya *learning rate* yang akan diuji nilai *learning rate 0.1*, *learning rate 0.01*, *learning rate 0.001*, *learning rate 0.0001*. Tahap selanjutnya *batch size* yang akan diuji nilai *batch size 16*, *batch size 32*, *batch size 64*, *batch size 128*. Dari hasil uji tersebut akan menghasilkan *output* akurasi, presisi, *recall*, *f1-score*.

Tabel 1. Detail Model CNN yang diajukan

Tipe Layer	Output Shape	Parameter
Convolution	32, 32, 16	448
ReLU	32, 32, 16	0
Max Pooling	16, 16, 16	0
Convolution	16, 16, 32	4640
ReLU	16, 16, 32	0
Max Pooling	8, 8, 32	0
Convolution	8, 8, 64	18496
ReLU	8, 8, 64	0
Max Pooling	4, 4, 64	0
Convolution	4, 4, 128	73856
ReLU	4, 4, 128	0
Max Pooling	2, 2, 128	0
Dropout	2, 2, 128	0
Flatten	512	0
Dense	2	1026
Activation	2	0

5. Performansi Sistem

Setelah semua tahap pengujian telah dilakukan, maka tahap selanjutnya yang akan dilakukan yaitu performansi sistem yang memiliki lima parameter yang dapat menentukannya, yaitu *confusion matrix*, akurasi, presisi, *recall*, dan *f1-score*.

Tabel 2 Proses *Confusion Matrix*

		Akurasi	
		<i>Defective</i>	<i>Non-Defective</i>
Prediksi	<i>Defective</i>	TP	FP
	<i>Non-Defective</i>	FN	TN

Keterangan :

- TP (*True Positive*) adalah data positif yang di prediksi benar (positif)
- TN (*True Negative*) adalah data negative yang di prediksi benar (negatif)
- FP (*False Positive*) adalah data negatif namun di prediksi sebagai data positif
- FN (*False Negative*) adalah data positif namun di prediksi sebagai data negatif

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

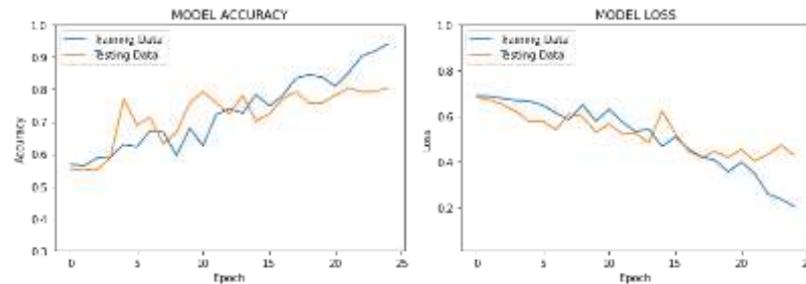
$$\text{Recall} = \frac{TP}{TP + FN}$$

$$\text{Presisi} = \frac{TP}{TP + FP}$$

$$f1 - \text{score} = 2 \times \frac{\text{Recall} \times \text{Presisi}}{\text{Recall} + \text{Presisi}}$$

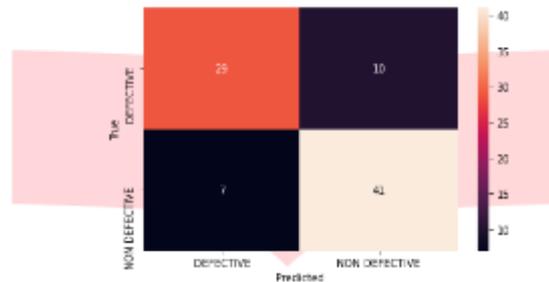
6. Hasil dan Diskusi

Pada penelitian ini akan membahas mengenai pengujian hasil dan analisis dari identifikasi kecacatan pada jalur rel kereta api untuk kondisi *defective* dan *non-defective* menggunakan metode *convolutional neural network*. Data citra yang digunakan sebanyak 384 citra terbagi menjadi 2 yaitu untuk *defective* sebanyak 192 citra dan *non-defective* sebanyak 192 citra. Hasil dari pengujian penelitian ini berupa akurasi, presisi, *recall*, *f1-score*. Terdapat tiga pengujian yang dilakukan pada tahap pengujian yaitu *resize*, *learning rate*, *batch size* terbaik. Pada penelitian ini digunakan nilai pengujian yang terbaik yaitu nilai *resize* 32, *learning rate* 0.01, *batch size* 16. Hasilnya mendapatkan nilai akurasi 80%, presisi *defective* 81%, presisi *non-defective* 80%, *recall defective* 74%, *recall non-defective* 85%, *f1-score defective* 77%, *f1-score non-defective* 83%.



Gambar 7. Hasil pengujian dengan parameter terbaik

Model *confusion matrix* yang didapat dari parameter terbaik di pengujian dapat dilihat pada gambar 7.



Gambar 8. *Confusion Matrix* model terbaik

7. Kesimpulan

Berdasarkan penelitian yang dilakukan terhadap Identifikasi Kecacatan Pada Jalur Rel Kereta Api Berbasis Pengolahan Citra Menggunakan *Convolutional Neural Network* disimpulkan bahwa mampu mengklasifikasi berdasarkan kelas *defective* dan *non-defective*. Pengujian metode CNN dalam mengklasifikasi menggunakan citra dengan mengubah parameter *resize*, *learning rate*, dan *batch size* sangat mempengaruhi tingkat akurasi, presisi, *recall*, *f1-score*. Parameter terbaik yang digunakan adalah *resize* 32, *learning rate* 0.001, *batch size* 16. Hasil pengujian terbaik mendapatkan nilai akurasi 80%, presisi *defective* 81%, presisi *non-defective* 80%, *recall defective* 74%, *recall non-defective* 85%, *f1-score defective* 77%, *f1-score non-defective* 83%.

Referensi

- [1] Buku Statistik Bidang Perkeretaapian, 2019.
- [2] Ashish James, Wang Jie, Yang Xulei, Ye Chenghao, Nguyen Bao Ngan, Lou Yuxin, Su Yi, Vijay Chandrasekhar, and Zeng Zeng, "TrackNet – A Deep Learning Based Fault Detection for Railway Track Inspection", IEEE. 2018.
- [3] Peraturan Menteri Perhubungan Republik Indonesia Nomor PM 60 Tahun 2020 Tentang Pengawasan Prasarana dan Sarana Perkeretaapian Berbasis Teknologi Informasi.
- [4] Admin. (2013, Februari 2014). *Komponen Penyusun Rel Kereta Api*. Retrieved From <https://www.ilmuteknisipil.com/teknik-lalu-lintas/komponen-penyusun-rel-kereta-api>.
- [5] PJKA. 1986. Perencanaan Konstruksi Jalan Rel (Peraturan Dinas No.10).
- [6] U. O. Tartu, "Digital Image Processing" University of Tartu [Online]. Available: <https://sisu.ut.ee/imageprocessing/book/1>. [Diakses 25 Februari 2021].
- [7] P. N. Andono, T.Sutojo and Muljono, "Representasi Citra Digital", dalam Pengolahan Citra Digital, Semarang, Andi, 2017, p. 2.
- [8] N. Nafi'iyah and S. Mujilawati, "Format Citra", dalam Buku Ajar Citra Binarisasi Dan Enhancement, Yogyakarta, Deepublish, Deepublish, p. 13.
- [9] A. Kadir and A. Susanto, Pengolahan Citra., Yogyakarta: ANDI, 2012.
- [10] Y. Heryadi and E. Irwansyah, Deep learning : Aplikasinya di Bidang Geospasial, Depok: AWI Technology Press, 2020.

- [11] M. Miftahul Huda, *Algoritma Data Mining: Analisis Data Dengan Komputer*, bisakimia,
- [12] P. Kim, *MATLAB Deep Learning With Machine Learning Neural Networks and Artificial Intelligence*, apress, 2017.
- [13] Y. N. Fu'adah and I. Wijiyanto, "Automated Classification of Alzheimer's Disease Based on MRI Image Processing using Convolutional Neural Network (CNN) with AlexNet Architecture", 2020.
- [14] S. Sakib and N. Ahmed, "An Overview of Convolutional Neural Network: Its Architecture and Applications", IEEE, 2018.
- [15] R. Yamashita and M. Nishio, "Convolutional Neural Network: An Overview and Application in Radiology", Springer, 2018.
- [16] R. D. Nurfitra and G. Ariyanto, "Implementasi Deep Learning Berbasis Tensorflow untuk pengenalan sidik jari", *J. Emit* vol 18, no.1, pp 22-27, 2018.
- [17] R. B. Arif and A. B. Siddique, "Study and Observation of the Variations of Accuracies for Handwritten Digits Recognition with Various Hidden Layers and Epochs using Convolutional Neural Network", IEEE, pp. 112-117, 2018.
- [18] Y. N. Fu'adah and S. Sa'idah, "Computer Aided Diagnosis for Early Detection of Glaucoma using Convolutional Neural Network (CNN)", 2020.
- [19] Santra, A. K. and Christy, C. J. (2012). Genetic Algorithm and Confusion Matrix for Document Clustering, *International Journal of Computer Science Issues*, 9(1), 322-328
- [20] T. de Bruin, K. Verbert, and R. Babuska, "Railway Track Circuit Fault Diagnosis Using Recurrent Neural Network", IEEE. 2016.
- [21] Welankiwar, A., Sherekar, S., Bhagat, A. P., & Khodke, P. A. (2018). Fault Detection in Railway Tracks Using Artificial Neural Networks. 2018 International Conference on Research in Intelligent and Computing in Engineering (RICE).

