

## **Deteksi Kerusakan Jalur Rel Kereta Api Menggunakan CLAHE-KNN (CLAHE K–Nearest Neighbour)**

**<sup>1</sup>Handrie Noprisson, <sup>2</sup>Vina Ayumi**

Fakultas Ilmu Komputer, Universitas Mercu Buana, Indonesia

<sup>1</sup>*handrie.noprisson@mercubuana.ac.id*, <sup>2</sup>*vina.ayumi@mercubuana.ac.id*

---

### **Article Info**

#### **Article history:**

Received, 2023-06-20

Revised, 2023-06-26

Accepted, 2023-06-30

---

#### **Kata Kunci:**

*CLAHE*

*KNN*

*Rel kereta api*

---

### **ABSTRAK**

Penelitian ini merupakan bagian dari pengembangan sistem tersebut yang bertujuan untuk deteksi kerusakan jalur rel kereta api dengan menggunakan model CLAHE-KNN. Penelitian ini bertujuan untuk deteksi kerusakan jalur rel kereta api dengan menggunakan metode CLAHE-K-NN dan mengetahui pengaruh CLAHE pada algoritma K–Nearest Neighbour untuk deteksi kerusakan rel kereta api. CLAHE didefinisikan oleh dua parameter: Block Size (BS) dan Clip Limit (CL). Dataset yang digunakan dalam penelitian ini adalah citra rel kereta api yang berjumlah 384 data. Berdasarkan hasil eksperimen menggunakan metode KNN, metode ini mendapatkan akurasi sebesar 65.62%. Selain itu, hasil eksperimen menggunakan KNN dengan optimasi CLAHE mendapatkan akurasi yang lebih baik dengan menggunakan clipLimit = 4.0 dan tileSize = (4,8) yaitu sebesar 66.67%.

---

### **ABSTRACT**

#### **Keywords:**

*CLAHE*

*KNN*

*Railroads*

This research is part of the development of the system, which aims to detect damage to railway tracks using the CLAHE-KNN model. This study aims to detect railway damage using the CLAHE-K-NN method and determine the effect of CLAHE on the K-Nearest Neighbor algorithm for railway damage detection. CLAHE is defined by Block Size (BS) and Clip Limit (CL). The dataset used in this study was railway imagery totaling 384 data. Based on the KNN method's experimental results, this method obtained an accuracy of 65.62%. In addition, the experimental results using KNN with CLAHE optimization get better accuracy by using clipLimit = 4.0 and tileSize = (4,8), which is 66.67%.

*This is an open access article under the CC BY-SA license.*



#### **Penulis Korespondensi:**

Handrie Noprisson

Fakultas Ilmu Komputer

Universitas Mercu Buana, Indonesia

Email: *handrie.noprisson@mercubuana.ac.id*

---

## **1. PENDAHULUAN**

Penelitian mengenai deteksi kerusakan pada jalur kereta api atau *railway track fault detection* sudah dimulai untuk mendukung hasil dari peran visual manusia secara manual untuk memantau kerusakan jalur kereta api. Pemantauan secara manual oleh manusia terkadang terdapat ketidaktelitian dan kesalahan yang akan mengakibatkan kerusakan pada jalur kereta api tidak terdeteksi dengan baik [1]–[3].

Deteksi manual oleh manusia atau staf operasional kereta api dilakukan dengan cara patroli atau menyisir jalur kereta api dengan kendaraan atau berjalan kaki. Deteksi ini minimal dilakukan oleh tim yang terdiri dari dua orang dengan tugas masing-masing. Staff pertama bertugas untuk memantau dan mendekteksi kemungkinan kerusakan pada lintasan kereta api dan lainnya bertugas untuk memantau pesan keluar dan masuk dari pusat operasional [4]–[9].

Meskipun telah dilakukan dengan standar operasional yang sesuai, namun terkadang kemampuan visual manusia terbatas dan pada waktu tertentu tidak dapat melihat atau memantau kerusakan jalur kereta api secara

akurat. Untuk memvalidasi hasil dari pemantauan kerusakan jalur kereta api dengan manual, perlu adanya data pendukung dengan bantuan teknologi sebagai data pelengkap [10]. Untuk memastikan keamanan transportasi kereta api, beberapa riset telah dilakukan untuk mengembangkan sistem kereta api terintegrasi. Melalui model pembelajaran berbasis kecerdasan buatan, sistem ini mencoba mendeteksi wilayah rel kereta api yang akan diamati [11]–[21][22]–[24].

Penelitian ini merupakan bagian dari pengembangan sistem tersebut yang bertujuan untuk deteksi kerusakan jalur rel kereta api dengan menggunakan model CLAHE-KNN. Dalam penelitian ini, model K-Nearest Neighbour dioptimasi dengan menggunakan CLAHE agar sebelum diproses K-Nearest Neighbour citra yang hasil dapat lebih baik dalam menampilkan fitur untuk deteksi kerusakan jalur rel kereta api.

Dalam penelitian oleh [25] menggunakan deskriptor Histogram of Oriented Gradients (HOG) untuk mendeteksi fasteners pada rel kereta api. Meskipun hasil yang kami peroleh menggunakan fitur HOG lebih baik daripada metode yang diusulkan sebelumnya, pendekatan ini masih memiliki keterbatasan. Misalnya, dimensi vektor fitur sangat besar (12.996), menghabiskan banyak memori dan sumber daya komputasi, dan pengklasifikasi linier tidak dapat menangani oklusi dengan sangat baik.

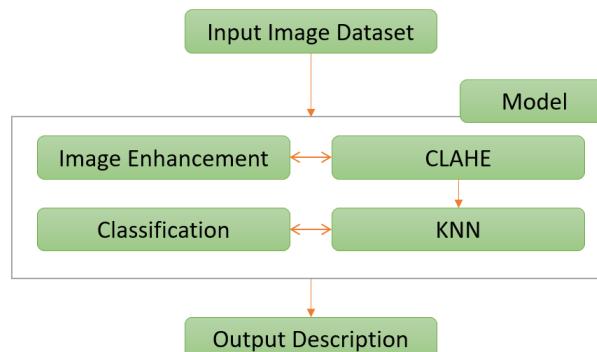
Penelitian oleh [26] menggunakan format RGB dikonversi ke ruang warna abu-abu kemudian diterapkan algoritma ekstraksi tepi Canny. Setelah proses deteksi tepi, berbagai operasi morfologis diterapkan. Tujuan dari proses ini adalah untuk mengukur jarak antara rel sehingga jarak antara profil rel yang ditandai sebagai piksel gambar biner putih dan nilai piksel ditentukan di setiap bingkai gambar yang akan diperiksa sesuai dengan ambang batas yang ditentukan. Sebagai contoh pada data jalur kereta api utama dapat dikatakan tidak ada masalah namun rel tetangga memiliki masalah kontraksi. Jarak antara dua rel biasanya 1435 mm. Namun, nilai ini dihitung sebagai 1402 mm di rel tetangga. Kesalahan pitch dapat menyebabkan keausan rel dan tergelincirnya kereta.

Penelitian oleh [10] menggunakan model neural network You Only Look Once (Yolo) untuk deteksi objek atau cacat karena efisiensinya yang tinggi. Namun, pembelajaran jaringan saraf membutuhkan sejumlah besar sampel. Jumlah sampel menentukan generalisasi dan akurasi model *neural network*. Ada kebutuhan untuk data pelatihan sebanyak mungkin untuk sampel normal dan salah. Penelitian ini menggunakan 16.677 objek untuk pelatihan dan 3.294 objek sebagai set uji. Matriks *confusion* dari model Yolo yang dibuat menunjukkan bahwa true positive (TP) adalah 3.114, false negative (FP) adalah 378, dan false negative (FN) adalah 180. Oleh karena itu, penelitian memperoleh presisi 89%, recall rate 95%, mean average precision (mAP) 84,08%, dan intersection over union (IoU) 73,4%.

Penelitian ini bertujuan untuk deteksi kerusakan jalur rel kereta api dengan menggunakan model CLAHE-KNN. Dalam penelitian ini, model K-Nearest Neighbour dioptimasi dengan menggunakan CLAHE agar sebelum diproses K-Nearest Neighbour, citra yang hasil dapat lebih baik dalam menampilkan fitur untuk deteksi kerusakan jalur rel kereta api.

## 2. METODE PENELITIAN

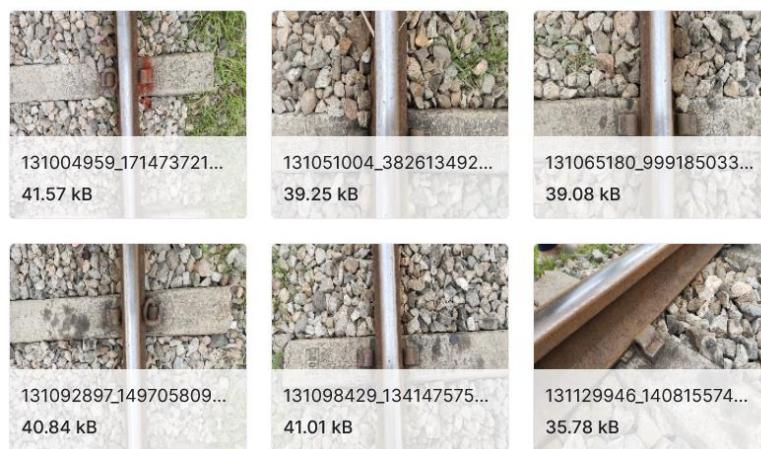
Penelitian ini bertujuan untuk mengetahui kinerja deteksi kerusakan rel kereta api dengan menggunakan algoritma K-Nearest Neighbour dan pengaruh CLAHE pada algoritma K-Nearest Neighbour untuk deteksi kerusakan rel kereta. Penelitian ini mengasumsikan bahwa jalur kereta api yang dideteksi berupa objek berada di lingkungan dengan cahaya rendah. Metode yang diusulkan dalam penelitian ini dapat dilihat pada **Gambar 1**.



Gambar 1 Metodologi Riset

Beberapa penelitian telah menunjukkan bahwa kinerja metode klasifikasi dipengaruhi oleh data, fitur, dan metode klasifikasi. Kinerja metode klasifikasi menunjukkan bahwa fitur warna, bentuk, dan tekstur tidak selalu menyebabkan akurasi yang buruk. Fitur-fitur ini dapat digunakan untuk menampilkan detail gambar secara

tepat berdasarkan fungsi yang ada. Namun, fitur ini dipengaruhi oleh sumber data. Untuk mengatasi masalah ini, penelitian ini menggunakan metode peningkatan kualitas gambar CLAHE diimplementasikan berdasarkan algoritma K-Nearest Neighbour. Adapun contoh dataset yang digunakan dapat dilihat pada **Gambar 2**.



Gambar 2 Contoh Dataset

### 3. HASIL DAN ANALISIS

Manfaat penelitian adalah memberikan kontribusi penelitian pada topik *image processing*, namun dengan cara menggabungkan pemodelan K-Nearest Neighbour (KNN) dioptimasi dengan menggunakan CLAHE. Penelitian ini adalah penelitian awal sebagai *pilot study* pengembangan aplikasi monitoring jarak jauh untuk mengetahui kerusakan rel kereta api. Secara spesifik pembahasan pada riset selanjutnya akan difokuskan pada kondisi masyarakat, fasilitas dan teknologi yang digunakan.

CLAHE didefinisikan oleh dua parameter: *Block Size* (BS) dan *Clip Limit* (CL). Kedua parameter ini terutama mengatur kualitas gambar yang lebih baik. Ketika CL ditingkatkan, gambar menjadi lebih cerah karena gambar input memiliki intensitas yang sangat rendah dan CL yang lebih besar membuat histogramnya lebih rata. Saat BS meningkat, rentang dinamis mengembang, dan kontras gambar meningkat. Kedua parameter yang ditentukan pada titik kelengkungan entropi maksimum menghasilkan kualitas gambar yang baik secara subjektif saat menggunakan entropi gambar. Ada dua parameter yang diatur dalam menggunakan CLAHE yaitu *clipLimit* dan *tileGridSize*. Parameter *clipLimit* mengontrol threshold untuk nilai kontras. Pengaturan default adalah 4.0. Parameter *tileGridSize* digunakan untuk menentukan jumlah kotak di setiap baris dan kolom. Ini diatur ke 8,8 secara default. Parameter ini diterapkan saat gambar dibagi menjadi kotak untuk CLAHE. Adapun hasil eksperimen penelitian dapat dilihat pada **Tabel 1**.

Tabel 1 Hasil Eksperimen Penelitian

No	Metode Eksperimen	Parameter	Hasil
1	KNN	-	65.62%
2	CLAHE+KNN	clipLimit =2.0, tileGridSize=(8,8)	62.50%
3	CLAHE+KNN	clipLimit =2.0, tileGridSize=(4,4)	65.62%
4	CLAHE+KNN	clipLimit =4.0, tileGridSize=(8,8)	62.50%
5	CLAHE+KNN	clipLimit =4.0, tileGridSize=(4,8)	66.67%

Pada eksperimen pertama, metode yang digunakan adalah KNN. Dataset yang digunakan berjumlah 384 data. Akurasi yang didapatkan dari metode KNN untuk deteksi kerusakan rel kereta api sebesar 65.62%. Adapun hasil lengkap dari eksperimen pertama dapat dilihat pada **Gambar 3**.

	precision	recall	f1-score	support
Defective	0.70	0.69	0.69	54
Non defective	0.60	0.62	0.61	42
accuracy			0.66	96
macro avg	0.65	0.65	0.65	96
weighted avg	0.66	0.66	0.66	96

Gambar 3 Eksperimen Menggunakan KNN

Pada eksperimen kedua, metode yang digunakan adalah KNN dan CLAHE. Parameter CLAHE yang digunakan adalah clipLimit =2.0 dan tileSize = (8,8). Dataset yang digunakan berjumlah 384 data. Akurasi yang didapatkan dari metode KNN dan CLAHE deteksi kerusakan rel kereta api sebesar 62.50%. Adapun hasil lengkap dari eksperimen pertama dapat dilihat pada **Gambar 4**.

	precision	recall	f1-score	support
Defective	0.63	0.80	0.70	54
Non defective	0.61	0.40	0.49	42
accuracy			0.62	96
macro avg	0.62	0.60	0.60	96
weighted avg	0.62	0.62	0.61	96

Gambar 4 Eksperimen Menggunakan KNN dan CLAHE dengan clipLimit =2.0 dan tileSize=(8,8)

Pada eksperimen kedua, metode yang digunakan adalah KNN dan CLAHE. Parameter CLAHE yang digunakan adalah clipLimit =2.0 dan tileSize = (4,4). Dataset yang digunakan berjumlah 384 data. Akurasi yang didapatkan dari metode KNN dan CLAHE deteksi kerusakan rel kereta api sebesar 65.62%. Adapun hasil lengkap dari eksperimen pertama dapat dilihat pada **Gambar 5**.

	precision	recall	f1-score	support
Defective	0.67	0.78	0.72	54
Non defective	0.64	0.50	0.56	42
accuracy			0.66	96
macro avg	0.65	0.64	0.64	96
weighted avg	0.65	0.66	0.65	96

Gambar 5 Eksperimen Menggunakan KNN dan CLAHE dengan clipLimit =2.0 dan tileSize=(4,4)

Pada eksperimen ketiga, metode yang digunakan adalah KNN dan CLAHE. Parameter CLAHE yang digunakan adalah clipLimit =4.0 dan tileSize = (8,8). Dataset yang digunakan berjumlah 384 data. Akurasi yang didapatkan dari metode KNN dan CLAHE deteksi kerusakan rel kereta api sebesar 62.50%. Adapun hasil lengkap dari eksperimen pertama dapat dilihat pada Gambar 6.

	precision	recall	f1-score	support
Defective	0.61	0.94	0.74	54
Non defective	0.75	0.21	0.33	42
accuracy			0.62	96
macro avg	0.68	0.58	0.54	96
weighted avg	0.67	0.62	0.56	96

Gambar 6 Eksperimen Menggunakan KNN dan CLAHE dengan clipLimit =4.0 dan tileSize=(8,8)

Pada eksperimen keempat, metode yang digunakan adalah KNN dan CLAHE. Parameter CLAHE yang digunakan adalah clipLimit =4.0 dan tileSize = (4,8). Dataset yang digunakan berjumlah 384 data. Akurasi yang didapatkan dari metode KNN dan CLAHE deteksi kerusakan rel kereta api sebesar 66.67%. Adapun hasil lengkap dari eksperimen pertama dapat dilihat pada **Gambar 7**.

	precision	recall	f1-score	support
Defective	0.63	0.96	0.76	54
Non defective	0.86	0.29	0.43	42
accuracy			0.67	96
macro avg	0.75	0.62	0.60	96
weighted avg	0.73	0.67	0.62	96

Gambar 7 Eksperimen Menggunakan KNN dan CLAHE dengan clipLimit =4.0 dan tileSize=(4,8)

#### 4. KESIMPULAN

Penelitian ini bertujuan untuk deteksi kerusakan jalur rel kereta api dengan menggunakan metode CLAHE-K-NN dan mengetahui pengaruh CLAHE pada algoritma K-Nearest Neighbour untuk deteksi kerusakan rel kereta api. CLAHE didefinisikan oleh dua parameter: *Block Size* (BS) dan *Clip Limit* (CL). Berdasarkan hasil eksperimen menggunakan metode KNN pada dataset berjumlah 384 data, metode KNN mendapatkan akurasi sebesar 65.62%. Selain itu, hasil eksperimen menggunakan KNN dengan optimasi CLAHE mendapatkan akurasi yang lebih baik dengan menggunakan clipLimit =4.0 dan tileSize=(4,8) yaitu sebesar 66.67%.

#### UCAPAN TERIMA KASIH

Terima kasih kepada Biro Penelitian, Pengabdian Masyarakat & Publikasi, Universitas Mercu Buana yang telah mendanai penelitian ini melalui skema Penelitian Internal Dosen Muda.

#### REFERENSI

- [1] A. Zaman, X. Liu, and Z. Zhang, “Video analytics for railroad safety research: an artificial intelligence approach,” *Transp. Res. Rec.*, vol. 2672, no. 10, pp. 269–277, 2018.
- [2] R. S. Ramapriya, R. Suganya, S. Nathan, and P. S. Perumal, “A Comparative Assessment of Deep Neural Network Models for Detecting Obstacles in the Real Time Aerial Railway Track Images,” *Appl. Artif. Intell.*, pp. 1–33, 2022.
- [3] M. Chenariyan Nakhaei, D. Hiemstra, M. Stoelinga, and M. van Noort, “The recent applications of machine learning in rail track maintenance: A survey,” in *International Conference on Reliability, Safety, and Security of Railway Systems*, 2019, pp. 91–105.
- [4] A. Naweed, J. Dorrian, and J. Rose, *Evaluation of Rail Technology: A practical human factors guide*. CRC Press, 2017.
- [5] F. Marino, A. Distante, P. L. Mazzeo, and E. Stella, “A real-time visual inspection system for railway maintenance: automatic hexagonal-headed bolts detection,” *IEEE Trans. Syst. Man, Cybern. Part C (Applications Rev.)*, vol. 37, no. 3, pp. 418–428, 2007.
- [6] M. Yilmazer, M. Karakose, and I. Aydin, “Determination of Railway Track Gauge with Image Processing,” in *2021 International Conference on Data Analytics for Business and Industry (ICDABI)*, 2021, pp. 510–514.
- [7] C. Bragança, E. F. Souza, D. Ribeiro, A. Meixedo, T. N. Bittencourt, and H. Carvalho, “Drive-by Methodologies Applied to Railway Infrastructure Subsystems: A Literature Review—Part II: Track and Vehicle,” *Appl. Sci.*, vol. 13, no. 12, p. 6982, 2023.
- [8] C. Du, S. Dutta, P. Kurup, T. Yu, and X. Wang, “A review of railway infrastructure monitoring using fiber optic sensors,” *Sensors Actuators A Phys.*, vol. 303, p. 111728, 2020.
- [9] M. O. Adeagbo, H.-F. Lam, and Y. Q. Ni, “A Bayesian methodology for detection of railway ballast damage using the modified Ludwik nonlinear model,” *Eng. Struct.*, vol. 236, p. 112047, 2021.
- [10] Y.-W. Lin, C.-C. Hsieh, W.-H. Huang, S.-L. Hsieh, and W.-H. Hung, “Railway Track Fasteners Fault Detection using Deep Learning,” in *2019 IEEE Eurasia Conference on IOT, Communication and Engineering (ECICE)*, 2019, pp. 187–190.
- [11] H. Noprisson, “Earthquake Early Warning (EEW) System: System Architecture, Data Modelling, and User Interface Design,” *Int. J. Sci. Res. Comput. Sci. Eng. Inf. Technol.*, pp. 650–657, Jun. 2021.
- [12] H. Noprisson, “Fine-Tuning Model Transfer Learning VGG16 Untuk Klasifikasi Citra Penyakit Tanaman Padi,” *JSAI (Journal Sci. Appl. Informatics)*, vol. 5, no. 3, pp. 244–249, 2022.
- [13] A. A. Shah, B. S. Chowdhry, T. D. Memon, I. H. Kalwar, and A. Ware, “Real time identification of railway track surface faults using canny edge detector and 2D discrete wavelet transform,” *Ann. Emerg. Technol. Comput.*, vol. 4, no. 2, 2020.
- [14] V. Ayumi, E. Ermatita, A. Abdiansah, H. Noprisson, M. Purba, and M. Utami, “A Study on Medicinal Plant Leaf Recognition Using Artificial Intelligence,” in *2021 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 2021, pp. 40–45.
- [15] V. Ayumi, “Performance Evaluation of Support Vector Machine Algorithm for Human Gesture Recognition,” *Int. J. Sci. Res. Sci. Eng. Technol.*, vol. 7, no. 6, pp. 204–210, 2020.
- [16] I. Nurhaida *et al.*, “Implementation of Deep Learning Predictor (LSTM) Algorithm for Human Mobility Prediction,” *Int. J. Interact. Mob. Technol.*, vol. 14, no. 18, p. 132, Nov. 2020.
- [17] V. Ayumi *et al.*, “Transfer Learning for Medicinal Plant Leaves Recognition: A Comparison with and without a Fine-Tuning Strategy,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 9, 2022.
- [18] J. Lu *et al.*, “SCueU-Net: Efficient damage detection method for railway rail,” *IEEE Access*, vol. 8,

- pp. 125109–125120, 2020.
- [19] Y. B. Yang, Z. L. Wang, K. Shi, H. Xu, X. Q. Mo, and Y. T. Wu, “Two-axle test vehicle for damage detection for railway tracks modeled as simply supported beams with elastic foundation,” *Eng. Struct.*, vol. 219, p. 110908, 2020.
- [20] A. Ghiasi, C.-T. Ng, and A. H. Sheikh, “Damage detection of in-service steel railway bridges using a fine k-nearest neighbor machine learning classifier,” in *Structures*, 2022, vol. 45, pp. 1920–1935.
- [21] M. Chen, W. Zhai, S. Zhu, L. Xu, and Y. Sun, “Vibration-based damage detection of rail fastener using fully convolutional networks,” *Veh. Syst. Dyn.*, vol. 60, no. 7, pp. 2191–2210, 2022.
- [22] M. Sadikin, R. Yusuf, and D. Arif Rifai, “Load balancing clustering on moodle LMS to overcome performance issue of e-learning system,” *Telkomnika (Telecommunication Comput. Electron. Control.)*, vol. 17, no. 1, pp. 131–138, 2019.
- [23] M. Sadikin and I. Wasito, “A novel rule based approach for entity relations extraction,” *J. Theor. Appl. Inf. Technol.*, vol. 74, no. 2, pp. 249–261, 2015.
- [24] H. Noprisson, “Analysis and Design e-Government Website for Special Allocation Fund,” *Int. J. Comput. Sci. Eng.*, vol. 8, no. 02, 2019.
- [25] N. Dalal and B. Triggs, “Histograms of oriented gradients for human detection,” in *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)*, 2005, vol. 1, pp. 886–893.
- [26] M. Karakose, O. Yaman, M. Baygin, K. Murat, and E. Akin, “A new computer vision based method for rail track detection and fault diagnosis in railways,” *Int. J. Mech. Eng. Robot. Res.*, vol. 6, no. 1, pp. 17–22, 2017.