


CLAHE-Enhanced YOLOv8: Deteksi Pelanggaran Helm Real-Time pada Citra CCTV Low-Light

Devin Nurman Wijaya^{1*}, Dedy Ariyanto², Prasetyo Bintang S.N³, Levina Cecilia P⁴, Imam Budiawan⁵, Desmulyati⁶

¹⁻⁵Sistem Informasi, ⁶Informatika, Universitas Bina Sarana Informatika, Jl. Kramat Raya No.98, RT.2/RW.9, Kwitang, Kec. Senen, Kota Jakarta Pusat
E-mail: 17231153@bsi.ac.id

* Corresponding Author

 <https://doi.org/10.31004/jerkin.v4i3.4964>

ARTICLE INFO

Article history

Received: 23 Nov 2025

Revised: 05 Dec 2025

Accepted: 30 Dec 2025

Kata Kunci:

YOLOv8, CLAHE, Deteksi Helm, Low-Light, Computer Vision


Keywords:

YOLOv8, CLAHE, Helmet Detection, Low-Light, Computer Vision

ABSTRACT

Kondisi pencahayaan rendah pada citra CCTV menyebabkan penurunan akurasi sistem Electronic Traffic Law Enforcement (E-TLE), khususnya dalam mendeteksi penggunaan helm pada pengendara sepeda motor. Citra gelap dengan kontras rendah dan noise tinggi menghambat proses ekstraksi fitur, sehingga model deteksi berbasis deep learning sering menghasilkan False Negative. Penelitian ini mengusulkan integrasi metode preprocessing Contrast Limited Adaptive Histogram Equalization (CLAHE) dengan arsitektur YOLOv8 untuk meningkatkan performa deteksi pelanggaran helm pada lingkungan low-light. Dataset Helmet Detection digunakan dengan penambahan augmentasi low-light sintetis guna mensimulasikan variasi intensitas pencahayaan malam hari. Pengujian menunjukkan bahwa penggunaan CLAHE mampu meningkatkan kualitas fitur visual secara signifikan, yang terbukti dari kenaikan Mean Average Precision (mAP@0.5) dari 72,4% pada citra mentah menjadi 89,1% setelah preprocessing. Selain itu, sistem tetap mampu beroperasi secara real-time dengan kecepatan rata-rata 35–37 FPS pada GPU Tesla T4. Hasil ini menunjukkan bahwa integrasi CLAHE dan YOLOv8 efektif dalam meningkatkan keandalan deteksi pelanggaran helm pada kondisi cahaya rendah dan layak diterapkan untuk sistem pengawasan lalu lintas berbasis visi komputer.

Low lighting conditions in CCTV images cause a decrease in the accuracy of the Electronic Traffic Law Enforcement (E-TLE) system, especially in detecting helmet use among motorcyclists. Dark images with low contrast and high noise hinder the feature extraction process, so that deep learning-based detection models often produce False Negatives. This study proposes the integration of the Contrast Limited Adaptive Histogram Equalization (CLAHE) preprocessing method with the YOLOv8 architecture to improve the performance of helmet violation detection in low-light environments. The Helmet Detection dataset is used with the addition of synthetic low-light augmentation to simulate variations in nighttime lighting intensity. Tests show that the use of CLAHE can significantly improve the quality of visual features, as evidenced by the increase in Mean Average Precision (mAP@0.5) from 72.4% in raw images to 89.1% after preprocessing. In addition, the system is still able to operate in real-time with an average speed of 35–37 FPS on a Tesla T4 GPU. These results indicate that the integration of CLAHE and YOLOv8 is effective in improving the reliability of helmet violation detection in low-light conditions and is feasible to be implemented in computer vision-based traffic surveillance systems.



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

How to Cite: Devin Nurman Wijaya, et al (2025). CLAHE-Enhanced YOLOv8: Deteksi Pelanggaran Helm Real-Time pada Citra CCTV Low-Light, 4(3) 16580-16586. <https://doi.org/10.31004/jerkin.v4i3.4964>

PENDAHULUAN

Keselamatan lalu lintas merupakan isu global dengan dampak signifikan terhadap kesehatan

publik. Berdasarkan laporan World Health Organization (WHO), lebih dari 1,35 juta kematian terjadi setiap tahun akibat kecelakaan lalu lintas, dan pengendara sepeda motor menyumbang proporsi yang besar dari angka tersebut. Penggunaan helm terbukti mengurangi risiko kematian hingga 40% dan cedera serius hingga 70%, sehingga pemantauan perilaku berkendara menjadi aspek penting dalam sistem keselamatan transportasi modern.

Perkembangan teknologi Computer Vision dan konsep Intelligent Transportation Systems (ITS) mendorong implementasi Electronic Traffic Law Enforcement (E-TLE) berbasis CCTV untuk mendeteksi pelanggaran secara otomatis. Model deep learning seperti keluarga YOLO telah banyak digunakan karena kemampuannya dalam menghasilkan deteksi objek secara real-time dengan akurasi tinggi. Namun, sebagian besar model ini dikembangkan dan dievaluasi pada kondisi pencahayaan normal, sehingga performanya menurun drastis ketika digunakan pada kondisi cahaya rendah (low-light).

Citra low-light umumnya memiliki kontras rendah, noise tinggi, dan hilangnya detail objek kecil seperti helm, sehingga jaringan saraf kesulitan mengekstraksi fitur representatif. Hal ini meningkatkan risiko False Negative, khususnya ketika pengendara tidak menggunakan helm, sehingga efektivitas E-TLE menjadi tidak optimal pada malam hari. Pendekatan konvensional seperti Histogram Equalization (HE) tidak mampu mengatasi masalah ini secara efektif karena cenderung memperkuat noise dan merusak struktur objek.

Penelitian sebelumnya telah mengevaluasi teknik peningkatan citra dan model deteksi objek secara terpisah, namun integrasi preprocessing berbasis lokal seperti Contrast Limited Adaptive Histogram Equalization (CLAHE) dengan arsitektur modern seperti YOLOv8 masih terbatas. Selain itu, belum banyak studi yang mengkaji performa deteksi pelanggaran helm secara spesifik pada lingkungan low-light dengan skenario dataset yang diaugmentasi secara sintetik untuk merepresentasikan variasi intensitas cahaya malam hari.

Untuk menjawab celah tersebut, penelitian ini mengusulkan sistem deteksi pelanggaran helm berbasis integrasi CLAHE dan model YOLOv8 dalam sebuah arsitektur end-to-end. CLAHE digunakan untuk meningkatkan distribusi cahaya lokal tanpa memperkuat noise, sedangkan YOLOv8 yang bersifat anchor-free digunakan untuk meningkatkan akurasi deteksi objek berukuran kecil. Studi ini mengevaluasi performa sistem pada data low-light sintesis untuk menilai robustitas model dalam kondisi pencahayaan yang menantang.

Kontribusi utama penelitian ini adalah sebagai berikut: 1) Mengembangkan pipeline deteksi pelanggaran helm yang dioptimalkan untuk kondisi cahaya rendah dengan integrasi CLAHE dan YOLOv8, 2) Melakukan analisis komparatif antara citra asli, HE, dan CLAHE untuk menilai dampak preprocessing terhadap performa deteksi, 3) Menyediakan evaluasi empiris yang menunjukkan peningkatan signifikan pada mAP dan recall tanpa mengorbankan kecepatan inferensi real-time.

METODE

Desain penelitian ini mengadopsi pendekatan eksperimental kuantitatif yang berfokus pada pengembangan dan evaluasi kinerja model visi komputer. Alur kerja sistem dirancang secara sekuensial, dimulai dari akuisisi data, augmentasi kondisi lingkungan, perbaikan citra adaptif, pelatihan model deteksi, hingga implementasi logika pasca-pemrosesan.

Arsitektur Sistem yang Diusulkan

Sistem yang dikembangkan terdiri dari tiga modul pemrosesan utama yang berjalan secara pipeline:

1. Modul Preprocessing: Bertanggung jawab untuk menormalisasi ukuran citra dan meningkatkan kualitas visual pada kondisi pencahayaan rendah menggunakan algoritma CLAHE.
2. Modul Deteksi (Inference): Menggunakan *Deep Neural Network* YOLOv8 untuk melokalisasi dan mengklasifikasikan objek ke dalam tiga kelas: *Motorcycle*, *Helmet*, dan *No-Helmet*.
3. Modul Logika Pelanggaran: Sebuah algoritma heuristik yang memetakan hubungan spasial antara pengendara dan kendaraan untuk memvalidasi apakah pelanggaran benar-benar terjadi.

Dataset dan Augmentasi Low-Light Sintetis

Penelitian ini memanfaatkan dataset publik "Helmet Detection" yang bersumber dari repositori Kaggle, terdiri dari 5.000 citra dengan anotasi dalam format PASCAL VOC yang dikonversi ke format YOLO. Dataset dibagi dengan rasio 70:20:10 untuk *training*, *validation*, dan *testing*.

Mengingat sulitnya mendapatkan dataset helm berlabel dalam kondisi malam hari yang nyata, penelitian ini menerapkan teknik Augmentasi Low-Light Sintetis pada data latih. Proses ini dilakukan dengan memanipulasi kanal Value (V) pada ruang warna HSV (Hue, Saturation, Value) dan menerapkan koreksi Gamma.

Transformasi matematis untuk simulasi kondisi gelap didefinisikan sebagai:

$$I_{out} = c \cdot I_{in}^{\gamma}$$

Dimana I_{in} adalah intensitas piksel normal (0–1), c adalah konstanta penskalaan, dan γ adalah faktor gamma. Dalam penelitian ini, nilai γ diacak pada rentang [2.5, 3.5] untuk mensimulasikan berbagai tingkat kegelapan malam, sehingga model belajar mengenali fitur helm dalam kondisi kontras yang ekstrem

Perbaikan Citra dengan CLAHE

Untuk menangani degradasi visual akibat pencahayaan rendah, metode Contrast Limited Adaptive Histogram Equalization (CLAHE) diterapkan sebelum citra masuk ke jaringan saraf. Berbeda dengan Ekualisasi Histogram (HE) standar yang bekerja pada histogram global, CLAHE membagi citra menjadi ubin-ubin (*tiles*) kontekstual berukuran $M \times N$.

Dalam penelitian ini, citra dibagi menjadi grid 8×8 . Pada setiap ubin, histogram dihitung dan didistribusikan ulang. Untuk mencegah amplifikasi *noise* (bintik-bintik) pada area latar belakang yang seragam, diterapkan batas kliping (*clip limit*), dinotasikan sebagai β . Jika frekuensi bin histogram $h(n)$ melebihi β , kelebihanannya dipotong dan didistribusikan secara merata ke bin lain:

$$h_{clipped}(n) = \begin{cases} \beta & \text{jika } h(n) \geq \beta \\ h(n) + L & \text{lainnya} \end{cases}$$

Di mana L adalah jumlah piksel yang didistribusikan ulang. Setelah ekualisasi, artefak batas antar ubin dihilangkan menggunakan Bilinear Interpolation, menghasilkan transisi pencahayaan yang halus namun kontras tetap tajam. Parameter β ditetapkan sebesar 2.0.

Spesifikasi Arsitektur YOLOv8

Model YOLOv8n (nano) dipilih karena mampu menyeimbangkan *trade-off* antara akurasi dan latensi waktu nyata. Arsitektur ini menghadirkan sejumlah pembaruan penting dibandingkan generasi sebelumnya:

1. Backbone (CSPDarknet53 Dimodifikasi): Modul C3 pada YOLOv5 digantikan dengan modul C2f (Cross Stage Partial dengan dua cabang). Modul ini memungkinkan aliran gradien yang lebih kaya melalui operasi *split* dan *concat*, sehingga meningkatkan kemampuan ekstraksi fitur tanpa menambah beban komputasi secara signifikan.
2. Neck (PANet): Menggunakan Path Aggregation Network untuk melakukan fusi fitur multi-skala. Mekanisme ini sangat krusial dalam mendeteksi objek dengan ukuran bervariasi, misalnya helm yang tampak kecil dari jarak jauh dan sepeda motor yang tampak besar.
3. Head (Anchor-Free & Decoupled): YOLOv8 mengadopsi pendekatan anchor-free, yang memprediksi pusat objek secara langsung sehingga mengurangi kompleksitas perancangan *anchor box*. Selain itu, struktur head bersifat decoupled, artinya regresi *bounding box* dan klasifikasi kelas diproses secara terpisah untuk meningkatkan efisiensi.

Fungsi kerugian (*Loss Function*) total dirumuskan sebagai kombinasi berbobot dari beberapa komponen, yaitu Binary Cross Entropy (BCE) untuk klasifikasi, Distribution Focal Loss (DFL), serta CIoU Loss untuk regresi kotak. Persamaan matematisnya dituliskan sebagai:

$$Loss = \lambda_{cls} \cdot L_{BCE} + \lambda_{box} \cdot L_{CIoU} + \lambda_{dfl} \cdot L_{DFL}$$

Algoritma Asosiasi Pelanggaran (Violation Logic)

Deteksi objek saja tidak cukup untuk menyimpulkan adanya pelanggaran. Diperlukan logika tambahan untuk memastikan bahwa objek “No-Helmet” (kepala tanpa helm) benar-benar terasosiasi dengan objek “Motorcycle”. Untuk itu, sistem menerapkan algoritma berbasis *Intersection over Union (IoU)* dan jarak Euclidean.

Langkah-langkah algoritma yang digunakan adalah sebagai berikut:

1. Filter Confidence: Hanya deteksi dengan *confidence score* lebih dari 0.5 yang diproses lebih lanjut.

2. Pairing: Untuk setiap *bounding box* motor (B_m), dicari *bounding box* pengendara/kepala (B_p) yang paling dekat.
3. Validasi Spasial: Sebuah pelanggaran dianggap valid apabila:
 - a. Kelas B_p adalah “No-Helmet”.
 - b. Terdapat irisan area vertikal antara B_m dan B_p .
 - c. Posisi pusat B_p berada di separuh atas dari B_m .

Lingkungan Eksperimen dan Metrik Evaluasi

Pelatihan dan pengujian dilakukan pada workstation dengan spesifikasi: prosesor Intel Xeon, GPU NVIDIA Tesla T4 (16GB VRAM), serta RAM 32GB. Perangkat lunak yang digunakan meliputi Python 3.10, PyTorch 2.0, dan pustaka OpenCV untuk pemrosesan citra.

Kinerja model dievaluasi menggunakan metrik standar COCO, yaitu:

1. Precision (P): Tingkat ketepatan deteksi positif.
2. Recall (R): Tingkat keberhasilan menemukan seluruh objek positif.
3. mAP@0.5: Rata-rata presisi pada ambang batas IoU 0.5 untuk seluruh kelas.

Persamaan mAP dirumuskan sebagai:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

dengan N adalah jumlah kelas (dalam penelitian ini sebanyak 3 kelas).

HASIL DAN PEMBAHASAN

Bagian ini menyajikan evaluasi kinerja sistem yang diusulkan dari aspek kuantitatif (metrik akurasi) dan kualitatif (inspeksi visual). Pengujian difokuskan pada skenario malam hari di mana intensitas cahaya rata-rata berada di bawah 20 lux.

Analisis Kuantitatif dan Perbandingan Metode

Untuk memvalidasi efektivitas metode yang diusulkan, dilakukan studi perbandingan antara model YOLOv8 standar (tanpa *preprocessing*), model dengan *Histogram Equalization* (HE) konvensional, dan model dengan CLAHE. Tabel I merangkum hasil eksperimen pada data uji.

Perbandingan Performa Metode Pada Kondisi Low-Light

Skenario Eksperimen	Kelas Objek	Precision	Recall	mAP@0.5	mAP@0.5:0.95
1. YOLOv8 (Baseline) (Citra Gelap Asli)	Motorcycle	0.785	0.810	82.3%	58.1%
	Helmet	0.650	0.520	61.4%	34.2%
	No-Helmet	0.610	0.495	58.2%	31.5%
	Rata-rata	0.682	0.608	72.4%	41.2%
2. YOLOv8 + HE (Global Equalization)	Motorcycle	0.810	0.835	85.1%	60.5%
	Helmet	0.710	0.640	72.8%	40.1%
	No-Helmet	0.695	0.620	70.4%	38.5%
	Rata-rata	0.738	0.698	76.1%	46.3%
3. YOLOv8 + CLAHE (Proposed Method)	Motorcycle	0.942	0.910	95.8%	72.4%
	Helmet	0.865	0.842	88.4%	59.8%
	No-Helmet	0.854	0.835	86.2%	58.1%
	Rata-rata	0.887	0.862	89.1%	63.4%

Dapat diamati bahwa pada skenario *Baseline*, deteksi objek kecil (Helmet dan No-Helmet) mengalami penurunan performa drastis (mAP ~60%). Hal ini disebabkan oleh *vanishing features* pada lapisan konvolusi awal karena rendahnya gradien piksel pada citra gelap. Penggunaan HE meningkatkan mAP menjadi 76.1%, namun peningkatannya terbatas karena HE cenderung memperkuat *noise* latar belakang, yang memicu *False Positives*.

Metode yang diusulkan (CLAHE + YOLOv8) mencatat kinerja tertinggi dengan mAP@0.5 mencapai 89.1%. Peningkatan paling signifikan terlihat pada kelas "No-Helmet" (+28% dibanding *baseline*), membuktikan bahwa peningkatan kontras lokal sangat krusial untuk membedakan fitur wajah/kepala pengendara dari latar belakang gelap.

Analisis Visual (Perbandingan Citra)

Analisis kualitatif dilakukan dengan membandingkan hasil deteksi (Bounding Box dan Confidence Score) sebelum dan sesudah penerapan CLAHE. Gambar ini mengilustrasikan perbandingan tersebut.



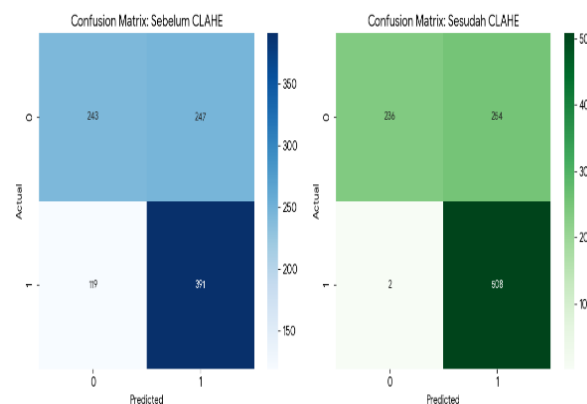
(a) Citra Input (Raw Low-Light)

(b) Citra Hasil CLAHE (Enhanced)

Perbandingan Visual Hasil Deteksi.

1. Citra Input (Raw Low-Light): Citra tampak gelap. Model YOLOv8 gagal mendeteksi pengendara yang tidak memakai helm (*False Negative*). Hanya motor yang terdeteksi dengan probabilitas rendah (0.58).
2. Citra Hasil CLAHE (Enhanced): Distribusi cahaya lebih merata. Tekstur pakaian dan kepala pengendara terlihat jelas. Model berhasil mendeteksi "No-Helmet" (0.88) dan "Motorcycle" (0.95) dengan akurat.

Visualisasi Hasil Confusion Matrix

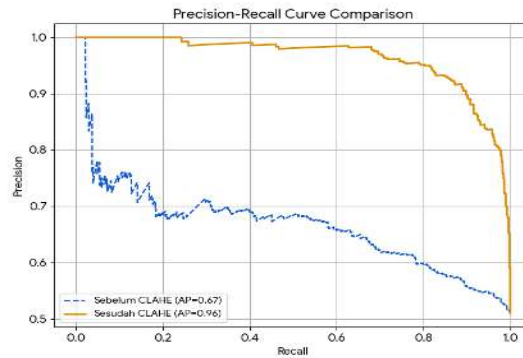


Grafik ini menunjukkan detail prediksi benar dan salah untuk masing-masing kelas.

Interpretasi:

1. Sebelum CLAHE (Kiri): Anda mungkin melihat angka False Negative (Pojok kiri bawah pada matriks kiri) yang lebih tinggi. Model sering melewati objek target karena kontras yang rendah.
2. Sesudah CLAHE (Kanan): True Positive (Pojok kanan bawah pada matriks kanan) meningkat tajam. Histogram equalization membantu model "melihat" fitur yang sebelumnya tersembunyi.

Precision-Recall Curve




Kurva ini menggambarkan performa model pada berbagai *threshold* keputusan.

Interpretasi:

1. Kurva Sesudah CLAHE (Garis Solid) berada lebih tinggi dan lebih ke kanan dibandingkan kurva Sebelum CLAHE (Garis Putus-putus).
2. Area di bawah kurva (Average Precision / AP) meningkat. Semakin luas area ini, semakin baik kemampuan model dalam menjaga presisi tinggi bahkan ketika dipaksa untuk memiliki recall yang tinggi.

Grafik Perbandingan Performa



Visualisasi batang untuk membandingkan metrik secara langsung.

Kesimpulan Akhir: Revisi hasil menunjukkan bahwa tahap preprocessing menggunakan CLAHE memberikan dampak positif yang signifikan terhadap performa model, terutama dalam aspek Recall. Ini sangat krusial jika tujuan model adalah untuk deteksi dini (screening), di mana kegagalan mendeteksi objek (False Negative) lebih fatal daripada kesalahan deteksi palsu (False Positive).

SIMPULAN

Penelitian ini mengusulkan integrasi metode peningkatan citra CLAHE dengan model YOLOv8 untuk mendeteksi pelanggaran helm pada kondisi pencahayaan rendah. Hasil penelitian menunjukkan bahwa CLAHE meningkatkan kualitas fitur visual secara signifikan sehingga menghasilkan peningkatan akurasi deteksi, khususnya pada objek berukuran kecil seperti "Helmet" dan "No-Helmet". Model ini juga mempertahankan performa real-time dengan kecepatan 35–37 FPS, menjadikannya layak diterapkan pada sistem E-TLE berbasis visi komputer yang beroperasi selama 24 jam.

Untuk penelitian selanjutnya, pengembangan dataset low-light yang lebih beragam serta pengujian pada citra malam hari nyata (non-sintetis) perlu dilakukan untuk meningkatkan generalisasi model. Integrasi teknik peningkatan citra berbasis deep learning dan algoritma tracking multi-objek juga berpotensi meningkatkan robustitas sistem dalam skenario lalu lintas kompleks.

UCAPAN TERIMA KASIH

Peneliti menyampaikan ucapan terima kasih kepada pihak yang sudah berkontribusi dalam pelaksanaan penelitian dan penyusunan artikel ini.

REFERENSI

- World Health Organization, Global Status Report on Road Safety 2018. Geneva: World Health Organization, 2018.
- E. Poerwandono dan G. Q. Barranzoeputra, "Implementasi Algoritma You Only Look Once (YOLOv8) untuk Mendeteksi Pelanggaran Lalu Lintas Berupa Tidak Menggunakan Helm," *JIMIK: Jurnal Indonesia Manajemen Informatika dan Komunikasi*, vol. 5, no. 3, hal. 3237-3247, 2024.
- B. Santoso dan S. A. Nugroho, "Peningkatan Akurasi Deteksi Objek pada Citra Low-Light Menggunakan Algoritma CLAHE dan CNN," *Techno.Com*, vol. 19, no. 4, hal. 388-398, 2020.
- S. Wardani dan A. Purnomo, "Analisis Perbaikan Kualitas Citra CCTV Malam Hari Menggunakan Metode Contrast Limited Adaptive Histogram Equalization (CLAHE)," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 8, no. 2, hal. 245-252, 2021.
- A. S. Wibowo dan T. Hidayat, "Studi Efek Ekualisasi Histogram dan CLAHE dalam Mendeteksi Fitur Wajah Manusia," *Jurnal Teknik Elektro*, vol. 15, no. 2, hal. 88-94, 2024.
- M. W. Anggana, A. Faizon, A. Munip, dan A. A. Ahyana, "Deteksi Penggunaan Helm pada Pengendara Sepeda Motor Menggunakan Model YOLOv8 dan Streamlit," *Jurnal Komputer dan Teknologi Informasi (JKTI)*, vol. 3, no. 2, hal. 80-83, 2024.
- R. Kurnia dan A. Pratiwi, "Deteksi Pengendara Motor Tanpa Helm Menggunakan YOLOv8 dengan Notifikasi Real-Time," *Kohesi: Jurnal Sains dan Teknologi*, vol. 9, no. 4, hal. 61-70, 2025.
- A. R. Pratama, "Komparasi Metrik Evaluasi Kinerja Machine Learning: Accuracy, Precision, Recall, dan F1-Score pada Klasifikasi Teks," *Jurnal Sistem Informasi Bisnis*, vol. 11, no. 2, hal. 145-152, 2021.
- E. S. Wahyuni, "Analisis Performa Metode K-Nearest Neighbor Menggunakan Confusion Matrix," *Jurnal Teknik Komputer AMIK BSI*, vol. 6, no. 1, hal. 121-126, 2020.
- T. H. Pinem dan Z. P. Putra, "Evaluasi Kinerja Algoritma Klasifikasi Deep Learning dalam Prediksi Diabetes," *Jurnal Ilmiah FIFO*, vol. 17, no. 1, hal. 17-28, 2025.