



JUDUL

**Peningkatan Akurasi YOLOv11 Untuk Pendeteksian Kendaraan
Pada Citra Low-Light Menggunakan Pendekatan Cascaded
CLAHE dan Denoising Autoencoder**

*diajukan untuk memenuhi sebagian persyaratan memperoleh gelar Sarjana pada
Program Studi Informatika.*

SKRIPSI

Oleh

**Andhika Rachmat Fauzi
222410103012**

**KEMENTERIAN PENDIDIKAN, KEBUDAYAAN, RISET, DAN
TEKNOLOGI
UNIVERSITAS JEMBER
FAKULTAS ILMU KOMPUTER
PROGRAM STUDI INFORMATIKA
JEMBER
2026**

PERSEMBAHAN

Dengan mengucapkan puji syukur kehadiran Tuhan Yang Maha Esa, karya tulis ini saya persembahkan kepada:

1. Allah SWT yang senantiasa melimpahkan rahmat, ridha, kesehatan, kekuatan, serta kemudahan kepada penulis sehingga dapat menyelesaikan skripsi ini dengan baik.
2. Kedua orang tua tercinta, yang senantiasa menjadi rumah untuk pulang, serta alasan untuk terus bertahan dan berjuang. Terimakasih atas doa yang tidak putus, kasih sayang dan pengorbanan yang tidak dapat diukur oleh apa pun, serta kepercayaan yang selalu diberikan kepada saya dalam setiap langkah kehidupan. Semoga karya sederhana ini menjadi salah satu bentuk bakti dan kebanggan yang dapat saya persembahkan.
3. Almamater tercinta, Program Studi Teknologi Informasi, Fakultas Ilmu Komputer, yang telah menjadi tempat bagi penulis untuk belajar, bertumbuh, berkembang dan memperoleh banyak pengalaman serta ilmu yang berharga selama masa perkuliahan.
4. Seluruh Bapak/Ibu dosen, khususnya dosen akademik, dosen pembimbing, dosen penguji, serta seluruh tenaga pendidik di lingkungan Program Studi yang telah memberikan ilmu, arahan, bimbingan, motivasi, dan pengalaman berharga selama masa perkuliahan hingga terselesaikannya skripsi ini.
5. Sahabat, pasangan dan teman-teman terdekat, yang selalu hadir memberikan bantuan, doa, maupun dukungan dalam bentuk apapun sehingga tugas akhir ini dapat diselesaikan dengan baik.

MOTTO

Apa adanya adanya apa

- Diwantara Anugrah Putra dan Gema Cita Andhika



PERNYATAAN ORISINALITAS

Saya yang bertanda tangan di bawah ini :

Nama : Andhika Rachmat Fauzi

NIM : 222410103012

Menyatakan dengan sesungguhnya bahwa skripsi yang berjudul: *Peningkatan Akurasi YOLOv11 Untuk Pendeteksian Kendaraan Pada Citra Low-Light Menggunakan Pendekatan Cascaded CLAHE dan Denoising Autoencoder* adalah benar-benar hasil karya sendiri, kecuali jika dalam pengutipan substansi disebutkan sumbernya, dan belum pernah diajukan pada institusi manapun, serta bukan karya jiplakan. Saya bertanggung jawab atas keabsahan dan kebenaran isinya sesuai dengan sikap ilmiah yang harus dijunjung tinggi.

Demikian pernyataan ini saya buat dengan sebenarnya, tanpa adanya tekanan dan paksaan dari pihak manapun serta bersedia mendapat sanksi akademik jika ternyata di kemudian hari pernyataan ini tidak benar.

Jember, 9 Juli 2026

Yang menyatakan,



Andhika Rachmat Fauzi

NIM 222410103012

HALAMAN PERSETUJUAN

Skripsi berjudul *Peningkatan Akurasi YOLOv11 Untuk Pendeteksian Kendaraan Pada Citra Low-Light Menggunakan Pendekatan Cascaded CLAHE dan Denoising Autoencoder* telah diuji dan disetujui oleh Fakultas Ilmu Komputer Universitas Jember pada:

Hari : Rabu
Tanggal : 22 Juli 2026
Tempat : Fakultas Ilmu Komputer Universitas Jember

Pembimbing

1. Pembimbing Utama

Nama : Nelly Oktavia Adiwijaya, S.Si., MT.
NIP : 198410242009122008


Tanda Tangan

().....)

Penguji

1. Penguji Utama

Nama : Dr. Dwiretno Istiyadi S, ST., M.Kom.
NIP : 197803302003121003

().....)

2. Penguji Anggota 1

Nama : Yudha Alif Auliya, S.Kom., M.Kom.
NIP : 199206302022031009

().....)

ABSTRAK

Pendeteksian kendaraan merupakan komponen krusial dalam Sistem Transportasi Cerdas (ITS). Namun, kinerja model deteksi objek seringkali mengalami penurunan akurasi yang drastis ketika dihadapkan pada citra dengan kondisi minim cahaya (*low-light*). Citra pada malam hari umumnya memiliki karakteristik kontras yang sangat rendah dan tingkat *noise* yang tinggi, sehingga mengakibatkan hilangnya detail fitur visual penting pada kendaraan. Penelitian ini bertujuan untuk meningkatkan akurasi model YOLOv11 dalam mendeteksi kendaraan pada citra *low-light* melalui penerapan pendekatan prapemrosesan bertingkat (*cascaded*). Metode yang diusulkan menggabungkan teknik peningkatan kontras *Contrast Limited Adaptive Histogram Equalization* (CLAHE) dan arsitektur *deep learning Convolutional Denoising Autoencoder* (CDAE).

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan memanfaatkan dataset berupa 2.000 citra lalu lintas yang diekstraksi dari rekaman CCTV publik di ruas jalan Tugu Ireng, Kabupaten Magelang. Objek penelitian difokuskan pada empat kelas kendaraan utama: mobil, sepeda motor, bus, dan truk. Pada tahap prapemrosesan, CLAHE diterapkan secara spesifik pada kanal *Lightness* (L) dalam ruang warna LAB untuk meningkatkan kontras secara lokal tanpa mendistorsi warna asli objek. Selanjutnya, model CDAE digunakan untuk mereduksi *noise* intensitas tinggi yang teramplifikasi, sekaligus mempertahankan ketajaman batas tepi kendaraan. Citra hasil kombinasi CLAHE-DAE ini kemudian diumpankan ke dalam arsitektur YOLOv11 untuk proses deteksi objek.

Evaluasi kinerja sistem diukur menggunakan metrik kualitas citra, yaitu *Peak Signal-to-Noise Ratio* (PSNR) dan *Structural Similarity Index Measure* (SSIM), serta metrik performa deteksi yang mencakup *Precision*, *Recall*, dan *mean Average Precision* (mAP). Melalui pendekatan *cascaded* ini, diharapkan kualitas visual citra *low-light* dapat dipulihkan secara komprehensif, sehingga mampu memberikan peningkatan yang signifikan terhadap stabilitas dan akurasi deteksi YOLOv11 dibandingkan dengan penggunaan citra mentah (*baseline*).

Kata kunci: deteksi kendaraan, *low-light*, YOLOv11, CLAHE, *Denoising Autoencoder*

ABSTRACT

Vehicle detection is a crucial component in Intelligent Transportation Systems (ITS). However, the performance of object detection models often experiences a drastic decrease in accuracy when faced with low-light images. Nighttime images generally have characteristics of very low contrast and high noise levels, resulting in the loss of important visual feature details of vehicles. This research aims to improve the accuracy of the YOLOv11 model in detecting vehicles in low-light images through the application of a cascaded pre-processing approach. The proposed method combines the contrast enhancement technique of Contrast Limited Adaptive Histogram Equalization (CLAHE) and the deep learning architecture of Convolutional Denoising Autoencoder (CDAE).

This research uses an experimental quantitative approach by utilizing a dataset of 2,000 traffic images extracted from public CCTV recordings on the Tugu Ireng road section, Magelang Regency. The research object focuses on four main vehicle classes: cars, motorcycles, buses, and trucks. In the pre-processing stage, CLAHE is applied specifically to the Lightness (L) channel in the LAB color space to increase contrast locally without distorting the original colors of the objects. Furthermore, the CDAE model is used to reduce the amplified high-intensity noise while maintaining the sharpness of the vehicle's edges. The combined CLAHE-DAE image is then fed into the YOLOv11 architecture for the object detection process.

The system's performance evaluation is measured using image quality metrics, namely Peak Signal-to-Noise Ratio (PSNR) and Structural Similarity Index Measure (SSIM), as well as detection performance metrics which include Precision, Recall, and mean Average Precision (mAP). Through this cascaded approach, it is expected that the visual quality of low-light images can be comprehensively restored, thereby providing a significant improvement to the stability and detection accuracy of YOLOv11 compared to the use of raw images (baseline).

Keywords: vehicle detection, low-light, YOLOv11, CLAHE, Denoising Autoencoder

RINGKASAN

Deteksi kendaraan pada malam hari merupakan tantangan fundamental dalam bidang Computer Vision. Kondisi iluminasi ekstrem, distorsi cahaya (glare), dan derau (noise) sensor pada rekaman CCTV secara matematis merusak fitur gradien tepi (edge gradients) yang krusial bagi ekstraksi fitur Convolutional Neural Network (CNN). Fenomena domain gap ini menyebabkan model deteksi mutakhir seperti YOLOv11 mengalami "kebutaan malam" (night blindness) dan gagal mengenali objek dengan akurat pada kondisi low-light, dimana bentuk fisik kendaraan sering kali melebur dengan kegelapan latar belakang.

Penelitian ini bertujuan untuk meningkatkan performa akurasi deteksi kendaraan YOLOv11 pada citra low-light tanpa harus mengubah arsitektur internal model deteksi itu sendiri. Solusi yang diusulkan adalah merancang sebuah pipeline prapemrosesan citra menggunakan pendekatan Cascaded yang menggabungkan algoritma Contrast Limited Adaptive Histogram Equalization (CLAHE) dan Denoising Autoencoder (DAE) berbasis U-Net. Selain itu, penelitian ini juga bertujuan untuk mengimplementasikan algoritma tersebut ke dalam sebuah sistem prototipe pendeteksian berbasis client-server.

Dataset yang digunakan dalam eksperimen terdiri atas 2.000 citra yang diekstraksi dari rekaman CCTV Tugu Ireng, Kabupaten Magelang. Data tersebut memiliki tantangan berupa extreme class imbalance dengan dominasi kelas Mobil dan Motor. Metodologi prapemrosesan dibagi menjadi empat skenario pengujian (SC-01 hingga SC-04). Parameter optimal dicari menggunakan metode Grid Search, yang menetapkan urutan eksekusi CLAHE terlebih dahulu (clip limit 1.0) untuk menaikkan kontras, dilanjutkan dengan DAE (Alpha Blending 0.3) untuk membersihkan derau. Evaluasi performa deteksi dilakukan dengan membandingkan dua skema arsitektur YOLOv11-Large: model zero-shot (COCO Baseline) dan model hasil fine-tuning (Retrain dengan strategi Domain Adaptation). Implementasi sistem dibangun menggunakan FastAPI (Python) pada sisi backend dan React.js pada sisi frontend.

Hasil penelitian menunjukkan bahwa pendekatan Cascaded (SC-04) sukses meningkatkan kontras dan mereduksi derau secara simultan, terbukti dari capaian kualitas restorasi dengan rata-rata PSNR 22,27 dB dan SSIM 0.9471. Pada evaluasi deteksi, metode prapemrosesan ini terbukti berfungsi sebagai feature recovery layer yang bersifat plug-and-play. Penerapan SC-04 berhasil memulihkan visibilitas fitur yang hilang sehingga mAP@0.5 pada model Baseline meningkat dari 0.2145 menjadi 0.2147. Sementara itu, eksperimen menggunakan model Retrain berhasil membuktikan mitigasi domain gap dengan mencapai mAP@0.5 sebesar 0.4596 pada citra mentah. Lebih lanjut, penerapan pra-pemrosesan Cascaded (SC-04) secara konsisten berhasil memulihkan dan menaikkan akurasi menjadi 0.4631, membuktikan bahwa metode ini efektif mencegah efek over-smoothing yang biasa terjadi pada pemrosesan tunggal.

Kesimpulan dari penelitian ini menegaskan bahwa sinergi Cascaded CLAHE-DAE terbukti efektif menormalisasi distribusi fitur low-light dan sangat direkomendasikan untuk menstabilkan serta meningkatkan akurasi model deteksi secara komprehensif. Sistem dashboard interaktif yang diimplementasikan juga telah berhasil mendemonstrasikan kapabilitas pemrosesan alur inferensi secara in-line, memberikan landasan operasional yang solid untuk pengembangan sistem pengawasan lalu lintas cerdas di masa depan.

PRAKATA

Puji syukur ke hadirat Allah SWT atas segala rahmat, taufik, dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul *"Peningkatan Akurasi YOLOv11 Untuk Pendeteksian Kendaraan Pada Citra Low-Light Menggunakan Pendekatan Cascaded CLAHE dan Denoising Autoencoder"* dengan baik. Skripsi ini disusun untuk memenuhi salah satu syarat memperoleh gelar Sarjana Komputer pada Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Jember.

Penyusunan skripsi ini tidak lepas dari bantuan, bimbingan, arahan, dan dukungan dari berbagai pihak. Oleh karena itu, dengan penuh rasa hormat dan kerendahan hati, penulis menyampaikan ucapan terima kasih dan penghargaan yang setinggi-tingginya kepada:

1. Kepada Allah SWT, Tuhan Yang Maha Esa, atas segala rahmat, karunia, dan pertolongan-Nya yang senantiasa menyertai langkah penulis dalam menyelesaikan skripsi ini. Segala puji bagi-Nya yang telah memudahkan setiap proses, memberikan kekuatan disaat lelah, dan jalan keluar di setiap kesulitan, sehingga skripsi ini dapat diselesaikan dengan baik dan tepat waktu.
2. Kedua orang tua tercinta penulis, Bapak dan Ibu, yang senantiasa memberikan doa yang tidak pernah putus, kasih sayang dan dukungan, serta menjadi sumber penyemangat bagi penulis untuk menyelesaikan pendidikan ini. Semoga Allah SWT senantiasa melimpahkan kesehatan, keberkahan, dan kebahagiaan kepada kedua orang tua.
3. Bapak Dekan Fakultas, Prof. Drs. Antonius Cahya Prihandoko, M.App.Sc, Ph.d., sekaligus Dosen pembimbing Akademik saya yang telah memberikan kesempatan dan fasilitas selama penulis menempuh pendidikan di Fakultas Ilmu Komputer ini. Terimakasih juga telah memberikan perhatian, nasihat, dan dukungan melalui bimbingan selama masa perkuliahan, sehingga penulis dapat menyelesaikan pendidikan tepat waktu.

4. Ibu Ketua Program Studi Informatika, Nelly Oktavia Adiwijaya, S.Si., MT., sekaligus selaku Dosen Pembimbing saya yang telah memberikan arahan selama proses kuliah berlangsung hingga penulis dapat menyelesaikan skripsi ini. Terimakasih juga telah penuh kesabaran telah meluangkan waktu, tenaga, dan pikiran untuk memberikan arahan, kritik, saran dan motivasi sehingga skripsi ini terselesaikan dengan baik dan tepat waktu.
5. Dosen Penguji, Bapak Dr. Dwiretno Istiyadi S, ST., M.Kom. dan Bapak Yudha Alif Auliya, S.Kom.,M.Kom. yang telah penuh kesabaran telah meluangkan waktu, tenaga, dan pikiran untuk memberikan masukan, saran, serta evaluasi yang sangat berharga dalam penyempurnaan skripsi ini, sehingga skripsi ini dapat menjadi lebih baik.
6. Sahabat semasa sekolah saya dari SMP, dan SMA, yang telah memberikan dukungan, bantuan, dan semangat yang luar biasa selama proses skripsi ini berlangsung dari awal hingga akhir.
7. Pasangan penulis yang selalu memberikan support, semangat, bantuan yang sangat berdampak dalam selama proses pengerjaan skripsi ini berlangsung dari awal hingga akhir
8. Teman-teman Perundungan yang selalu memberikan support dan dukungan serta selalu menghibur disaat adanya kesulitan dalam proses pengerjaan skripsi ini
9. *Last but not least*, untuk penulis sendiri, Andhika Rachmat Fauzi. Seorang anak bungsu yang selalu berusaha menyimpan segala sesuatunya sendiri. Terima kasih sudah bertahan dan terus berusaha sejauh ini, tanpa semangat dari diri sendiri akan terasa tidak mudah untuk melangkah dan menyelesaikan apa yang harus diselesaikan. Meskipun harus dengan perasaan yang sering kali bercampur aduk, tapi dengan tidak menyerah itu salah satu hal paling membanggakan. Semoga di langkah selanjutnya selalu bisa mendapatkan hal baik dan dikelilingi oleh orang-orang yang baik juga.


DAFTAR ISI

HALAMAN JUDUL	i
PERSEMBAHAN	ii
MOTTO	iii
PERNYATAAN ORISINALITAS	iv
HALAMAN PERSETUJUAN	v
ABSTRAK	vi
RINGKASAN	viii
PRAKATA	ix
DAFTAR ISI	x
DAFTAR TABEL	xii
DAFTAR GAMBAR	xiii
DAFTAR LAMPIRAN	xiv
DAFTAR NOTASI	xv
DAFTAR ISTILAH DAN SINGKATAN	xvi
BAB 1. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	2
1.3 Batasan Penelitian	3
1.4 Tujuan Penelitian	3
1.5 Manfaat Penelitian	3
BAB 2. TINJAUAN TEORI	5
2.1 Kajian Literatur	5
2.2 Deteksi Kendaraan	7
2.3 Citra low-light	7
2.4 Algoritma Deteksi Objek YOLOv11	8
2.5 prapemrosesan Region of Interest (ROI) Masking	8
2.6 Contrast Limited Adaptive Histogram Equalization (CLAHE)	8
2.7 Denoising Autoencoder (DAE) Berbasis Arsitektur U-Net	9
2.8 Multi-Component Loss Function (MSE, SSIM, dan Perceptual Loss VGG-16)	10
2.9 Teknik Fusi Citra (Alpha Blending)	10
2.10 Sintesis Citra, Domain Adaptation, dan Penanganan Class Imbalance	11
2.11 Metrik Evaluasi Kualitas Citra dan Deteksi	11
BAB 3. METODOLOGI PENELITIAN	13
3.1 Jenis Penelitian	13
3.2 Objek Penelitian	13

3.3 Waktu Penelitian	13
3.4 Tahapan penelitian	13
3.4.1. Pengumpulan Dataset	13
3.4.2. Preprocessing Dataset	14
3.4.3. Pelatihan Model Denoising Autoencoder	14
3.4.4. Peningkatan Kontras Menggunakan CLAHE	15
3.4.5. Reduksi Noise Menggunakan Denoising Autoencoder	15
3.4.6. Evaluasi Kualitas Citra	15
3.4.7. Deteksi Objek Menggunakan YOLOv11	15
3.4.8. Evaluasi Performa Deteksi	16
BAB 4. HASIL DAN PEMBAHASAN	17
4.1 Hasil Penelitian	17
4.1.1. Karakteristik Dataset	17
4.1.2. Analisis Pemilihan dan Optimasi Arsitektur DAE	18
4.1.3. Hasil Pelatihan Model DAE	18
4.1.4. Hasil Optimasi Parameter melalui Grid Search	19
4.1.5. Hasil Restorasi Citra: Studi Ablasi (SC-01 s/d SC-04)	20
4.1.6. Evaluasi Performa Deteksi YOLOv11: Skema Baseline vs. Proposed Method	20
4.1.7. Visualisasi Perbandingan Kualitatif SC-01 vs SC-04	22
4.2 Pembahasan	23
4.2.1. Evaluasi Kualitas Restorasi Citra pada Metode Proposed	23
4.2.2. Analisis Kritis Performa Deteksi: Tantangan Ekstrem Citra Malam	24
4.2.3. Signifikansi Metode Proposed pada Model Zero-Shot	25
4.2.4. Eksperimen Retrain YOLO: Mitigasi Domain Gap dan Dampak Domain Adaptation	25
4.2.5. Potensi Data Leakage pada Skema Domain Adaptation	27
4.2.6. Analisis Sinergi Pipeline Cascaded vs Kegagalan Metode Tunggal	27
4.2.7. Evaluasi Kritis Kinerja Sistem: Imbalansi Kelas dan Distorsi Visual	28
4.3 Implementasi Sistem	29
4.3.1. Lingkungan Pengembangan (Tools & Framework)	29
4.3.2. Implementasi Backend (Logika Pipeline & REST API)	30
BAB 5. KESIMPULAN DAN SARAN	31
5.1 Kesimpulan	31
5.2 Saran	31
DAFTAR PUSTAKA	32
LAMPIRAN-LAMPIRAN	35

DAFTAR TABEL

Tabel 2.1 Penelitian Terdahulu	6
Tabel 2.2 Matriks Sintesis Variabel Penelitian	6
Tabel 3.1 Tabel Skenario Pengujian	16
Tabel 4.1 Distribusi Dataset Penelitian	17
Tabel 4.2 Distribusi Objek Kendaraan pada Data Uji (594 Citra)	17
Tabel 4.3 Ringkasan Hasil Pelatihan DAE	19
Tabel 4.4 Perbandingan Rata-rata PSNR dan SSIM pada Data Uji	20
Tabel 4.5 Perbandingan Metrik Deteksi (mAP@0.5, Precision, Recall) Berdasarkan Skenario	21
Tabel 4.6 Evaluasi Per Kelas mAP@0.5	22



DAFTAR GAMBAR

Gambar 2.1 Perbandingan Citra Low-Light dan Normal	5
Gambar 2.2 Menunjukkan adanya kesalahan klasifikasi kendaraan pada citra	5
Gambar 2.3 Menunjukkan Class kendaraan	5
Gambar 2.4: Arsitektur U-Net dengan Skip Connections Sumber (Medium)	10
Gambar 3.1 Tahapan Penelitian	13
Gambar 3.2 Perbandingan karakteristik dataset: (a) Citra Siang Asli (Ground Truth DAE), (b) Citra Siang Sintetis (Input Training DAE), dan (c) Citra Malam Asli (Data Testing YOLOv11)	14
Gambar 4.1 Kurva Precision-Recall Model YOLO Retrain	21
Gambar 4.2 Kurva F1-Confidence Model YOLO Retrain	21
Gambar 4.3 Visualisasi 4-panel SC01 vs SC04 - Gambar (brightness=54.1/255)...	1 23
Gambar 4.4 Visualisasi 4-panel SC01 vs SC04 - Gambar (brightness=44.5/255)...	2 23
Gambar 4.6 Distribusi Jumlah Label pada Dataset	28
Gambar 4.7 Confusion Matrix Model Retrain	28

DAFTAR LAMPIRAN

Lampiran 1.1 Dataset	35
Lampiran 1.2 Source Code	35
Lampiran 1.3 Hasil Training YOLO	35
Lampiran 1.4 Visualisasi Output	35



DAFTAR NOTASI

$I(x)$	<i>Citra hasil tangkapan (input)</i>
$L(x)$	<i>Luminansi citra</i>
$R(x)$	<i>Reflektansi objek</i>
$n(x)$	<i>Noise (derau) pada sensor</i>
$C_{\{limit\}}$	<i>Nilai batas amplifikasi maksimum pada CLAHE</i>
θ	<i>Parameter bobot jaringan (pada DAE)</i>
α	<i>Bobot rasio alpha blending (fusi citra)</i>
PSNR	<i>Peak Signal-to-Noise Ratio</i>
SSIM	<i>Structural Similarity Index Measure</i>
MSE	<i>Mean Squared Error</i>
TP	<i>True Positive</i>
FP	<i>False Positive</i>
FN	<i>False Negative</i>
mAP	<i>mean Average Precision</i>

DAFTAR ISTILAH DAN SINGKATAN

BPS	Badan Pusat Statistik
CDAE	<i>Convolutional Denoising Autoencoder</i>
CLAHE	<i>Contrast Limited Adaptive Histogram Equalization</i>
CCTV	<i>Closed-Circuit Television</i>
DAE	<i>Denoising Autoencoder</i>
DFL	<i>Distribution Focal Loss</i>
ITS	<i>Intelligent Transportation Systems</i>
IoU	<i>Intersection over Union</i>
mAP	<i>mean Average Precision</i>
MSE	<i>Mean Squared Error</i>
PSNR	<i>Peak Signal-to-Noise Ratio</i>
ROI	<i>Region of Interest</i>
SSIM	<i>Structural Similarity Index Measure</i>
YOLO	<i>You Only Look Once</i>

BAB 1. PENDAHULUAN

1.1 Latar Belakang

Sistem Transportasi Cerdas (Intelligent Transportation System) telah menjadi instrumen vital dalam manajemen lalu lintas modern, khususnya dalam aspek pemantauan volume kendaraan dan keamanan jalan raya. Komponen inti dari sistem ini adalah teknologi deteksi objek berbasis deep learning yang dituntut untuk beroperasi secara real-time dan akurat. Model-model mutakhir seperti YOLOv11 telah menunjukkan performa luar biasa pada kondisi pencahayaan ideal. Meski demikian, efektivitas operasional sistem ini seringkali terdegradasi secara drastis ketika dihadapkan pada skenario lingkungan yang tidak terkendali, terutama kondisi low-light atau pencahayaan minim pada malam hari. Secara teknis, citra low-light membawa dua hambatan fundamental bagi algoritma deteksi objek: rendahnya rasio kontras dan tingginya intensitas derau (noise) sensor. Kontras yang rendah menyebabkan fitur morfologi kendaraan seperti kontur dan batas objek menjadi samar, sedangkan noise yang tinggi mendistorsi informasi tekstur yang dibutuhkan model untuk ekstraksi fitur. Akibatnya, model deteksi objek seringkali mengalami kegagalan lokalisasi (bounding box) maupun kesalahan klasifikasi, yang secara kuantitatif terefleksi pada penurunan nilai mean Average Precision (mAP) yang signifikan (Bell et al., 2022; Li et al., 2021).

Upaya untuk mengatasi permasalahan ini umumnya terbagi menjadi dua pendekatan: peningkatan kontras tradisional dan restorasi citra berbasis deep learning. Teknik Contrast Limited Adaptive Histogram Equalization (CLAHE) sering digunakan karena kemampuannya meningkatkan visibilitas secara adaptif. Di sisi lain, CLAHE memiliki kelemahan inheren berupa amplifikasi noise pada area gelap, yang justru dapat membingungkan model deteksi. Di sisi lain, penggunaan model Denoising Autoencoder (DAE) berbasis deep learning efektif dalam membersihkan derau, namun seringkali menghasilkan efek over-smoothing. Proses kompresi data pada area bottleneck arsitektur DAE menyebabkan hilangnya fitur frekuensi tinggi (high-frequency features) seperti tepian tajam

kendaraan, yang sangat krusial bagi mekanisme deteksi YOLOv11 (Lore et al., 2017). Ketidakmampuan metode tunggal dalam menyeimbangkan antara peningkatan kontras dan retensi detail spasial menciptakan celah penelitian yang krusial. Dibutuhkan sebuah pendekatan yang tidak hanya mampu memperjelas objek dalam kegelapan, tetapi juga mampu menjaga kebersihan citra tanpa mengorbankan ketajaman fitur.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan sebuah pipeline prapemrosesan bertingkat (cascaded) yang mengintegrasikan CLAHE dan Convolutional Denoising Autoencoder (CDAE) untuk mengoptimalkan input bagi YOLOv11. Pendekatan ini dirancang secara sistematis: CLAHE digunakan untuk membongkar detail objek yang tersembunyi dalam kegelapan, sementara CDAE bertugas mereduksi amplifikasi noise yang dihasilkan. Sebagai langkah kunci untuk mengatasi masalah over-smoothing dan hilangnya data pada bottleneck DAE, penelitian ini menerapkan teknik fusi citra (Alpha Blending). Teknik ini berfungsi sebagai mekanisme restorasi untuk menyatukan kembali ketajaman fitur dari tahap CLAHE dengan kebersihan visual dari tahap CDAE. Melalui pendekatan integratif ini, diharapkan sistem deteksi kendaraan dapat mencapai tingkat akurasi dan reliabilitas yang lebih tinggi pada kondisi pencahayaan ekstrim.

1.2 Rumusan Masalah

Berdasarkan permasalahan yang ada rumusan masalah yang di dapatkan sebagai berikut :

1. Bagaimana pengaruh kondisi citra *low-light* yang ditandai oleh rendahnya kontras dan tingginya noise terhadap performa deteksi YOLOv11 dalam konteks pendeteksian kendaraan?
2. Bagaimana pendekatan *Cascaded CLAHE* dan *Denoising Autoencoder* yang dioptimasi dengan teknik fusi citra (*Alpha Blending*) mampu meningkatkan kualitas citra *low-light* melalui peningkatan kontras dan reduksi noise secara simultan?

3. Apakah pendekatan *Cascaded CLAHE* dan *Denoising Autoencoder* memberikan peningkatan signifikan terhadap akurasi deteksi YOLOv11 berdasarkan matrik kuantitatif (PSNR, SSIM, mAP50, mAP50–95, *precision*, *recall*)?

1.3 Batasan Penelitian

Penelitian ini dibatasi oleh beberapa aspek sebagai berikut:

1. Ruang Lingkup Data dan Karakteristik Citra: Penelitian ini menggunakan dataset citra CCTV yang bersumber dari satu lokasi pengambilan, yaitu ruas Jalan Tugu Ireng, Kabupaten Magelang, sehingga generalisasi hasil ke lokasi atau karakteristik kamera CCTV lain memerlukan validasi lebih lanjut. Objek deteksi dibatasi pada empat kelas kendaraan (mobil, sepeda motor, bus, dan truk), dengan distribusi kelas yang tidak seimbang (class imbalance) antara Mobil/Motor dan Bis/Truk. Citra yang digunakan juga tidak mencakup kondisi kendaraan bergerak cepat yang menghasilkan efek motion blur signifikan.
2. Metode Peningkatan Citra dan Model Deteksi: Pendekatan peningkatan kualitas citra dibatasi pada kombinasi cascaded CLAHE dan Denoising Autoencoder (DAE) berbasis arsitektur U-Net, tanpa membandingkan secara langsung dengan metode state-of-the-art lain seperti Zero-DCE, Retinex-Net, atau pendekatan berbasis GAN. Model deteksi objek dibatasi pada YOLOv11, dan pengujian dilakukan pada dua skema, yaitu model pretrained COCO tanpa fine-tuning (zero-shot) dan model hasil fine-tuning dengan strategi domain adaptation. Skema pembagian data latih dan uji pada proses fine-tuning tidak dirancang seketat skema pengujian pipeline preprocessing itu sendiri, sehingga hasil pada model fine-tuned diinterpretasikan sebagai bukti pendukung, bukan klaim utama generalisasi model.
3. Parameter Evaluasi dan Lingkup Implementasi Sistem: Evaluasi kualitas citra dibatasi pada metrik PSNR dan SSIM, sedangkan evaluasi performa deteksi dibatasi pada metrik Precision, Recall, dan mAP, tanpa pengujian signifikansi statistik formal terhadap selisih antar-skenario. Pengujian dilakukan pada

citra penuh (full image) tanpa penerapan Region of Interest (ROI) Masking pada tahap evaluasi akhir. Implementasi sistem berupa prototipe backend REST API yang diuji secara fungsional, namun tidak mencakup pengujian performa real-time pada perangkat keras dengan sumber daya terbatas (edge device).

1.4 Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini:

1. Menganalisis citra low-light dan dampaknya terhadap performa deteksi YOLOv11 dalam konteks pendeteksian kendaraan.
2. Mengembangkan dan menerapkan pendekatan *Cascaded* CLAHE dan *Denoising Autoencoder* yang dikombinasikan dengan fusi citra untuk meningkatkan kualitas citra *low-light* secara komplementer.
3. Mengukur efektivitas pendekatan *cascaded* dalam meningkatkan akurasi dan stabilitas deteksi YOLOv11 berdasarkan metrik performa deteksi dan kualitas citra.

1.5 Manfaat Penelitian

Melalui penelitian ini diharapkan memiliki manfaat sebagai berikut:

1. Bagi Akademik

Secara akademis, penelitian ini memberikan kontribusi dalam memperkaya kajian mengenai integrasi metode peningkatan citra berbasis teknik klasik, deep learning dan fusi citra untuk mengatasi permasalahan *over-smoothing* dalam konteks citra *low-light*.

2. Bagi Peneliti

Bagi peneliti, penelitian ini memberikan pengetahuan dan pengalaman dalam membangun *pipeline pre-processing* berbasis *deep learning*, mengolah dataset *low-light*, serta melakukan analisis kinerja model secara kuantitatif.

3. Bagi Instansi Terkait

Bagi instansi atau pihak yang terlibat dalam sistem pengawasan lalu lintas, penelitian ini menawarkan solusi peningkatan akurasi deteksi pada kondisi

malam hari melalui sistem yang efisien dan dapat diintegrasikan dengan infrastruktur CCTV yang telah ada.



BAB 2. TINJAUAN TEORI

2.1 Kajian Literatur

Deteksi kendaraan pada Sistem Transportasi Cerdas (ITS) seringkali menghadapi tantangan degradasi visual pada malam hari. Penurunan kualitas visual ini dibuktikan oleh Bell et al. (2022) dan Fu et al. (2022) sebagai faktor utama yang menyebabkan kegagalan ekstraksi fitur. Kendati algoritma mutakhir seperti YOLOv11 telah dilengkapi dengan fungsi *Distribution Focal Loss* (DFL) yang canggih untuk lokalisasi objek (Weng & Niu, 2025), model ini tetap rentan mengalami misklasifikasi pada kelas kendaraan (Mobil, Motor, Bus, dan Truk) jika tidak dibarengi dengan tahap prapemrosesan citra.



Gambar 2.1 Perbandingan Citra Low-Light dan Normal



Gambar 2.2 Menunjukkan adanya kesalahan klasifikasi kendaraan pada citra



Gambar 2.3 Menunjukkan Class kendaraan

Untuk memulihkan visibilitas, Contrast Limited Adaptive Histogram Equalization (CLAHE) terbukti efektif meningkatkan akurasi deteksi (Yuan et al., 2023), namun memicu amplifikasi derau (noise) pada area gelap (Lashkov et al., 2023). Sebagai solusinya, Denoising Autoencoder (DAE) berbasis deep learning

mampu mereduksi derau secara signifikan (Lore et al., 2017; Li et al., 2023). Teknik fusi citra diterapkan guna menyeimbangkan ketajaman visual dan mencegah hilangnya detail akibat over-smoothing dari DAE (Jin et al., 2024). Sintesis penelitian terdahulu yang mendasari kerangka pemikiran ini dirangkum pada Tabel 2.1 dan Tabel 2.2.

Tabel 2.1 Penelitian Terdahulu

No	Penelitian	Dataset	Metode	Hasil (Performa Deteksi)
1.	Bell et al. (2022)	Menggunakan Dataset Privat /Sendiri berupa rekaman video lalu lintas jalan raya pada malam hari.	<i>Pre-processing:</i> Headlight Detection (deteksi lampu depan) untuk menentukan ROI. <i>Processing:</i> Foveal Classifiers.	Kinerja deteksi kendaraan pada malam hari dapat mengalami degradasi performa yang drastis apabila citra <i>low-light</i> tidak diproses lebih dulu.
2.	Fu et al. (2022)	UA-DETRAC dan BDD100K	<i>Pre-processing:</i> GAN dengan metode transfer gaya "Night-to-Day". <i>Processing:</i> YOLO / Faster R-CNN.	Meningkatkan mAP secara signifikan. Pada dataset UA-DETRAC, akurasi meningkat sekitar 10.2% dibandingkan metode <i>low-light enhancement</i> biasa.
3.	Yuan et al. (2023)	CPLID(Chinese Power Line Insulator Dataset) via Drone	<i>Pre-processing:</i> CLAHE. <i>Processing:</i> YOLOv4 dan YOLOv5.	Penerapan CLAHE terbukti meningkatkan mAP hingga 4-5% dibandingkan menggunakan citra asli (RAW).
4.	Lore et al. (2017)	Dataset Sintetis (siang hari digelapkan + <i>Gaussian noise</i>)	<i>Pre-processing:</i> Stacked Sparse Denoising Autoencoder (SSDA).	Model LLNet (DAE) mampu meningkatkan pencahayaan dan mengurangi <i>noise</i> , serta mempertahankan detail halus lebih baik dibanding metode tradisional.
5.	Penelitian Ini (2026)	CCTV Tugu Ireng (Low-light) dibagi siang & malam. Dataset siang disintesis untuk melatih DAE.	Cascaded CLAHE + DAE (U-Net) + Alpha Blending + YOLOv11	Diharapkan menjaga ketajaman fitur untuk meningkatkan mAP melalui skema <i>zero-shot</i> dan <i>domain adaptation</i> .

Tabel 2.2 Matriks Sintesis Variabel Penelitian

Peneliti (Tahun)	Peningkatan Kontras	Reduksi Noise (DAE)	Deteksi	Fusi Citra
Bell et al. (2022)			V	
Lore et al. (2017)	V	V		

Yuan et al. (2023)	V		V	
Jin et al. (2024)	V			V
Penelitian Ini (2026)	V	V	V	V

Berdasarkan tinjauan penelitian terdahulu pada tabel di atas, terlihat adanya celah penelitian (research gap) yang belum terselesaikan. Penggunaan metode CLAHE secara tunggal masih rentan terhadap amplifikasi noise, sedangkan penggunaan DAE secara tunggal sering memicu hilangnya detail spasial (over-smoothing). Berdasarkan celah tersebut, penelitian ini mengusulkan integrasi metode Cascaded CLAHE dan DAE yang dioptimasi melalui fusi citra (Alpha Blending), guna menyeimbangkan ketajaman kontras dan kebersihan visual sebelum proses deteksi oleh YOLOv11.

2.2 Deteksi Kendaraan

Deteksi kendaraan merupakan komponen penting dalam sistem transportasi cerdas (*Intelligent Transportation Systems / ITS*) untuk memantau lalu lintas dan meningkatkan keselamatan jalan secara otomatis. Dalam bidang *Deep Learning*, algoritma YOLO (*You Only Look Once*) banyak digunakan karena mampu memberikan keseimbangan antara akurasi dan kecepatan deteksi. Keunggulan tersebut dibuktikan oleh Khekare et al. (2025) yang berhasil mengembangkan sistem pemantauan lalu lintas *real-time* dengan akurasi deteksi kendaraan yang tinggi. Berdasarkan data Badan Pusat Statistik (2024), penelitian ini memfokuskan deteksi pada empat kelas kendaraan utama, yaitu mobil, sepeda motor, bus, dan truk, yang mewakili mayoritas kendaraan di jalan raya Indonesia.

2.3 Citra low-light

Citra low-light memiliki karakteristik kontras rendah, tekstur kabur, dan tingkat noise yang tinggi akibat minimnya cahaya yang diterima sensor kamera (Li et al., 2022; Zhao et al., 2024). Pada rekaman CCTV malam hari, kondisi tersebut diperparah oleh efek silau (glare) dari lampu kendaraan yang menutupi detail objek (Bell et al., 2022; Fu et al., 2022). Secara matematis, degradasi citra dijelaskan melalui model Retinex (Wei et al., 2018):

$I(x) = L(x) \cdot R(x) + n(x)$(i)

di mana $I(x)$ merupakan citra hasil tangkapan, $L(x)$ adalah luminansi, $R(x)$ adalah reflektansi objek, dan $n(x)$ adalah noise sensor. Pada kondisi low-light, rendahnya nilai $L(x)$ menyebabkan informasi objek tertutupi oleh noise, sehingga menurunkan kemampuan model YOLO dalam mengekstraksi fitur dan mendeteksi objek. Akibatnya, performa deteksi dapat menurun hingga 40–60% dibandingkan kondisi pencahayaan normal (Jing et al., 2024; Narayanan et al., 2024). Tahap image enhancement pun diperlukan sebelum proses deteksi objek.

2.4 Algoritma Deteksi Objek YOLOv11

You Only Look Once (YOLO) merupakan arsitektur deteksi objek *single-stage* yang cepat dan akurat. YOLOv11 mengadopsi pendekatan *anchor-free* dan memisahkan tugas klasifikasi serta regresi melalui *decoupled head* (Weng & Niu, 2025). Kendati dilengkapi dengan fitur ekstraksi tingkat lanjut seperti blok C3k2, performa YOLOv11 sangat bergantung pada visibilitas tepi dan tekstur spasial citra masukan.

2.5 prapemrosesan *Region of Interest (ROI) Masking*

Region of Interest (ROI) Masking adalah teknik lokalisasi piksel yang membatasi area komputasi hanya pada wilayah yang memuat informasi relevan pada area jalan raya (Bell et al., 2022). Pada rekaman CCTV pemantauan lalu lintas, seringkali terdapat overlay teks bawaan (*timestamp*). Keberadaan teks ini dapat memicu bias fitur (*feature bias*) di mana model *deep learning* salah menginterpretasikan pola teks sebagai bagian dari objek kendaraan, yang berujung pada tingginya False Positive (Fu et al., 2022; Khekare et al., 2025).

2.6 *Contrast Limited Adaptive Histogram Equalization (CLAHE)*

CLAHE meratakan histogram secara adaptif pada pembagian *tile* kecil citra (Yuan et al., 2023). Guna mencegah amplifikasi derau (*noise*) yang berlebihan pada area gelap, CLAHE memotong puncak histogram melalui parameter *clip limit*. Mekanisme pembatasan ini dirumuskan sebagai:

$$H_{clipped}(i) = \min(H(i), C_{limit}) \dots \dots \dots (ii)$$

Dengan $H(i)$ melambangkan histogram asli dan C_{limit} sebagai nilai batas amplifikasi maksimum. Piksel yang telah dipotong kemudian didistribusikan

ulang menggunakan fungsi distribusi kumulatif (*Cumulative Distribution Function/CDF*) adaptif pada setiap *tile* untuk menghasilkan intensitas keluaran:

$$I_{out}(x) = CDF_{tile}(I_{in}(x)) \cdot (L - 1) \dots \dots \dots (iii)$$


Penerapan CLAHE secara spesifik difokuskan pada kanal *Lightness* (L) dalam ruang warna LAB. Pendekatan ini terbukti efektif untuk meningkatkan kontras pencahayaan lokal tanpa mendistorsi komponen krominansi atau warna asli objek (Lashkov et al., 2023). Guna memastikan parameter *clip limit* tidak ditentukan secara acak, penelitian ini menerapkan metode *Grid Search Optimization*, yaitu algoritma evaluasi sistematis untuk menemukan konfigurasi hiperparameter yang menghasilkan kualitas citra paling optimal.

2.7 Denoising Autoencoder (DAE) Berbasis Arsitektur U-Net

Denoising Autoencoder (DAE) adalah jaringan saraf tiruan yang memetakan citra bising ($y = x + n$) untuk merekonstruksi citra bersih ($\{\hat{x}\}$) secara laten (Gondara, 2016). Model dilatih dengan meminimalkan fungsi kerugian rekonstruksi berbasis jarak Euclidean kuadrat (L2 Norm):

$$(L(\theta) = ||x - \{\hat{x}\}||_2^2) \dots \dots \dots (iv)$$

Dengan mengoptimalkan parameter bobot jaringan θ hingga nilai selisih piksel minimum, DAE mampu menekan noise intensitas tinggi secara agresif tanpa mengaburkan fitur pendeteksi tepi (*edge detectors*). Kapasitas ini menjadikannya solusi ideal untuk memitigasi efek amplifikasi noise pasca-proses CLAHE (Lore et al., 2017). Penelitian ini mengimplementasikan DAE menggunakan arsitektur U-Net (Zhu et al., 2025). Kekuatan utama arsitektur ini terletak pada Skip Connections, yaitu jalur pintas yang mengalirkan detail spasial resolusi tinggi langsung dari *Encoder* ke *Decoder*. Mekanisme ini krusial untuk mencegah hilangnya batas struktur bodi kendaraan saat melewati kompresi *bottleneck*, sehingga menekan efek *over-smoothing*. Arsitektur ini juga menerapkan Group Normalization untuk mempertahankan stabilitas perhitungan varians secara akurat ketika model dilatih menggunakan ukuran batch yang kecil.



Gambar 2.4: Arsitektur U-Net dengan Skip Connections Sumber (Medium)

2.8 Multi-Component Loss Function (MSE, SSIM, dan *Perceptual Loss* VGG-16)

Fungsi kerugian (loss function) dalam penelitian ini digabungkan dari tiga matrik evaluasi. Pertama, *Mean Squared Error* (MSE) digunakan untuk menghitung selisih matematis warna piksel antara prediksi dan target. Kedua, *Structural Similarity Index* (SSIM) mengevaluasi kesamaan pencahayaan, kontras, dan struktur spasial. Ketiga, *Perceptual Loss* menghitung selisih *Feature Map* menggunakan model *pre-trained* VGG-16. Fungsi ini memaksa DAE untuk mempertahankan "pemahaman bentuk" seperti batas kontur kendaraan, bukan sekadar mencocokkan warna piksel secara seragam (Gondara, 2016; Lore et al., 2017).

2.9 Teknik Fusi Citra (Alpha Blending)

Fusi citra secara matematis digunakan untuk menyeimbangkan ketajaman kontras dari keluaran CLAHE dan kebersihan noise dari keluaran DAE (Yuan et al., 2023). Persamaan dasar alpha blending yang digunakan adalah:

$$I_{final} = (\alpha \cdot I_{DAE}) + ((1 - \alpha) \cdot I_{CLAHE}) \dots\dots\dots(v)$$

Di mana I_{final} adalah citra hasil fusi dan α adalah bobot rasio *blending*. Sinergi ini memastikan YOLOv11 menerima input dengan keseimbangan antara ketajaman kontras dan kebersihan visual (Jin et al., 2024; Lashkov et al., 2023).

2.10 Sintesis Citra, *Domain Adaptation*, dan Penanganan *Class Imbalance*

Guna melatih DAE, citra siang hari disimulasikan menjadi malam hari melalui manipulasi *Gamma Correction* (menurunkan luminansi) dan penambahan *Gaussian/Poisson Noise* (menyimulasikan derau sensor). Proses prapemrosesan

matematis ini mengubah distribusi statistik piksel menjadi tekstur semi-artifisial, yang menyebabkan terjadinya pergeseran domain data atau *Domain Shift* (Wei et al., 2018). Berdasarkan hal tersebut, diperlukan *Domain Adaptation* berupa pelatihan ulang (retraining) bobot YOLOv11 menggunakan dataset low-light hasil prapemrosesan tersebut agar mampu beradaptasi pada kondisi malam hari (Weng & Niu, 2025; Zhao et al., 2024). Teknik *Oversampling* diterapkan dengan menduplikasi data kelas minoritas untuk menghindari bias model akibat dominasi kelas tertentu, teknik *Oversampling* diterapkan dengan menduplikasi data kelas minoritas (Bus dan Truk) agar distribusi kelas (*Class Imbalance*) menjadi seimbang.

2.11 Metrik Evaluasi Kualitas Citra dan Deteksi

Kualitas citra hasil peningkatan (*enhancement*) dan performa deteksi objek dievaluasi menggunakan serangkaian metrik standar. Penggunaan metrik ini selaras dengan studi terbaru (Zhao et al., 2024; Jing et al., 2024). Penggunaan metrik ini diselaraskan dengan studi terbaru (Zhao et al., 2024; Jing et al., 2024) guna memastikan perbaikan visual berkorelasi positif dengan akurasi model YOLOv11. . *Peak Signal-to-Noise Ratio* (PSNR) digunakan untuk mengukur tingkat distorsi atau *noise* pada citra hasil rekonstruksi DAE dibandingkan dengan citra referensi (bersih). Nilai PSNR yang lebih tinggi mengindikasikan kualitas rekonstruksi yang lebih baik.

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX_1^2}{MSE} \right) \dots\dots\dots(vi)$$

di mana MAX_i^2 adalah nilai piksel maksimum citra (biasanya 255 untuk citra 8-bit), dan *Mean Squared Error* (MSE) didefinisikan sebagai:

$$MSE = \frac{1}{M \cdot N} \sum_{i=1}^M \sum_{j=1}^N [I(i, j) - K(i, j)]^2 \dots\dots\dots(vii)$$

Keterangan: $M \cdot N$: Dimensi lebar dan tinggi citra. $I(i, j)$: Nilai piksel citra referensi (ground truth/normal light). $K(i, j)$: Nilai piksel citra hasil pemrosesan (enhanced).

Structural Similarity Index Measure (SSIM) mengukur kemiripan struktural antara dua citra berdasarkan luminansi, kontras, dan struktur. Metrik ini

lebih relevan daripada PSNR untuk menilai persepsi visual manusia dan keutuhan bentuk objek pasca-proses CLAHE.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \dots\dots\dots(viii)$$

Keterangan: μ_x, μ_y : Nilai rata-rata intensitas citra x dan y., σ_x^2, σ_y^2 :

Varian dari citra x dan y. $\sigma_{\{xy\}}$: Kovarian antara citra x dan y. C_1, C_2 : Konstanta untuk menstabilkan pembagian saat penyebut mendekati nol.

Metrik Deteksi Objek (Precision, Recall, dan mAP) Untuk mengevaluasi kinerja YOLOv11, digunakan metrik berdasarkan *Confusion Matrix*:

Precision: Mengukur seberapa akurat prediksi positif model (misal: seberapa banyak deteksi "mobil" yang benar-benar mobil).

$$Precision = \frac{TP}{TP + FP} \dots\dots\dots(ix)$$

Recall: Mengukur kemampuan model menemukan seluruh objek yang ada (misal: dari 100 mobil, berapa yang berhasil dideteksi).

$$Recall = \frac{TP}{TP + FN} \dots\dots\dots(x)$$

Keterangan: TP (*True Positive*): Objek terdeteksi dengan benar ($IoU > threshold$). FP (*False Positive*): Deteksi salah (latar belakang dideteksi sebagai objek). FN (*False Negative*): Objek yang gagal dideteksi.

mean Average Precision (mAP): Merupakan rata-rata dari *Average Precision* (AP) seluruh kelas, yang memberikan gambaran menyeluruh tentang akurasi model pada berbagai ambang batas (*threshold*).

$$mAP = \frac{1}{N_{class}} \sum_{i=1}^{N_{class}} AP_i \dots\dots\dots(xi)$$

Dalam penelitian ini, metrik utama yang digunakan adalah mAP@0.5 (mAP pada IoU threshold 0.5) dan mAP@0.5:0.95 untuk mengukur ketepatan lokasi *bounding box* pada kondisi minim cahaya.

BAB 3. METODOLOGI PENELITIAN

3.1 Jenis Penelitian

Penelitian ini termasuk dalam jenis penelitian kuantitatif dengan pendekatan eksperimental. Pendekatan kuantitatif digunakan karena penelitian ini melibatkan pengukuran numerik menggunakan matrik evaluasi yang terstandar, seperti *Peak Signal-to-Noise Ratio* (PSNR), *Structural Similarity Index Measure* (SSIM), *mean Average Precision* (mAP), *precision*, dan *recall*.

3.2 Objek Penelitian


Objek penelitian pada penelitian ini adalah citra lalu lintas yang diperoleh dari rekaman CCTV publik. Dataset berasal dari siaran kamera lalu lintas yang tersedia secara daring melalui kanal youtube Dinas Perhubungan Kabupaten Magelang Tugu Ireng. Data dikumpulkan selama 24 sampai 48 jam.

3.3 Waktu Penelitian

Penelitian ini dilaksanakan secara daring. Proses pengumpulan data, pengolahan citra, pelatihan model, serta evaluasi performa dilakukan dalam kurun waktu kurang lebih empat bulan.

3.4 Tahapan penelitian

Tahapan penelitian menggambarkan alur kerja penelitian yang dilakukan secara sistematis sebagaimana ditunjukkan pada Gambar 3.1, yang terdiri dari beberapa tahapan sebagai berikut.




Gambar 3.1 Tahapan Penelitian

3.4.1. Pengumpulan Dataset

Dataset penelitian merupakan data sekunder yang diperoleh dari rekaman CCTV publik melalui kanal YouTube Dinas Perhubungan Kabupaten Magelang di ruas Jalan Tugu Ireng. Video diekstraksi menggunakan teknik frame sampling

sehingga menghasilkan 2.000 citra berformat .jpg. Sebanyak 1.400 citra siang digunakan sebagai data latih dengan mensintesisnya menjadi citra low-light melalui empat tahap, yaitu *Gamma Darkening*, simulasi *glare*, penambahan Poisson dan Gaussian noise, serta kompresi JPEG artifact. Citra siang asli digunakan sebagai *ground truth*, sedangkan citra sintetis menjadi input untuk melatih Denoising Autoencoder (DAE). Di sisi lain, 600 citra malam asli digunakan sebagai data uji yang dianotasi secara manual dalam format YOLO untuk mengevaluasi performa deteksi kendaraan.



Gambar 3.2 Perbandingan karakteristik dataset: (a) Citra Siang Asli (*Ground Truth DAE*), (b) Citra Siang Sintetis (*Input Training DAE*), dan (c) Citra Malam Asli (*Data Testing YOLOv11*)

3.4.2. Preprocessing Dataset

Sebelum pelatihan dan pengujian, seluruh citra melalui tahap preprocessing. Sebanyak 1.400 citra siang digunakan untuk melatih DAE dengan pembagian 80% data pelatihan dan 20% data validasi (random seed 42), sedangkan 600 citra malam asli digunakan sebagai test set YOLOv11. Seluruh citra diubah ukurannya menjadi 640×360 piksel, kemudian citra uji dianotasi secara manual untuk empat kelas kendaraan (mobil, sepeda motor, bus, dan truk) menggunakan format YOLO.

3.4.3. Pelatihan Model Denoising Autoencoder

Setelah pembagian dataset, model *Denoising Autoencoder* (DAE) dilatih menggunakan 1.400 citra. Citra siang asli digunakan sebagai ground truth, sedangkan citra low-light sintetis digunakan sebagai masukan (input). Proses pelatihan bertujuan agar DAE mampu mempelajari karakteristik noise dan merekonstruksi citra yang lebih bersih sehingga dapat digunakan pada tahap pengujian.

3.4.4. Peningkatan Kontras Menggunakan CLAHE

Tahap selanjutnya adalah peningkatan kontras citra low-light menggunakan *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Metode ini bertujuan untuk memperbaiki distribusi luminansi dan meningkatkan visibilitas struktur objek pada area gelap dengan cara meningkatkan kontras secara lokal (Yuan et al., 2023). Hiperparameter yang digunakan pada tahap ini ditetapkan sebesar clipLimit = 1.0 dan tileGridSize = (16×16) guna memastikan noise tidak teramplifikasi secara berlebihan. Output dari tahap ini adalah citra dengan kontras yang lebih baik, namun masih mengandung noise yang relatif tinggi.

3.4.5. Reduksi Noise Menggunakan Denoising Autoencoder

Citra hasil CLAHE kemudian diproses menggunakan Denoising Autoencoder (DAE) berarsitektur U-Net untuk mereduksi noise yang muncul akibat kondisi pencahayaan rendah maupun akibat peningkatan kontras (Gondara, 2016). DAE bekerja dengan merekonstruksi citra yang lebih bersih tanpa menghilangkan detail struktural penting (Lore et al., 2017). Sebagai langkah optimasi, tahap ini menerapkan teknik fusi Alpha Blending dengan hiperparameter rasio ($\alpha = 0.3$) untuk menyeimbangkan ketajaman kontras keluaran CLAHE dan kebersihan visual keluaran DAE (Jin et al., 2024; Lashkov et al., 2023). Hasil dari tahap ini disebut sebagai citra enhanced Cascaded CLAHE–DAE.

3.4.6. Evaluasi Kualitas Citra

Evaluasi kualitas citra dilakukan pada citra *enhanced* CLAHE–DAE dengan menggunakan metrik *Peak Signal-to-Noise Ratio* (PSNR) dan *Structural Similarity Index Measure* (SSIM). Tahap ini bertujuan untuk mengukur peningkatan kualitas citra berhasil dicapai sebelum citra digunakan.

3.4.7. Deteksi Objek Menggunakan YOLOv11

Citra low-light dan citra hasil enhancement CLAHE–DAE digunakan sebagai input pada proses deteksi kendaraan menggunakan YOLOv11. Kinerja model dievaluasi dengan membandingkan hasil deteksi pada skenario SC-01

hingga SC-04 untuk menganalisis pengaruh setiap metode enhancement terhadap akurasi deteksi.

3.4.8. Evaluasi Performa Deteksi

Evaluasi sistem dilakukan berdasarkan skenario pengujian pada Tabel 3.1. Kinerja sistem diukur menggunakan metrik PSNR dan SSIM untuk menilai kualitas citra, serta Precision, Recall, mAP@0.5, dan mAP@0.5:0.95 untuk mengevaluasi performa deteksi YOLOv11. Hasil evaluasi digunakan untuk membandingkan kinerja pada citra low-light asli dan citra hasil enhancement CLAHE-DAE.

Tabel 3.1 Tabel Skenario Pengujian

ID Skenario	Nama Skenario	Deskripsi Proses	Input & Tujuan Pengujian	Metrik Evaluasi
SC-01	Baseline (Raw)	Citra low-light asli dimasukkan langsung ke YOLOv11 tanpa peningkatan kualitas.	Menetapkan tolok ukur (benchmark) kinerja awal pada kondisi gelap alami.	Metrik Deteksi: Precision, Recall, mAP@0.5, mAP@0.5:0.95
SC-02	CLAHE Only	Citra hanya diproses menggunakan CLAHE (Kanal L pada ruang warna LAB), lalu dideteksi.	Menganalisis peningkatan secara tunggal terhadap akurasi deteksi.	Metrik Citra:PSNR, SSIM Metrik Deteksi:Precision, Recall, mAP
SC-03	DAE Only	Citra hanya diproses menggunakan Denoising Autoencoder (DAE) untuk reduksi noise, lalu dideteksi.	Menganalisis penghilangan noise secara tunggal terhadap akurasi deteksi.	Metrik Citra:PSNR, SSIM Metrik Deteksi:Precision, Recall, mAP
SC-04	Proposed Method (Cascaded)	Citra diproses bertahap: CLAHE → DAE, kemudian dideteksi oleh YOLOv11.	Membuktikan bahwa kombinasi peningkatan kontras dan reduksi noise memberikan akurasi deteksi dan kualitas visual terbaik.	Metrik Citra:PSNR, SSIM Metrik Deteksi:Precision, Recall, mAP@0.5, mAP@0.5:0.95

BAB 4. HASIL DAN PEMBAHASAN

4.1 Hasil Penelitian

Hasil penelitian ini menyajikan evaluasi bertahap terhadap efektivitas sistem prapemrosesan citra low-light. Pengujian dilakukan pada 594 citra malam asli dari rekaman CCTV Tugu Ireng menggunakan dua model pembanding: (1) COCO Baseline YOLOv11-Large dengan bobot pretrained COCO, dan (2) SC04 Retrained YOLOv11 yang dilatih ulang menggunakan dataset malam sintesis. Arsitektur YOLOv11-Large yang digunakan pada kedua skema tersebut memiliki jumlah parameter yang identik, yaitu 25.372.160 parameter (trainable parameters).

Tabel 4.0 Ringkasan Tiga Model yang Diuji dalam Penelitian

Model	Peran	Arsitektur	Jumlah Parameter	Metrik Utama	Hasil Terbaik (SC-04)
Denoising Autoencoder (DAE)	Reduksi noise pada tahap prapemrosesan citra	U-Net + Group Normalization	1.885.827	PSNR / SSIM	22,27 dB / 0,9471
YOLOv11 COCO Baseline	Deteksi kendaraan (zero-shot, tanpa fine-tuning)	YOLOv11-Large pretrained COCO	25.372.160	mAP@0.5	0,2147
YOLOv11 Retrained	Deteksi kendaraan (fine-tuned, domain adaptation)	YOLOv11-Large fine-tuned	25.372.160	mAP@0.5	0,4631

Ketiga model tersebut memiliki peran yang saling melengkapi dalam pipeline penelitian: DAE bertugas memulihkan kualitas citra pada tahap prapemrosesan, sedangkan YOLOv11 COCO Baseline dan YOLOv11 Retrained merupakan dua skema evaluasi deteksi yang digunakan untuk mengukur dampak pipeline prapemrosesan pada kondisi model generik (zero-shot) maupun model yang telah diadaptasi ke domain malam hari. *) Hasil pada YOLOv11 Retrained perlu diinterpretasikan dengan hati-hati mengingat potensi data leakage sebagaimana dijelaskan pada Subbab 4.2.5, sehingga hasil pada COCO Baseline tetap menjadi rujukan utama untuk menjawab rumusan masalah penelitian.

4.1.1. Pengumpulan Dataset

Dataset yang digunakan terdiri dari 2.000 citra yang dikumpulkan dari rekaman CCTV publik Tugu Ireng, Kabupaten Magelang. Distribusi dataset adalah sebagai berikut:

Tabel 4.1 Distribusi Dataset Penelitian

Subset	Jumlah Citra	Kondisi	Penggunaan
Siang Asli	1.400	Normal (clean)	Target (ground truth) pelatihan DAE
Siang Sintetis	1.400	Disintesis low-light menjadi	Input pelatihan DAE
Malam Asli	600	Low-light nyata	Data uji YOLOv11 (tidak pernah dilihat model)

Tabel 4.2 Distribusi Objek Kendaraan pada Data Uji (594 Citra)

Kelas	Jumlah Objek	Proporsi
Mobil	2.428	53.1%
Motor	2.015	44.1%
Truk	109	2.4%
Bis	18	0.4%
Total	4.570	100%

Dari 1.400 citra pelatihan DAE, dibagi secara internal menggunakan rasio 80:20 (seed=42) menjadi 1.120 citra training dan 280 citra validasi. Distribusi kelas kendaraan pada 600 citra uji malam menunjukkan ketidakseimbangan (class imbalance) yang signifikan, dengan dominasi kelas Mobil dan Motor dibandingkan Bus dan Truk.

Dominasi kelas Mobil dan Motor (97.2% dari total objek) dan sangat sedikitnya kelas Bis (hanya 18 instansi) menjadi konteks penting dalam interpretasi hasil evaluasi per kelas.

4.1.2. *Preprocessing Dataset*

Seluruh citra hasil pengumpulan data melalui tahap preprocessing sebelum digunakan untuk pelatihan maupun pengujian. Sebanyak 1.400 citra siang dibagi menjadi 1.120 citra untuk pelatihan DAE dan 280 citra untuk validasi DAE, menggunakan rasio 80:20 dengan random seed 42. Sementara itu, 600 citra malam asli disiapkan sebagai data uji YOLOv11, dengan 594 citra dinyatakan valid setelah proses anotasi manual. Seluruh citra pada penelitian ini diseragamkan resolusinya menjadi 640×360 piksel sesuai aspek rasio kamera

CCTV asli. Data uji kemudian dianotasi secara manual untuk empat kelas kendaraan (mobil, sepeda motor, bus, dan truk) menggunakan format YOLO, menghasilkan distribusi kelas yang tidak seimbang (class imbalance) dengan dominasi kelas Mobil dan Motor.

Secara khusus, proses sintesis citra malam dari 1.400 citra siang dilakukan melalui empat tahap dengan parameter acak (random) agar setiap citra memiliki variasi degradasi yang realistis, yaitu: (1) Gamma Darkening dengan nilai gamma acak 2,8–3,2 untuk penggelapan non-linear; (2) simulasi glare berupa 1–3 titik lampu jalan dan 0–2 titik lampu kendaraan yang disebar menggunakan fungsi Gaussian; (3) penambahan Poisson noise (skala 0,001–0,005) dan Gaussian noise (σ 0,002–0,01) untuk mensimulasikan derau sensor CCTV; serta (4) kompresi JPEG dengan kualitas acak 45–72% untuk mensimulasikan artefak transmisi video CCTV. Variasi acak pada keempat tahap ini bertujuan agar model DAE terpapar kombinasi degradasi yang beragam sebelum diuji pada citra malam asli.

4.1.3. *Pelatihan Model Denoising Autoencoder*

Pemilihan arsitektur Denoising Autoencoder (DAE) pada penelitian ini difokuskan pada kemampuan model dalam menjaga integritas fitur spasial. Arsitektur U-Net dipilih mengungguli autoencoder standar karena memiliki mekanisme skip connections. Mekanisme ini berfungsi mengalirkan informasi spasial frekuensi tinggi (seperti detail tepi atau edges kendaraan) secara langsung dari encoder ke decoder, sehingga secara efektif mencegah hilangnya informasi visual yang krusial saat data melewati fase kompresi di bottleneck.

Selanjutnya, untuk optimasi normalisasi lapisan, dilakukan eksperimen studi ablasi (*ablation study*) yang membandingkan performa Group Normalization dan Instance Normalization (merujuk pada implementasi skrip `trainDAE.py` dan `trainDAEInstance.py`). Berdasarkan hasil observasi, Group Normalization (dengan pengaturan 8 grup) ditetapkan sebagai konfigurasi definitif.

Keputusan ini didasari oleh kemampuannya dalam menghasilkan stabilitas training yang jauh lebih konsisten pada citra CCTV beresolusi 640×360 piksel dengan ukuran batch (batch size) yang kecil, yakni 4. Berbeda dengan Batch Normalization yang kinerjanya merosot tajam pada batch kecil, atau *Instance*

Normalization yang terlalu bergantung pada statistik individual per gambar, Group Normalization menghitung statistik normalisasi berdasarkan subkelompok kanal. Pendekatan ini terbukti mampu menghasilkan aliran gradien yang lebih stabil selama proses optimasi. Paduan arsitektur U-Net dengan Group Normalization pun dipertahankan sebagai model definitif dalam pipeline prapemrosesan ini. Dari sisi kompleksitas komputasi, arsitektur U-Net yang digunakan pada model DAE ini tergolong ringan, dengan total 1.885.827 parameter (trainable parameters) — jauh lebih kecil dibandingkan model deteksi YOLOv11-Large, sehingga tidak membebani proses inferensi secara signifikan.

4.1.4. Hasil Pelatihan Model DAE

Model DAE dilatih selama 150 epoch dengan Early Stopping (patience=20). Konvergensi terbaik tercatat pada epoch ke-128 dengan:

Tabel 4.3 Ringkasan Hasil Pelatihan DAE

Parameter	Nilai
Optimizer	AdamW ($lr=1\times10^{-4}$, $wd=1\times10^{-4}$)
Loss Function	$0.4\times\text{MSE} + 0.3\times\text{SSIM} + 0.3\times\text{Perceptual (VGG-16)}$
Train Loss Awal → Akhir	$0.5438 \rightarrow 0.3711$
Val Loss Terbaik	0.3673
PSNR Validasi Terbaik	28.11 dB
Scheduler	Cosine Annealing LR ($\eta_{\min}=1\times10^{-6}$)

Nilai PSNR validasi 28.11 dB melampaui ambang batas kualitas restorasi yang umumnya diterima (≥ 28 dB) dan membuktikan bahwa DAE berhasil merekonstruksi citra sintetis low-light mendekati kualitas citra siang aslinya.

4.1.5. Peningkatan Kontras Menggunakan CLAHE

Nilai parameter utama pada pipeline prapemrosesan, yaitu clip limit pada CLAHE dan bobot alpha pada DAE, tidak ditentukan secara acak. Parameter tersebut dioptimasi melalui metode *Grid Search* sistematis menggunakan implementasi skrip `tuning_sc04.py`. Pengujian ini mengevaluasi 50 kombinasi

yang terdiri dari 5 variasi nilai clip limit (1.0, 2.0, 3.0, 4.0, 6.0), 5 variasi nilai alpha (0.3, 0.5, 0.7, 0.9, 1.0), serta 2 skenario urutan prapemrosesan (CLAHE-*first* vs DAE-*first*). Seluruh kombinasi tersebut kemudian divalidasi dan dievaluasi efektivitasnya terhadap skor metrik mAP@0.5.

Hasil pengujian *Grid Search* menetapkan konfigurasi paling optimal pada skenario urutan CLAHE → DAE (*clahe_first*) dengan nilai clipLimit = 1.0 dan alpha = 0.3. Pemilihan nilai clip limit yang rendah (1.0) terbukti efektif untuk menghindari terjadinya amplifikasi derau (noise) yang berlebihan pada area gelap.

4.1.6. Reduksi Noise Menggunakan Denoising Autoencoder

Adapun penetapan alpha = 0.3 menunjukkan bahwa fusi citra mempertahankan 70% detail karakteristik kontras dari keluaran CLAHE dan hanya mengaplikasikan 30% efek pemulusan (smoothing) dari keluaran DAE. Proporsi keseimbangan ini sangat krusial untuk menjaga ketajaman batas tepi (edges) objek kendaraan agar tidak terlalu terhaluskan selama proses rekonstruksi berlangsung.

4.1.7. Evaluasi Kualitas Citra

Kualitas restorasi diukur terhadap 594 citra uji malam asli menggunakan metrik PSNR dan SSIM:

Tabel 4.4 Perbandingan Rata-rata PSNR dan SSIM pada Data Uji

Skenario	Tahapan Prapemrosesan	PSNR (dB)	SSIM
SC-01	Citra Asli (<i>Baseline</i>)	—	1.0000
SC-02	CLAHE Only	20.2790	0.8040
SC-03	DAE Only	16.3053	0.8001
SC-04	CLAHE → DAE (Cascaded)	22.2719	0.9471



Gambar 4.x Perbandingan Visual Tahapan Studi Ablasi: (a) Citra Malam Asli/SC-01, (b) Hasil CLAHE/SC-02, (c) Hasil DAE Murni/SC-03, (d) Hasil Fusi Cascaded/SC-04.

Guna memvalidasi kontribusi spesifik dari masing-masing modul prapemrosesan terhadap kinerja deteksi akhir, dilakukan studi ablasi yang mengisolasi setiap tahapan. Gambar 4.x mengilustrasikan dampak visual dari setiap skenario eksperimen terhadap satu sampel citra yang sama. Skenario SC-01 (Citra Asli): Sebagaimana terlihat pada Gambar 4.x (a), citra bawaan memiliki rasio kontras yang sangat rendah. Keterbatasan rentang dinamis ini menyamarkan fitur struktural kendaraan sehingga sulit dibedakan dari latar belakang (aspal dan pepohonan), yang pada akhirnya menghambat YOLOv11 dalam melakukan ekstraksi fitur secara optimal. Skenario SC-02 (Ablasi CLAHE): Pada Gambar 4.x (b), penerapan modul CLAHE secara tunggal terbukti secara agresif membongkar detail objek di area gelap. Siluet dan tepian kendaraan menjadi jauh lebih tegas. Meskipun demikian, sifat adaptif algoritma ini secara bersamaan memicu amplifikasi profil noise yang ekstrem. Distorsi berbentuk bintik kasar (grain) ini justru berisiko merusak pola tekstur asli dan membingungkan mekanisme klasifikasi model deteksi. Skenario SC-03 (Ablasi DAE): Pada Gambar 4.x (c), penggunaan Denoising Autoencoder secara mandiri terbukti sangat superior dalam mereduksi noise. Citra terlihat sangat bersih dan halus. Namun, ketiadaan modul peningkatan kontras menyebabkan fitur frekuensi tinggi (tepi tajam dan batas bounding box ideal kendaraan) terdegradasi. Efek over-smoothing ini secara kuantitatif terbukti fatal karena menurunkan nilai mAP menjadi 0.1367 (terendah dari semua pengujian).


Skenario SC-04 (Pipeline Cascaded CLAHE-DAE): Gambar 4.x (d) merepresentasikan solusi definitif dari arsitektur yang diusulkan. Melalui integrasi Alpha Blending ($\alpha=0.3$), kelemahan dari metode tunggal berhasil dieliminasi. Output akhir mampu mempertahankan ketajaman kontur kendaraan hasil ekstraksi CLAHE, sembari mengadopsi tingkat kebersihan ruang spasial (spatial domain) yang dihasilkan oleh proses rekonstruksi DAE. perbandingan visual dan metrik evaluasi dari studi ablasi ini, dapat ditarik kesimpulan bahwa ketiadaan salah satu dari dua komponen utama (CLAHE atau DAE) akan mendisrupsi keseimbangan representasi fitur, sehingga membuktikan urgensi dari arsitektur cascaded yang diusulkan.

4.1.8. Deteksi Objek Menggunakan YOLOv11


Pengujian deteksi objek dirancang secara komprehensif untuk mengukur efektivitas metode prapemrosesan yang diusulkan (proposed method) dalam memitigasi efek *Domain Gap*. Eksperimen dilakukan pada dua skema konfigurasi arsitektur YOLOv11-*Large* untuk melihat bagaimana metode prapemrosesan berinteraksi dengan tingkat adaptasi model yang berbeda:

- *COCO Baseline (Zero-Shot Inference)*: Model bawaan (*pretrained COCO*) yang digunakan tanpa proses *fine-tuning*. Skema ini bertujuan menguji fleksibilitas metode prapemrosesan sebagai solusi *plug-and-play* yang mampu memperbaiki kualitas fitur visual secara instan agar model dapat bekerja pada kondisi malam tanpa memerlukan pelatihan ulang.
- *Retrained Model (Domain Adaptation)*: Model yang melalui proses *fine-tuning* sistematis menggunakan strategi *Domain Adaptation* (kombinasi citra siang, citra sintetis, dan sampel citra malam asli). Skema ini dilakukan untuk memvalidasi apakah metode prapemrosesan tetap memberikan kontribusi akurasi tambahan bahkan pada model yang sudah dioptimasi secara khusus untuk lingkungan malam hari.

Performa keseluruhan dari kedua skema ini diukur menggunakan *confidence threshold* 0.05 dan *IoU* 0.5. Metrik evaluasi yang meliputi *mAP@0.5*, *Precision*, dan *Recall* disajikan secara terpadu pada Tabel 4.5. Selain itu, stabilitas model selama proses *fine-tuning* dan efektivitas deteksi divisualisasikan melalui kurva *Precision-Recall* pada Gambar 4.1 serta kurva *F1-Confidence* pada Gambar 4.2.



Gambar 4.1 Kurva Precision-Recall Model YOLO Retrain



Gambar 4.2 Kurva F1-Confidence Model YOLO Retrain

4.1.9. Evaluasi Performa Deteksi

Tabel 4.5 Perbandingan Metrik Deteksi (mAP@0.5, Precision, Recall)
Berdasarkan Skenario

Metrik	Skenario	COCO Baseline	Retrain
mAP@0.5	SC01_Raw	0.2145	0.4596
	SC02_CLAHE	0.1834	0.4004
	SC03_DAE	0.1367	0.3604
	SC04_Cascaded	0.2147	0.4631
Precision	SC01_Raw	0.3297	0.4765
	SC02_CLAHE	0.2974	0.3043
	SC03_DAE	0.2196	0.3945
	SC04_Cascaded	0.3250	0.4600
Recall	SC01_Raw	0.1521	0.4284
	SC02_CLAHE	0.1525	0.3199
	SC03_DAE	0.0997	0.3165
	SC04_Cascaded	0.1555	0.4491

Untuk memahami kontribusi deteksi secara lebih spesifik, performa mAP@0.5 dipecah berdasarkan kelas kendaraan uji yang disajikan pada Tabel 4.6.

Tabel 4.6 Evaluasi Per Kelas mAP@0.5

Skenario	Kelas	COCO Baseline	Retrain
SC01_Raw	Bis	0.0548	0.5456
	Mobil	0.3214	0.5884


Skenario	Kelas	COCO Baseline	Retrain
SC04_Cascaded	Motor	0.4168	0.3762
	Truk	0.0648	0.3281
	Bis	0.0380	0.5663
	Mobil	0.3281	0.5831
	Motor	0.4329	0.3702
	Truk	0.0596	0.3329

4.1.10. Visualisasi Perbandingan Kualitatif SC-01 vs SC-04

Selain evaluasi kuantitatif, dilakukan analisis kualitatif melalui visualisasi 4-panel yang membandingkan citra asli (SC-01), citra enhanced (sebelum deteksi SC-04), hasil deteksi SC-04, dan *Difference Heatmap* yang memperbesar perbedaan piksel $5\times$ untuk menunjukkan area yang terpengaruh prapemrosesan.

Gambar 4.3 Visualisasi perbandingan SC-01 vs SC-04 pada kondisi citra dengan *brightness* rendah (54.1/255). Panel kiri: SC-01 mendeteksi 1 mobil ($\text{conf}=0.48$). Panel kanan: SC-04 berhasil mendeteksi 2 kendaraan 1 mobil dan 1 motor yang tidak terdeteksi sebelumnya. *Heatmap* bawah menunjukkan area merah/kuning (area ter-enhance CLAHE) dan biru (*noise* ditekan DAE).


Secara metodologis, difference heatmap pada Gambar 4.3 diperoleh dari selisih absolut (absolute pixel difference) antara citra sebelum dan sesudah proses enhancement, yang kemudian diperbesar $5\times$ agar perbedaan intensitas yang halus dapat teramati secara visual. Warna merah–kuning menunjukkan perubahan intensitas piksel yang besar akibat peningkatan kontras oleh CLAHE, sedangkan warna biru menunjukkan perubahan yang relatif kecil, mengindikasikan bahwa DAE berhasil mereduksi noise tanpa mengubah struktur utama citra secara signifikan.



Gambar 4.3 Visualisasi 4-panel SC01 vs SC04 - Gambar 1 (*brightness=54.1/255*)

Gambar 4.4 Visualisasi kondisi citra sangat gelap (*brightness=44.5/255*). Pada SC-01, tidak ada kendaraan terdeteksi sama sekali. Pasca penerapan SC-04, 1 mobil berhasil dideteksi (*conf=0.38*). Heatmap menunjukkan dominasi warna merah-oranye yang mengindikasikan keseluruhan frame mengalami enhancement signifikan oleh CLAHE.

Dominasi warna merah-oranye pada kondisi pencahayaan yang sangat rendah ini menunjukkan bahwa sebagian besar piksel pada frame mengalami peningkatan intensitas akibat proses CLAHE, mengindikasikan bahwa pipeline Cascaded CLAHE-DAE bekerja secara global untuk meningkatkan visibilitas objek tanpa mengubah struktur utama kendaraan.



Gambar 4.4 Visualisasi 4-panel SC01 vs SC04 - Gambar 2 (*brightness=44.5/255*)

Penjelasan :

- Merah – Oranye: Ter-enhance CLAHE

- Biru: Noise di tekan DAE

4.2 Pembahasan

4.2.1. *Evaluasi Kualitas Restorasi Citra pada Metode Proposed*

Hasil pengujian metrik PSNR dan SSIM secara eksplisit menjawab Rumusan Masalah 1 terkait efektivitas prapemrosesan citra. Secara teknis, mengapa skenario SC-03 (DAE murni) justru menghasilkan kualitas terburuk (PSNR 16.31 dB)? DAE yang menerima citra sangat gelap tanpa penguatan kontras awal tidak memiliki informasi gradien yang cukup untuk membedakan struktur kendaraan dari latar belakang. Model secara konservatif meratakan semua piksel gelap menjadi homogen (*over-smoothing* masif) (Lore et al., 2017).

Sebaliknya, skenario SC-04 (*Cascaded CLAHE-DAE*) mencapai SSIM tertinggi sebesar 0.9471. Keberhasilan ini didasari oleh sinergi mekanis antara kedua algoritma:

1. Peran CLAHE: CLAHE bertugas memberikan "petunjuk kontras" awal. Melalui pembatasan amplifikasi histogram (*clip limit* = 1.0), CLAHE meningkatkan visibilitas lokal tanpa menyorot piksel secara berlebihan, sehingga siluet kendaraan yang tersembunyi di kegelapan dapat muncul ke permukaan (seperti yang ditunjukkan pada visualisasi *Heatmap* di Gambar 4.1 hingga 4.3). Kendati demikian, efek samping dari proses ini adalah munculnya amplifikasi derau (*noise*).
2. Peran DAE: Di sinilah arsitektur U-Net pada DAE mengambil alih. DAE bertindak sebagai filter spasial yang membedakan mana derau akibat CLAHE dan mana garis batas (*edges*) asli kendaraan.
3. Peran Alpha Blending: Agar DAE tidak menghapus detail penting, fusi *Alpha Blending* ($\alpha=0.3$) diaplikasikan untuk menjaga 70% karakteristik ketajaman asli dari CLAHE, dan hanya mengambil 30% efek pembersihan (*denoising*) dari DAE. Sinergi inilah yang mencegah *over-smoothing* dan mempertahankan kemiripan struktural yang sangat tinggi.

4.2.2. *Analisis Kritis Performa Deteksi: Tantangan Ekstrem Citra Malam*

Berbagai literatur terdahulu telah membuktikan bahwa deteksi objek pada citra malam hari merupakan salah satu tantangan paling fundamental dalam

bidang Computer Vision. Kondisi iluminasi ekstrem, distorsi cahaya lampu (*glare*), dan noise sensor secara matematis merusak fitur gradien tepi (*edge gradients*) yang menjadi tumpuan utama ekstraksi fitur pada algoritma CNN seperti YOLO (Wei et al., 2018; Fu et al., 2022).

Tantangan fundamental ini terbukti secara empiris dari hancurnya angka mAP pada model COCO Baseline yang hanya menyentuh angka 0.2145 saat dihadapkan pada citra malam mentah (SC-01). Rendahnya performa ini bukan mengindikasikan kegagalan arsitektur YOLOv11, melainkan fenomena domain gap yang ekstrim, di mana model yang dilatih pada citra siang beresolusi tinggi kehilangan referensi spasial saat harus membaca bentuk kendaraan yang melebur dengan kegelapan. (Catatan analitis: Feature importance eksplisit tidak dilakukan karena ekstraksi fitur pada YOLOv11 berjalan hierarkis secara otomatis).

4.2.3. Signifikansi Metode Proposed pada Model Zero-Shot

Berdasarkan kegagalan ekstraksi fitur pada citra mentah tersebut, metode proposed (SC-04) diimplementasikan sebagai feature recovery layer. Melalui prapemrosesan SC-04, nilai rata-rata mAP@0.5 pada model Baseline berhasil ditingkatkan dari 0.2145 menjadi 0.2147 (menjawab Rumusan Masalah 2). Peningkatan ini secara spesifik didorong oleh pemulihan fitur pada dua kelas dominan, di mana akurasi kelas Mobil naik dari 0.3214 menjadi 0.3281, dan Motor naik dari 0.4168 menjadi 0.4329 (merujuk pada Tabel 4.6).

Kendati peningkatan total terlihat minor secara kuantitatif, pencapaian ini membuktikan bahwa integrasi *Cascaded* bekerja efektif dalam menormalisasi distribusi fitur yang rusak akibat kondisi malam, tanpa harus menyentuh arsitektur deteksi itu sendiri. Metode ini terbukti memiliki keunggulan fleksibilitas (*plug-and-play*), di mana sistem tidak perlu mengorbankan waktu dan sumber daya GPU untuk melakukan retraining model YOLO pada kondisi lingkungan visual yang baru.

4.2.4. Eksperimen Retrain YOLO: Mitigasi Domain Gap dan Dampak Domain Adaptation

Guna memvalidasi batasan dari metode prapemrosesan, dilakukan eksperimen lanjutan dengan melatih ulang model (Retrain) menggunakan strategi

Domain Adaptation. Pendekatan ini dilakukan dengan mengawinkan (mixing) data siang sintetis dan sampel citra malam riil selama proses training. Hasil evaluasi menunjukkan peningkatan yang sangat signifikan pada model Retrain terhadap citra mentah (SC-01) yang mencapai $mAP@0.5$ sebesar 0.4596, melompat dua kali lipat lebih tinggi dibandingkan COCO Baseline (0.2145).

Hal ini secara eksplisit menjawab Rumusan Masalah 3. Peningkatan signifikan ini membuktikan bahwa strategi Domain Adaptation berhasil memaksa bobot internal jaringan YOLOv11 untuk mempelajari dan menghafal pola pendaran cahaya (glare) serta derau sensor CCTV secara natural (Fu et al., 2022). Artinya, model berhasil mengatasi "kebutaan malam" (night blindness) karena distribusi visual lingkungan Tugu Irena telah dipelajari secara end-to-end, yang mana sebelumnya tidak dikenali oleh model standar bawaan COCO.

Kestabilan pembelajaran dan performa deteksi model Retrain ini divalidasi lebih lanjut melalui Kurva Precision-Recall dan F1-Confidence (Gambar 4.1 dan 4.2). Berdasarkan analisis kurva F1, model mencapai titik ekuilibrium terbaiknya pada confidence threshold 0.209. Titik ini mengindikasikan keseimbangan optimal antara Precision dan Recall, di mana model memiliki sensitivitas yang cukup tinggi untuk menemukan kendaraan di kegelapan (menekan false negatives), tanpa menghasilkan deteksi palsu (false positives) yang berlebihan akibat pantulan cahaya lampu di latar belakang.

4.2.5. *Potensi Data Leakage pada Skema Domain Adaptation*

Kendati strategi Domain Adaptation menunjukkan lonjakan akurasi yang tinggi pada skema Retrain, tingginya angka absolut ini harus dievaluasi secara kritis secara metodologis. Proses fine-tuning melibatkan citra yang diekstraksi dari sumber rekaman CCTV publik yang sama (Tugu Ireng) dengan 594 citra yang digunakan pada set pengujian. Kendati dipisahkan secara acak, kontinuitas rekaman video menciptakan korelasi temporal yang tinggi antar-frame berdekatan.

Fenomena ini memunculkan potensi data leakage (kebocoran data), di mana model deteksi cenderung "menghafal" latar belakang spasial dan karakteristik statis dari lokasi kamera tersebut. Dengan demikian, lonjakan performa dari 0,21 ke 0,45 lebih merepresentasikan keberhasilan adaptasi domain spesifik, dan tingkat reliabilitas generalisasi model universal tetap harus dirujuk pada model zero-shot COCO Baseline.

4.2.6 *Analisis Sinergi Pipeline Cascaded vs Kegagalan Metode Tunggal*

Guna mengisolasi efek murni dari pemrosesan citra pada model yang telah diadaptasi, analisis difokuskan pada studi ablasi skskenario pemrosesan menggunakan model Retrained. Merujuk pada Tabel 4.5, penerapan prapemrosesan secara tunggal terbukti berdampak destruktif terhadap performa deteksi. Penggunaan CLAHE saja (SC-02) menurunkan mAP menjadi 0.4004 (-12.9%), sedangkan DAE saja (SC-03) menurunkan mAP hingga 0.3604 (-21.6%).

Penurunan tajam pada metode tunggal ini disebabkan oleh amplifikasi derau berlebih pada CLAHE murni yang menghancurkan informasi tepi objek, sejalan dengan kekhawatiran Lashkov et al. (2023), serta fenomena over-smoothing pada DAE murni yang menghapus siluet halus kendaraan akibat ketiadaan panduan gradien kontras yang cukup (Lore et al., 2017).


Ketika kedua metode digabungkan secara Cascaded (SC-04), nilai mAP@0.5 kembali pulih dan berhasil mencapai skor tertinggi sebesar 0.4631 (naik +0.76% dari citra mentah SC-01). Temuan ini membuktikan secara empiris keunggulan utama dari pendekatan bertingkat: CLAHE dan DAE tidak dapat

berdiri sendiri pada ekosistem low-light. Keduanya wajib bekerja secara sinergis, di mana CLAHE bertugas membongkar detail tersembunyi, DAE mereduksi derau hasil amplifikasinya, dan fusi Alpha Blending menjaga keseimbangan ketajaman visual agar terhindar dari bias over-smoothing. Dampak positif dari pemulihan fitur visual ini juga terefleksi kuat pada metrik Recall model Retrained yang meningkat signifikan dari 0.4284 (SC-01) menjadi 0.4491 (SC-04), membuktikan bahwa metode Cascaded sukses meminimalisasi jumlah kendaraan yang gagal terdeteksi (false negatives).

4.2.7. Evaluasi Kritis Kinerja Sistem: Imbalansi Kelas dan Distorsi Visual

Metode *Cascaded* ini memiliki keunggulan operasional karena aman dari *Hallucination* (halusinasi generatif) dan diuji pada citra utuh (*Full Image*) tanpa penyempitan area *Region of Interest* (ROI). Meski demikian, nilai rata-rata mAP keseluruhan sistem ditekan oleh dua faktor teknis utama yang dapat diamati pada Distribusi Label dan Matriks Kebingungan (Gambar 4.6 dan Gambar 4.7):

1. Extreme Class Imbalance: Performa deteksi pada kelas mayoritas seperti Mobil sangat stabil (mAP 0.5831). Meski demikian, nilai mAP rata-rata keseluruhan sistem ditarik turun secara matematis oleh performa kelas minoritas, yaitu Bis (0.4% dari total data) dan Truk (2.4% dari total data), akibat minimnya sampel representatif selama proses evaluasi.
2. Kehilangan Bentuk (Shape Loss): Merujuk pada Bell et al. (2022), pada kondisi CCTV malam hari yang ekstrem, bentuk fisik asli kendaraan hampir hilang (*virtually lost*) dan hanya tersisa sebagai kilatan cahaya acak akibat distorsi silau lampu (*glare*). Hal ini memicu tingginya nilai *False Negatives* pada matriks kebingungan (Gambar 4.7), di mana target objek diklasifikasikan sebagai latar belakang (*background*) karena model gagal menarik logika batas kotak (*bounding box*) di tengah intervensi cahaya lampu sorot.



Gambar 4.5 Distribusi Jumlah Label pada Dataset



Gambar 4.6 Confusion Matrix Model Retrain

4.3 Implementasi Sistem

Bagian ini membahas implementasi perangkat lunak (sistem) yang dibangun untuk menjalankan dan menguji model deteksi kendaraan yang telah dilatih. Sistem ini dirancang menggunakan arsitektur *Client-Server* modern dan dibagi menjadi dua modul utama, yaitu *Backend* (pemrosesan logika dan inferensi model) dan *Frontend* (antarmuka pengguna).

4.3.1. Lingkungan Pengembangan (*Tools & Framework*)

Implementasi sistem pada penelitian ini menggunakan teknologi yang relevan untuk menangani komputasi tingkat tinggi:

1. Backend (*Server*): Dibangun menggunakan bahasa pemrograman Python dengan *framework* FastAPI. FastAPI dipilih karena performanya yang tinggi dalam menangani request secara asinkron, yang mana sangat

esensial untuk proses komputasi deep learning. Modul utama yang berjalan di sisi server meliputi PyTorch untuk inferensi arsitektur DAE (U-Net), *Ultralytics* untuk inferensi YOLOv11, serta OpenCV untuk manipulasi matriks citra (seperti eksekusi CLAHE dan ROI *Masking*).

2. Frontend (*Client*): Dibangun menggunakan pustaka React.js dengan build-tool Vite. Antarmuka ini berkomunikasi dengan backend melalui arsitektur REST API menggunakan modul Axios. Visualisasi data dan matrik evaluasi di render secara responsif menggunakan pustaka Recharts.

Pemilihan tech stack ini difokuskan untuk menjawab tujuan penelitian, yakni membangun sebuah prototipe sistem cerdas yang mampu memproses rekaman CCTV secara *in-line*, menerapkan algoritma prapemrosesan *Cascaded* CLAHE dan DAE secara otomatis, serta menghitung volume kendaraan.

4.3.2. Implementasi Backend (Logika Pipeline & REST API)

Inti pemrosesan dari sistem ini berada pada skrip `main.py` dan `services/Pipeline.py` di sisi backend. Terdapat endpoint utama, yaitu POST `/detect`, yang bertugas menerima input citra dan mengeksekusi skenario (SC-01 hingga SC-05) berdasarkan parameter yang dikirim oleh pengguna. Fitur Utama Backend meliputi:

1. Penerimaan Citra dan Gamma Adjusting: Sistem menerima unggahan gambar dan memiliki kapabilitas untuk melakukan penyesuaian gamma guna mensimulasikan kondisi *low-light* secara artifisial jika input berasal dari citra siang hari.
2. Eksekusi Skenario (*Pipeline*): Gambar dilewatkan ke dalam fungsi `process_pipeline` yang memetakan tahapan prapemrosesan. Pada skenario usulan (SC-04), gambar dieksekusi menggunakan CLAHE, direkonstruksi oleh DAE U-Net menggunakan *Alpha Blending*, lalu diakhiri dengan ROI *Masking* (menghitamkan 15% bagian atas gambar untuk menghapus *noise* berupa teks/stempel waktu CCTV).
3. Deteksi YOLOv11: Citra hasil prapemrosesan diumpankan (*feed*) ke dalam model YOLOv11 hasil *fine-tuning* (`bestYOLO.pt`) untuk mengekstraksi koordinat kotak pembatas (*bounding box*).

BAB 5. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis data dan pembahasan, penelitian ini menyimpulkan beberapa poin utama sebagai jawaban atas rumusan masalah penelitian:

1. Dampak *Low-Light*: Kontras rendah dan noise tinggi menyamarkan fitur objek, menurunkan mAP standar YOLOv11 ke 0.2145.
2. Efektivitas Restorasi: Kombinasi Cascaded (CLAHE, DAE, *Alpha Blending* 0.3) sukses meningkatkan kontras & mereduksi noise (PSNR 22,27 dB; SSIM 0.9471).
3. Peningkatan Akurasi: Metode ini konsisten menaikkan mAP zero-shot ke 0.2147, dan berhasil mencapai skor 0.4631 pada eksplorasi model retrain.

5.2 Saran

Beberapa saran yang direkomendasikan untuk pengembangan selanjutnya adalah:

1. Penerapan Masking ROI: Mengintegrasikan algoritma pembatasan area jalan aktif (ROI) pada tahap pengujian guna mereduksi bias dari distorsi cahaya latar belakang.
2. Mitigasi Kelas Minoritas: Implementasi Oversampling, atau Focal Loss untuk meningkatkan deteksi pada kendaraan berat.
3. Implementasi Sistem: Optimasi confidence threshold berdasarkan titik F1-score (0.209) guna menyeimbangkan *precision* dan *recall*.
4. Penggunaan kamera CCTV berspesifikasi tinggi yang dilengkapi fitur *night vision* atau sensor *low-light* sangat disarankan untuk implementasi di lapangan. Kualitas *footage* mentah yang lebih jernih dan minim *noise* sejak awal perekaman akan sangat meringankan beban komputasi restorasi digital, sekaligus memaksimalkan akurasi deteksi YOLOv11 tanpa harus bergantung sepenuhnya pada perbaikan perangkat lunak.

DAFTAR PUSTAKA

- Bell, A., Mantecon, T., Diaz, C., del-Blanco, C. R., Jaureguizar, F., & Garcia, N. (2022). A Novel System for Nighttime Vehicle Detection Based on Foveal Classifiers With Real-Time Performance. *IEEE Trans. Intell. Transport. Syst.*, 23(6), 5421–5433. <https://doi.org/10.1109/TITS.2021.3053863>
- Dai, X., Lan, J., Chen, Z., Wang, B., & Wen, X. (2026). Multi-exposure image enhancement and YOLO integration for nighttime pedestrian detection. *Signal Processing: Image Communication*, 140, 117421. <https://doi.org/10.1016/j.image.2025.117421>
- Fu, L., Yu, H., Juefei-Xu, F., Li, J., Guo, Q., & Wang, S. (2022). Let There Be Light: Improved Traffic Surveillance via Detail Preserving Night-to-Day Transfer. *IEEE Trans. Circuits Syst. Video Technol.*, 32(12), 8217–8226. <https://doi.org/10.1109/TCSVT.2021.3081999>
- Gondara, L. (2016). Medical Image Denoising Using Convolutional Denoising Autoencoders. *2016 IEEE 16th International Conference on Data Mining Workshops (ICDMW)*, 241–246. <https://doi.org/10.1109/ICDMW.2016.0041>
- Jin, H., Li, L., Su, H., Zhang, Y., Xiao, Z., & Wang, B. (2024). A Multi-Exposure Generation and Fusion Method for Low-Light Image Enhancement. *2024 International Joint Conference on Neural Networks (IJCNN)*, 1–7. <https://doi.org/10.1109/IJCNN60899.2024.10650454>
- Jing, Z., Li, S., & Zhang, Q. (2024). YOLOv8-STE: Enhancing Object Detection Performance Under Adverse Weather Conditions with Deep Learning. *Electronics*, 13(24), 5049. <https://doi.org/10.3390/electronics13245049>
- Khekare, G., Singh, R., Karmakar, V., Natarajan, Y., & Sri Preethaa, K. R. (2025). Real time traffic surveillance system using YOLOv9. *IET Conf. Proc.*, 2025(7), 505–510. <https://doi.org/10.1049/icp.2025.1339>
- Lashkov, I., Yuan, R., & Zhang, G. (2023). Edge-Computing-Facilitated Nighttime Vehicle Detection Investigations With CLAHE-Enhanced

- Images. *IEEE Trans. Intell. Transport. Syst.*, 24(11), 13370–13383.
<https://doi.org/10.1109/TITS.2023.3255202>
- Li, C., Guo, C., Han, L., Jiang, J., Cheng, M.-M., Gu, J., & Loy, C. C. (2021). *Low-Light Image and Video Enhancement Using Deep Learning: A Survey*.
<http://arxiv.org/abs/2104.10729>
- Li, Y., Liu, T., Fan, J., & Ding, Y. (2023). LDNet: low-light image enhancement with joint lighting and denoising. *Machine Vision and Applications*, 34(1), 13. <https://doi.org/10.1007/s00138-022-01365-z>
- Lore, K. G., Akintayo, A., & Sarkar, S. (2017). LLNet: A deep autoencoder approach to natural low-light image enhancement. *Pattern Recognition*, 61, 650–662. <https://doi.org/10.1016/j.patcog.2016.06.008>
- Narayanan, P., Nikhil, V., & Veluchamy, S. (2024). Vehicle Object Detection in Traffic Environments Using Low-Light Image Enhancement. *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 1–8.
<https://doi.org/10.1109/ICCCNT61001.2024.10723924>
- Wei, C., Wang, W., Yang, W., & Liu, J. (2018). *Deep Retinex Decomposition for Low-Light Enhancement*. arXiv.
<https://doi.org/10.48550/ARXIV.1808.04560>
- Weng, T., & Niu, X. (2025). Enhancing UAV Object Detection in Low-Light Conditions with ELS-YOLO: A Lightweight Model Based on Improved YOLOv11. *Sensors*, 25(14). <https://doi.org/10.3390/s25144463>
- Yuan, Z., Zeng, J., Wei, Z., Jin, L., Zhao, S., Liu, X., Zhang, Y., & Zhou, G. (2023). CLAHE-Based Low-Light Image Enhancement for Robust Object Detection in Overhead Power Transmission System. *IEEE Trans. Power Delivery*, 38(3), 2240–2243. <https://doi.org/10.1109/TPWRD.2023.3269206>
- Zhang, F., Li, Y., You, S., & Fu, Y. (n.d.). *Learning Temporal Consistency for Low Light Video Enhancement from Single Images*. <https://github.com/zkawfanx/>
- Zhao, D., Shao, F., Zhang, S., Yang, L., Zhang, H., Liu, S., & Liu, Q. (2024). Advanced Object Detection in Low-Light Conditions: Enhancements to

YOLOv7 Framework. *Remote Sensing*, 16(23), 4493.
<https://doi.org/10.3390/rs16234493>

Zhu, F., Fei, R., & Ji, C. (2025). Research on low-light image enhancement method based on UNet. In W. Pedrycz & S. S. Agaian (Eds.), *Fifth International Conference on Telecommunications, Optics, and Computer Science (TOCS 2024)* (p. 67). SPIE. <https://doi.org/10.1117/12.3067813>

Badan Pusat Statistik (BPS). (2023). *Perkembangan Jumlah Kendaraan Bermotor Menurut Jenis (Unit), 2021-2023*. Diakses pada [Isi Tanggal/Bulan/Tahun Kamu Mengakses], dari <https://www.bps.go.id/id/statistics-table/2/NTcjMg==/perkembangan-jumlah-kendaraan-bermotor-menurut-jenis.html>

Dinas Perhubungan Kabupaten Magelang [dishubkabmagelang]. (n.d.). *CCTV Tugu Ireng Magelang* [Video/Kanal YouTube]. YouTube. Diakses pada [Isi Tanggal/Bulan/Tahun], dari <https://www.youtube.com/@dishubkabmagelang>

LAMPIRAN-LAMPIRAN

- Lampiran 1.1 Dataset
- Lampiran 1.2 *Source Code*
- Lampiran 1.3 Hasil *Training* YOLO
- Lampiran 1.4 Visualisasi *Output*



SCAN ME