

## ANALISIS KOMPARATIF KINERJA YOLOV5, YOLOV8, DAN YOLO11 PADA DETEKSI OBJEK LALU LINTAS MALAM HARI MENGGUNAKAN CLAHE

Daniel Achmad Farizki, Anggay Luri Pramana

Informatika, Universitas Nahdlatul Ulama Sidoarjo

Jl. Lingkar Timur KM 5,5 Rangkah Kidul, Kec. Sidoarjo, Kabupaten Sidoarjo, Jawa Timur 61234

niiellpz@gmail.com

### ABSTRAK

Deteksi objek pada kondisi malam hari menjadi tantangan dalam sistem transportasi cerdas karena rendahnya pencahayaan, kontras citra yang buruk, dan noise yang dapat menurunkan akurasi deteksi objek. Permasalahan tersebut menyebabkan proses ekstraksi fitur pada model deep learning menjadi kurang optimal, terutama pada citra lalu lintas malam hari. Penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja YOLOv5, YOLOv8, dan YOLO11 dalam mendeteksi objek lalu lintas malam hari menggunakan preprocessing Contrast Limited Adaptive Histogram Equalization (CLAHE). Metode penelitian dilakukan secara eksperimental menggunakan dataset sebanyak 2.000 citra lalu lintas malam hari dengan enam kategori objek. Eksperimen dilakukan pada dua skenario, yaitu tanpa preprocessing dan dengan preprocessing CLAHE. Evaluasi performa menggunakan precision, recall, dan mean Average Precision (mAP). Hasil penelitian menunjukkan bahwa penerapan CLAHE meningkatkan performa seluruh model. YOLOv5 mengalami peningkatan mAP dari 0,509 menjadi 0,600, sedangkan YOLOv8 meningkat dari 0,491 menjadi 0,497 dan YOLO11 dari 0,475 menjadi 0,494. Hasil tersebut menunjukkan bahwa CLAHE efektif meningkatkan kualitas citra dan membantu meningkatkan performa deteksi objek pada kondisi pencahayaan rendah.

**Kata kunci :** Deteksi Objek; Citra Malam Hari; YOLO; CLAHE; Deep Learning; Computer Vision

### 1. PENDAHULUAN

Perkembangan kecerdasan buatan (Artificial Intelligence) telah mendorong transformasi signifikan dalam berbagai sektor, termasuk sistem transportasi cerdas (Intelligent Transportation Systems/ITS). Salah satu teknologi utama dalam ITS adalah computer vision, yang memungkinkan sistem untuk mengekstraksi, menganalisis, dan memahami informasi visual dari citra maupun video secara otomatis. Dalam konteks transportasi, computer vision banyak diterapkan untuk pemantauan lalu lintas, deteksi kendaraan, analisis kepadatan jalan, identifikasi pelanggaran, serta peningkatan keselamatan pengguna jalan melalui sistem pengawasan berbasis kamera [1].

Salah satu pendekatan yang paling banyak digunakan dalam deteksi objek berbasis computer vision adalah deep learning, khususnya algoritma You Only Look Once (YOLO). YOLO dikenal sebagai metode deteksi objek real-time yang mampu mengintegrasikan proses klasifikasi dan lokalisasi objek dalam satu arsitektur jaringan sehingga menghasilkan kecepatan dan akurasi yang baik [2].

Seiring perkembangan teknologi, YOLO mengalami berbagai penyempurnaan melalui hadirnya beberapa generasi model seperti YOLOv5 [3], YOLOv8 [4], hingga YOLO11 [5] yang menawarkan peningkatan dari sisi efisiensi komputasi, stabilitas pelatihan, dan kemampuan generalisasi pada berbagai kondisi lingkungan. Dalam bidang transportasi, model YOLO telah banyak digunakan untuk mendeteksi kendaraan, pejalan kaki, serta berbagai objek lalu lintas lainnya dengan performa yang cukup baik [1], [6].

Meskipun demikian, performa sistem deteksi objek berbasis deep learning masih menghadapi tantangan besar ketika diterapkan pada kondisi pencahayaan rendah, khususnya pada malam hari. Citra malam hari umumnya memiliki karakteristik berupa kontras rendah, distribusi pencahayaan tidak merata, noise tinggi, serta hilangnya detail visual akibat keterbatasan intensitas cahaya [7], [8]. Kondisi tersebut menyebabkan proses ekstraksi fitur visual menjadi kurang optimal sehingga berdampak pada penurunan akurasi deteksi objek [8], [9].

Dalam konteks lalu lintas, permasalahan ini menjadi sangat penting karena sistem pemantauan lalu lintas dituntut mampu bekerja secara konsisten selama 24 jam, termasuk pada kondisi malam hari dengan visibilitas terbatas [6].

Permasalahan utama dalam penelitian ini adalah rendahnya performa deteksi objek pada citra lalu lintas malam hari akibat kualitas pencahayaan yang buruk dan keterbatasan kemampuan model dalam mengekstraksi fitur visual pada kondisi low-light.

Untuk mengatasi keterbatasan tersebut, tahap preprocessing citra menjadi salah satu solusi yang umum digunakan sebelum proses deteksi objek dilakukan. Salah satu metode preprocessing yang banyak diterapkan adalah Contrast Limited Adaptive Histogram Equalization (CLAHE), yaitu teknik peningkatan kontras citra yang bekerja secara adaptif pada area lokal untuk memperjelas detail objek tanpa meningkatkan noise secara berlebihan [10], [11].

CLAHE terbukti efektif dalam meningkatkan kualitas citra pada kondisi low-light dengan memperbaiki distribusi intensitas cahaya sehingga objek menjadi lebih mudah dikenali [11], [12].

Berbagai penelitian sebelumnya menunjukkan bahwa peningkatan kualitas citra melalui preprocessing dapat memberikan dampak positif terhadap performa model deep learning pada kondisi pencahayaan rendah [8], [13].

Selain itu, kombinasi antara teknik enhancement dan model deteksi objek modern juga menunjukkan potensi dalam meningkatkan akurasi deteksi secara signifikan [13], [14].

Namun demikian, sebagian besar penelitian masih berfokus pada satu model YOLO tertentu atau hanya mengevaluasi pengaruh preprocessing tanpa membandingkan perkembangan performa antar generasi model secara komprehensif [13], [14].

Meskipun berbagai penelitian telah mengeksplorasi peningkatan performa deteksi objek melalui pengembangan arsitektur YOLO maupun penerapan teknik preprocessing citra, sebagian besar studi masih berfokus pada satu model tertentu atau hanya mengevaluasi satu pendekatan peningkatan kualitas citra secara terpisah. Penelitian yang secara khusus melakukan analisis komparatif lintas generasi model YOLO, khususnya YOLOv5, YOLOv8, dan YOLO11, pada skenario deteksi objek lalu lintas malam hari berbasis citra nyata dengan integrasi CLAHE masih sangat terbatas.

Untuk menyelesaikan permasalahan tersebut, penelitian ini menerapkan metode preprocessing Contrast Limited Adaptive Histogram Equalization (CLAHE) dan melakukan analisis komparatif terhadap model YOLOv5, YOLOv8, dan YOLO11 untuk mengetahui model dengan performa terbaik pada kondisi pencahayaan rendah.

Kontribusi utama penelitian ini terletak pada evaluasi komparatif terhadap tiga generasi model YOLO dalam dua skenario berbeda, yaitu tanpa preprocessing dan dengan preprocessing CLAHE, menggunakan dataset citra lalu lintas malam hari berbasis kamera egosentris. Pendekatan ini memberikan gambaran yang lebih komprehensif mengenai pengaruh kualitas citra terhadap performa deteksi objek sekaligus perkembangan efektivitas arsitektur YOLO pada kondisi pencahayaan rendah.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengevaluasi dan membandingkan performa YOLOv5, YOLOv8, dan YOLO11 dalam mendeteksi objek lalu lintas pada citra malam hari serta menganalisis efektivitas CLAHE dalam meningkatkan akurasi deteksi berdasarkan metrik precision, recall, dan mean Average Precision (mAP) [15].

Hasil penelitian ini diharapkan dapat menjadi referensi dalam pemilihan model deteksi objek yang optimal untuk implementasi sistem transportasi cerdas pada kondisi pencahayaan rendah.

## 2. TINJAUAN PUSTAKA

Deteksi objek merupakan salah satu bidang utama dalam computer vision yang bertujuan untuk mengidentifikasi keberadaan, lokasi, dan kategori

objek pada suatu citra atau video. Dalam beberapa tahun terakhir, perkembangan deep learning telah meningkatkan performa deteksi objek secara signifikan melalui penggunaan Convolutional Neural Network (CNN). Salah satu algoritma yang paling populer dalam bidang ini adalah You Only Look Once (YOLO), yang diperkenalkan sebagai metode deteksi objek real-time dengan pendekatan single-stage detector yang mengintegrasikan proses klasifikasi dan lokalisasi objek dalam satu jaringan [2].

Pendekatan ini memungkinkan YOLO mencapai keseimbangan yang baik antara kecepatan dan akurasi dibandingkan metode two-stage detector tradisional.

Seiring perkembangan teknologi, arsitektur YOLO terus mengalami peningkatan. YOLOv5 dikembangkan dengan fokus pada efisiensi implementasi, fleksibilitas penggunaan, dan kemudahan integrasi pada berbagai perangkat komputasi [3].

YOLOv8 sebagai generasi yang lebih baru menawarkan pendekatan anchor-free detection, arsitektur yang lebih efisien, serta peningkatan kemampuan generalisasi pada berbagai skenario deteksi objek [4].

Perkembangan terbaru juga menunjukkan hadirnya model modern untuk kondisi visual kompleks seperti low-light, misalnya YOLO11 [5].

Perkembangan ini menunjukkan bahwa setiap generasi YOLO memiliki karakteristik dan keunggulan masing-masing, sehingga analisis komparatif diperlukan untuk menentukan model yang paling sesuai pada kondisi tertentu, khususnya lingkungan dengan pencahayaan rendah [9].

Dalam konteks sistem transportasi cerdas, deteksi objek berperan penting dalam berbagai aplikasi seperti pemantauan lalu lintas, analisis kepadatan kendaraan, pengawasan keselamatan jalan, dan kendaraan otonom [1].

Penelitian sebelumnya menunjukkan bahwa model berbasis YOLO memiliki performa yang baik dalam mendeteksi kendaraan dan objek lalu lintas secara real-time [6].

Namun, performa tersebut sangat dipengaruhi oleh kualitas citra masukan, terutama ketika sistem diterapkan pada malam hari atau kondisi low-light.

Citra malam hari memiliki tantangan yang lebih kompleks dibandingkan citra siang hari karena ditandai oleh rendahnya intensitas cahaya, kontras yang buruk, distribusi pencahayaan yang tidak merata, serta noise tinggi akibat sumber cahaya buatan seperti lampu kendaraan dan lampu jalan [7], [8].

Kondisi ini menyebabkan hilangnya detail visual penting yang dibutuhkan model deep learning untuk melakukan ekstraksi fitur secara optimal. Penurunan kualitas visual tersebut dapat berdampak langsung pada menurunnya precision, recall, maupun mean Average Precision (mAP) dari sistem deteksi objek [8], [15].

Untuk meningkatkan kualitas citra pada kondisi pencahayaan rendah, berbagai teknik image

enhancement telah dikembangkan, salah satunya adalah Contrast Limited Adaptive Histogram Equalization (CLAHE). CLAHE merupakan pengembangan dari Adaptive Histogram Equalization (AHE) yang bekerja dengan membagi citra ke dalam beberapa area lokal (tiles), kemudian melakukan peningkatan kontras secara adaptif pada masing-masing area dengan membatasi amplifikasi kontras berlebih untuk mengurangi noise [10].

Dibandingkan metode histogram equalization konvensional, CLAHE lebih efektif dalam meningkatkan detail lokal tanpa menyebabkan over-enhancement [11].

Beberapa penelitian menunjukkan bahwa CLAHE mampu meningkatkan kualitas citra secara signifikan pada berbagai skenario, termasuk citra medis, pengawasan malam hari, dan lalu lintas [11], [12].

Dalam konteks deteksi objek, peningkatan kontras melalui CLAHE dapat membantu model deep learning mengenali fitur-fitur penting seperti bentuk kendaraan, lampu, kontur objek, dan rambu lalu lintas secara lebih jelas. Dengan demikian, preprocessing menggunakan CLAHE berpotensi meningkatkan performa model deteksi objek, terutama pada kondisi visual yang menantang [13].

Evaluasi performa model deteksi objek umumnya menggunakan metrik precision, recall, dan mean Average Precision (mAP). Precision mengukur tingkat ketepatan prediksi model terhadap seluruh prediksi yang dihasilkan, recall mengukur kemampuan model dalam mendeteksi seluruh objek yang sebenarnya ada, sedangkan mAP digunakan sebagai indikator utama performa keseluruhan model [15].

Penggunaan metrik ini memungkinkan analisis yang objektif terhadap kemampuan model dalam berbagai kondisi eksperimen.

Berdasarkan kajian literatur tersebut, dapat disimpulkan bahwa performa deteksi objek pada citra malam hari dipengaruhi oleh dua faktor utama, yaitu kualitas citra masukan dan kemampuan arsitektur model dalam mengekstraksi fitur. Oleh karena itu, kombinasi antara preprocessing citra menggunakan CLAHE dan pemilihan model YOLO yang tepat menjadi aspek penting dalam meningkatkan performa sistem deteksi objek lalu lintas pada kondisi pencahayaan rendah [14], [13].

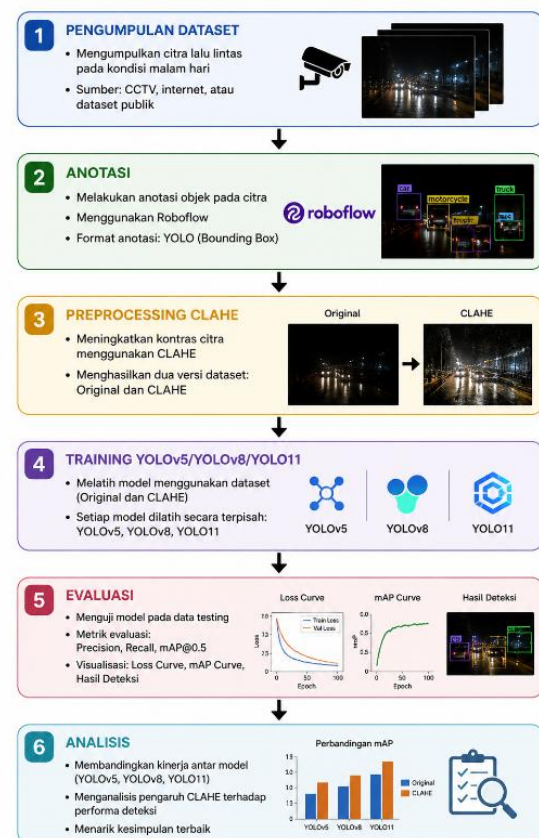
Penelitian ini memanfaatkan landasan teori tersebut untuk melakukan analisis komparatif terhadap YOLOv5, YOLOv8, dan YOLO11 pada skenario citra malam hari secara lebih komprehensif.

### 3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan eksperimental kuantitatif berbasis deep learning untuk menganalisis dan membandingkan kinerja tiga generasi model YOLO, yaitu YOLOv5, YOLOv8, dan YOLO11, dalam mendeteksi objek lalu lintas pada citra malam hari. Eksperimen dilakukan dalam dua skenario utama, yaitu menggunakan dataset asli tanpa

preprocessing dan dataset yang telah ditingkatkan kualitasnya menggunakan Contrast Limited Adaptive Histogram Equalization (CLAHE). Pendekatan ini bertujuan untuk mengevaluasi pengaruh preprocessing citra terhadap performa deteksi objek sekaligus membandingkan efektivitas perkembangan arsitektur YOLO pada kondisi pencahayaan rendah.

Tahapan penelitian meliputi pengumpulan dataset, anotasi data, preprocessing citra, pelatihan model, evaluasi performa, dan analisis komparatif hasil eksperimen. Seluruh proses dirancang secara sistematis agar setiap model diuji pada kondisi dataset dan konfigurasi pelatihan yang setara, sehingga hasil penelitian dapat dibandingkan secara objektif. Alur tahapan penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Alur Tahapan Penelitian Analisis Komparatif YOLOv5, YOLOv8, dan YOLO11

#### 3.1. Dataset

Dataset yang digunakan dalam penelitian ini berupa citra lalu lintas malam hari yang diperoleh melalui proses pengambilan data secara langsung menggunakan kamera egosentris. Penggunaan kamera egosentris bertujuan untuk menghasilkan dataset yang merepresentasikan kondisi nyata sistem pemantauan lalu lintas pada malam hari, termasuk variasi sudut pandang, intensitas pencahayaan, kepadatan kendaraan, serta kompleksitas lingkungan jalan [7].

Dataset terdiri dari sekitar 2.000 citra yang memuat enam kategori objek utama, yaitu mobil,

sepeda motor, bus, truk, rambu lalu lintas, dan pejalan kaki. Keenam kategori tersebut dipilih karena merepresentasikan komponen penting dalam analisis lalu lintas berbasis computer vision [6].

Seluruh data dianotasi secara manual menggunakan platform Roboflow dengan format bounding box sesuai standar YOLO untuk memastikan akurasi pelabelan objek.

Proses anotasi dilakukan dengan memberikan label kelas pada setiap objek beserta koordinat lokasi objek pada citra. Tahap ini sangat penting karena kualitas anotasi secara langsung memengaruhi kemampuan model dalam mempelajari pola visual selama proses pelatihan.

Data pelatihan digunakan untuk proses pembelajaran model, data validasi digunakan untuk memantau performa model selama pelatihan dan mencegah overfitting, sedangkan data pengujian digunakan untuk evaluasi akhir pada data yang belum pernah dilihat sebelumnya.

Tabel 1. Distribusi Dataset Berdasarkan Kategori Objek Lalu Lintas

| Kategori     | Jumlah      |
|--------------|-------------|
| Mobil        | 620         |
| Motor        | 540         |
| Bus          | 180         |
| Truk         | 210         |
| Rambu        | 250         |
| Pejalan Kaki | 200         |
| <b>Total</b> | <b>2000</b> |

Selain distribusi anotasi, contoh sampel dataset citra lalu lintas malam hari yang digunakan dalam penelitian ini ditampilkan pada Gambar 2. Gambar tersebut menunjukkan variasi kondisi visual dataset, termasuk perbedaan pencahayaan, kepadatan kendaraan, dan kompleksitas latar belakang yang menjadi tantangan utama dalam proses deteksi objek malam hari.



Gambar 2. Contoh Sampel Dataset Citra Lalu Lintas Malam Hari yang Digunakan dalam Penelitian

Untuk menjaga validitas eksperimen, dataset dibagi menjadi tiga subset, yaitu training set sebesar 70%, validation set sebesar 20%, dan testing set sebesar 10%. Data training digunakan untuk pembelajaran model, validation digunakan untuk

memantau performa selama pelatihan serta mencegah overfitting, sedangkan testing set digunakan untuk evaluasi akhir terhadap data yang belum pernah dilihat model sebelumnya.

### 3.2. Preprocessing Citra

Tahap preprocessing dilakukan untuk meningkatkan kualitas citra malam hari sebelum digunakan pada proses pelatihan model. Metode yang diterapkan adalah Contrast Limited Adaptive Histogram Equalization (CLAHE), yaitu teknik peningkatan kontras citra berbasis histogram lokal yang bekerja dengan membagi citra ke dalam beberapa area kecil (tiles), kemudian melakukan peningkatan kontras secara adaptif pada setiap area [10].

CLAHE dipilih karena mampu meningkatkan visibilitas objek pada kondisi pencahayaan rendah tanpa memperkuat noise secara berlebihan [11], [12].

Pada citra malam hari, objek seperti kendaraan, lampu jalan, pejalan kaki, dan rambu lalu lintas sering kali sulit dikenali akibat rendahnya kontras dan distribusi pencahayaan yang tidak merata [8].

Dengan CLAHE, distribusi intensitas cahaya menjadi lebih seimbang sehingga detail visual objek menjadi lebih jelas. Perbandingan kualitas citra sebelum dan sesudah penerapan CLAHE ditunjukkan pada Gambar 3. Berdasarkan visualisasi tersebut, CLAHE mampu meningkatkan kontras lokal secara signifikan, terutama pada area gelap yang sebelumnya kehilangan detail visual penting.



Gambar 3. Perbandingan Kualitas Citra Sebelum dan Sesudah Penerapan CLAHE

Dalam penelitian ini, preprocessing dilakukan pada seluruh dataset untuk membentuk dua skenario eksperimen, yaitu dataset original tanpa preprocessing dan dataset enhanced dengan CLAHE. Pendekatan ini memungkinkan evaluasi langsung terhadap pengaruh preprocessing terhadap performa model.

### 3.3. Model Deteksi Objek

Penelitian ini menggunakan tiga model deteksi objek dari keluarga YOLO, yaitu YOLOv5, YOLOv8, dan YOLO11. Ketiga model dipilih karena merepresentasikan perkembangan arsitektur YOLO dari generasi berbeda [3], [4], [5].

YOLOv5 digunakan sebagai baseline model karena stabil, ringan, dan telah banyak digunakan pada penelitian sebelumnya [3].

YOLOv8 dipilih sebagai representasi model modern dengan pendekatan anchor-free yang lebih efisien [4].

YOLO11 digunakan sebagai model generasi terbaru untuk mengevaluasi sejauh mana perkembangan arsitektur mampu meningkatkan performa deteksi pada kondisi citra kompleks seperti malam hari [5].

Setiap model diuji pada dua kondisi dataset, yaitu tanpa CLAHE dan dengan CLAHE, sehingga total terdapat enam konfigurasi eksperimen:

- YOLOv5 tanpa CLAHE
- YOLOv5 dengan CLAHE
- YOLOv8 tanpa CLAHE
- YOLOv8 dengan CLAHE
- YOLO11 tanpa CLAHE
- YOLO11 dengan CLAHE

Pendekatan ini memungkinkan analisis yang lebih komprehensif baik dari sisi pengaruh preprocessing maupun perkembangan arsitektur model.

### 3.4. Proses Pelatihan Model

Pelatihan model dilakukan menggunakan Google Colab dengan dukungan GPU NVIDIA T4 untuk mempercepat komputasi. Seluruh model dilatih menggunakan dataset yang sama agar eksperimen bersifat adil dan objektif.

Konfigurasi hyperparameter yang digunakan pada seluruh model diseragamkan untuk menjaga validitas perbandingan performa. Parameter pelatihan lengkap yang digunakan dalam penelitian ini ditunjukkan pada Tabel 2. Penggunaan konfigurasi yang seragam memastikan bahwa perbedaan performa yang dihasilkan lebih merepresentasikan kemampuan arsitektur model dibandingkan pengaruh variasi parameter pelatihan.

Tabel 2. Konfigurasi Hyperparameter Pelatihan Model

| Parameter             | Nilai                                     |
|-----------------------|-------------------------------------------|
| Framework             | Ultralytics YOLO                          |
| Model yang Diuji      | YOLOv5, YOLOv8, YOLO11                    |
| Jumlah Epoch          | 100                                       |
| Batch Size            | 16                                        |
| Ukuran Input Citra    | 640 × 640 piksel                          |
| Optimizer             | Default Ultralytics                       |
| Initial Learning Rate | 0.001                                     |
| Perangkat Komputasi   | Google Colab (NVIDIA Tesla T4 GPU)        |
| Dataset Split         | 70% Training, 20% Validation, 10% Testing |
| Preprocessing         | Tanpa CLAHE dan Dengan CLAHE              |

Berdasarkan konfigurasi tersebut, setiap model dilatih selama 100 epoch dengan ukuran input 640 × 640 piksel dan batch size 16. Precision, recall, training loss, validation loss, dan mAP dipantau selama proses pelatihan untuk mengevaluasi perkembangan performa model secara berkala [15].

### 3.5. Evaluasi Kinerja Model

Evaluasi performa dilakukan menggunakan testing set untuk mengukur kemampuan akhir masing-masing model dalam mendeteksi objek lalu lintas pada citra malam hari. Metrik evaluasi yang digunakan meliputi precision, recall, dan mean Average Precision (mAP) [6].

Precision digunakan untuk mengukur ketepatan prediksi model terhadap seluruh prediksi yang dihasilkan. Recall digunakan untuk mengukur kemampuan model dalam mendeteksi seluruh objek yang benar-benar ada pada citra. Sementara itu, mAP digunakan sebagai indikator utama performa keseluruhan model karena menggabungkan precision dan recall dalam berbagai threshold evaluasi.

Selain evaluasi numerik, penelitian ini juga melakukan analisis visual terhadap hasil deteksi berdasarkan kualitas bounding box, kemampuan mendeteksi objek kecil, performa pada area gelap, dan konsistensi antar kelas objek.

Hasil evaluasi dari keenam konfigurasi eksperimen dibandingkan untuk menentukan model terbaik, pengaruh CLAHE terhadap peningkatan performa, serta sensitivitas masing-masing model terhadap kualitas citra malam hari.

## 4. HASIL DAN PEMBAHASAN


Hasil penelitian ini menyajikan eksperimen berdasarkan pengujian tiga model deteksi objek, yaitu YOLOv5, YOLOv8, dan YOLO11, pada dua skenario berbeda, yakni menggunakan dataset original tanpa preprocessing dan dataset dengan preprocessing CLAHE. Evaluasi dilakukan secara kuantitatif menggunakan precision, recall, dan mean Average Precision (mAP), serta secara visual melalui analisis kualitas citra dan hasil deteksi objek. Pendekatan ini memungkinkan analisis komprehensif terhadap pengaruh peningkatan kualitas citra serta perkembangan arsitektur model terhadap performa deteksi objek lalu lintas pada malam hari.

### 4.1. Hasil Pelatihan Model

Proses pelatihan dilakukan menggunakan dataset citra malam hari yang telah dianotasi dengan enam kategori objek, yaitu mobil, sepeda motor, bus, truk, rambu lalu lintas, dan pejalan kaki. Seluruh model dilatih menggunakan konfigurasi hyperparameter yang sama agar hasil eksperimen dapat dibandingkan secara objektif. Berdasarkan hasil pelatihan, seluruh model menunjukkan kemampuan konvergensi yang baik, namun terdapat perbedaan pada kecepatan pembelajaran dan stabilitas loss. YOLOv5 [3] menunjukkan pola training loss yang stabil, tetapi memerlukan waktu lebih lama untuk mencapai performa optimal. YOLOv8 [4] menunjukkan proses konvergensi yang lebih cepat dengan validation loss yang lebih stabil, sedangkan YOLO11 [5] menunjukkan efisiensi pelatihan terbaik dengan penurunan loss yang lebih konsisten.

Penerapan CLAHE pada dataset memberikan dampak positif terhadap proses pelatihan. Dataset dengan preprocessing CLAHE menghasilkan pola pembelajaran yang lebih stabil, khususnya pada tahap awal pelatihan, karena peningkatan kontras citra membantu model mengenali fitur visual objek secara lebih jelas [11], [12].

Grafik hasil pelatihan pada Gambar 4 menunjukkan bahwa nilai loss mengalami penurunan secara bertahap seiring bertambahnya epoch, yang menandakan bahwa model berhasil mempelajari pola objek dari dataset secara progresif.



Gambar 4. Grafik Perkembangan Loss dan Metrik Evaluasi Selama Proses Pelatihan Model YOLO11 pada Dataset dengan Preprocessing CLAHE

Grafik pada Gambar 4 menunjukkan proses pelatihan model YOLO11 yang ditandai dengan penurunan nilai loss secara bertahap pada data training dan validasi. Nilai train loss dan validation loss mengalami penurunan yang konsisten seiring bertambahnya epoch, yang menunjukkan bahwa model berhasil mempelajari pola pada data secara efektif.

Selain itu, nilai precision dan recall menunjukkan fluktuasi pada awal pelatihan, kemudian cenderung stabil pada epoch selanjutnya. Hal ini merupakan karakteristik umum dalam proses pelatihan model deep learning.

Nilai mean Average Precision (mAP) mengalami peningkatan signifikan pada awal pelatihan dan kemudian mencapai kondisi stabil, yang menunjukkan bahwa model telah mencapai konvergensi dan mampu mendeteksi objek dengan cukup baik pada dataset yang digunakan [15].

#### 4.2. Hasil Evaluasi Model

Evaluasi kuantitatif dilakukan terhadap enam konfigurasi eksperimen untuk membandingkan performa masing-masing model secara objektif. Hasil evaluasi lengkap ditunjukkan pada Tabel 3.

Tabel 3. Perbandingan Nilai Precision, Recall, dan mAP pada Seluruh Konfigurasi Model

| Model  | Preprocessing | Precision | Recall | mAP   |
|--------|---------------|-----------|--------|-------|
| YOLOv5 | Tanpa CLAHE   | 0.602     | 0.443  | 0.509 |
| YOLOv5 | CLAHE         | 0.614     | 0.476  | 0.600 |
| YOLOv8 | Tanpa CLAHE   | 0.772     | 0.435  | 0.491 |
| YOLOv8 | CLAHE         | 0.607     | 0.476  | 0.497 |
| YOLO11 | Tanpa CLAHE   | 0.709     | 0.418  | 0.475 |
| YOLO11 | CLAHE         | 0.527     | 0.505  | 0.494 |

Berdasarkan Tabel 3, penerapan preprocessing CLAHE memberikan dampak yang berbeda pada masing-masing model. Pada YOLOv5, terjadi peningkatan performa yang signifikan dengan nilai mAP meningkat dari 0,509 menjadi 0,600. Selain itu, recall juga meningkat dari 0,443 menjadi 0,476, yang menunjukkan bahwa model menjadi lebih sensitif dalam mendeteksi objek setelah peningkatan kualitas citra.

Pada YOLOv8, penerapan CLAHE menghasilkan peningkatan mAP yang relatif kecil, yaitu dari 0,491 menjadi 0,497. Namun demikian, terjadi penurunan nilai precision dari 0,772 menjadi 0,607, yang menunjukkan bahwa peningkatan kontras citra juga menyebabkan peningkatan deteksi yang kurang relevan (false positive).

Sementara itu, pada YOLO11, nilai mAP meningkat dari 0,475 menjadi 0,494, disertai dengan peningkatan recall dari 0,418 menjadi 0,505. Hal ini menunjukkan bahwa CLAHE membantu model dalam mendeteksi lebih banyak objek, meskipun dengan penurunan precision dari 0,709 menjadi 0,527.

Hasil ini menunjukkan bahwa preprocessing CLAHE cenderung meningkatkan kemampuan deteksi objek (recall), namun pada beberapa kasus dapat menurunkan ketepatan deteksi (precision), sehingga menghasilkan trade-off antara kedua metrik tersebut.


Nilai evaluasi diperoleh langsung dari hasil validasi model menggunakan framework Ultralytics pada dataset pengujian.

#### 4.3. Analisis Pengaruh CLAHE

Penerapan CLAHE terbukti memberikan dampak positif terhadap performa seluruh model yang diuji. CLAHE meningkatkan distribusi pencahayaan lokal pada citra malam hari sehingga objek seperti kendaraan, pejalan kaki, dan rambu lalu lintas menjadi lebih jelas [10], [11].

Pada kondisi tanpa preprocessing, beberapa citra menunjukkan area underexposed dan detail objek yang kurang terlihat, terutama pada area dengan pencahayaan minim. Setelah preprocessing CLAHE diterapkan, detail visual meningkat secara signifikan sehingga model mampu mengekstraksi fitur secara lebih optimal.

Perbandingan histogram pada Gambar 5 menunjukkan bahwa citra original memiliki distribusi intensitas yang cenderung terpusat pada area gelap, sedangkan citra hasil CLAHE memiliki distribusi yang lebih merata pada rentang intensitas yang lebih luas.



Gambar 5. Histogram Distribusi Intensitas Citra Sebelum dan Sesudah CLAHE



Distribusi intensitas yang lebih merata menunjukkan bahwa CLAHE berhasil meningkatkan kontras lokal dan memperluas rentang dinamis citra, sehingga detail visual objek menjadi lebih jelas terutama pada area dengan pencahayaan rendah. Pada citra original, distribusi intensitas didominasi oleh nilai rendah yang menunjukkan kondisi underexposed dan rendahnya variasi intensitas. Setelah penerapan CLAHE, distribusi intensitas menjadi lebih menyebar ke rentang menengah, yang mengindikasikan peningkatan kualitas pencahayaan dan visibilitas objek.

Perbaikan distribusi intensitas ini berdampak langsung pada kemampuan model dalam mengekstraksi fitur visual, sehingga meningkatkan performa deteksi objek. Besarnya peningkatan performa akibat penerapan CLAHE ditunjukkan pada Tabel 4.

Tabel 4. Peningkatan Nilai mAP Setelah Penerapan CLAHE

| Model  | mAP Tanpa CLAHE | mAP Dengan CLAHE | Peningkatan (%) |
|--------|-----------------|------------------|-----------------|
| YOLOv5 | 0.509           | 0.600            | +17.95%         |
| YOLOv8 | 0.491           | 0.497            | +1.28%          |
| YOLO11 | 0.475           | 0.494            | +4.09%          |

Berdasarkan Tabel 4, peningkatan performa terbesar terjadi pada YOLOv5 dengan peningkatan mAP sebesar 17,95%, yang menunjukkan bahwa model baseline sangat terbantu oleh peningkatan kualitas citra. YOLO11 mengalami peningkatan sebesar 4,09%, sedangkan YOLOv8 hanya mengalami peningkatan sebesar 1,28%.

Hal ini menunjukkan bahwa pengaruh CLAHE lebih signifikan pada model dengan kemampuan ekstraksi fitur yang lebih sederhana, sedangkan model yang lebih kompleks seperti YOLOv8 dan YOLO11 telah memiliki kemampuan adaptasi terhadap kondisi pencahayaan yang lebih baik, sehingga peningkatan performa yang dihasilkan relatif lebih kecil.

Selain itu, peningkatan recall yang disertai dengan penurunan precision pada beberapa model menunjukkan bahwa CLAHE meningkatkan sensitivitas model terhadap objek, namun juga meningkatkan kemungkinan kesalahan deteksi pada kondisi tertentu.


#### 4.4. Perbandingan Kinerja Model

Berdasarkan seluruh hasil evaluasi, perkembangan arsitektur YOLO menunjukkan pengaruh signifikan terhadap performa deteksi objek pada kondisi malam hari. YOLOv5 sebagai baseline menghasilkan performa terendah, meskipun tetap mengalami peningkatan setelah CLAHE diterapkan. YOLOv8 menunjukkan nilai precision tertinggi, sedangkan YOLOv5 memperoleh peningkatan

performa terbesar setelah penerapan CLAHE, khususnya pada precision dan mAP [14].

YOLO11 menunjukkan performa yang kompetitif dengan keseimbangan antara precision dan recall, sementara YOLOv8 unggul dalam precision dan YOLOv5 memperoleh peningkatan terbesar setelah penerapan CLAHE. [5], [1].

Perbandingan performa antar model divisualisasikan pada Gambar 6.



Gambar 6. Perbandingan Nilai mAP Antar Model pada Skenario Tanpa CLAHE dan Dengan CLAHE

YOLOv5 menunjukkan performa paling rendah secara keseluruhan, namun memperoleh peningkatan paling signifikan setelah preprocessing. YOLOv8 menunjukkan keseimbangan terbaik antara performa dan stabilitas, sedangkan YOLO11 menunjukkan performa yang kompetitif dengan keseimbangan antara precision dan recall.


Perbedaan performa ini menunjukkan bahwa perkembangan arsitektur YOLO berkontribusi langsung terhadap peningkatan kemampuan deteksi objek pada lingkungan visual kompleks.

#### 4.5. Analisis Visual Deteksi Objek

Selain evaluasi numerik, penelitian ini juga melakukan analisis visual terhadap hasil deteksi objek untuk menilai kualitas bounding box, akurasi lokasi objek, dan kestabilan deteksi pada berbagai kondisi pencahayaan. Pada skenario tanpa preprocessing, beberapa objek kecil seperti sepeda motor, pejalan kaki, dan rambu lalu lintas pada area gelap cenderung kurang terdeteksi atau menghasilkan bounding box yang kurang presisi. Setelah preprocessing CLAHE diterapkan, objek terlihat lebih jelas sehingga hasil deteksi menjadi lebih akurat [13].

YOLO11 dengan CLAHE menunjukkan performa visual terbaik karena mampu menghasilkan bounding box yang lebih stabil, akurat, dan konsisten pada berbagai kelas objek.

Perbandingan visual hasil deteksi pada Gambar 7 menunjukkan bahwa penerapan CLAHE meningkatkan kejelasan objek sehingga model mampu menghasilkan deteksi yang lebih stabil dan bounding box yang lebih presisi.



Gambar 7. Perbandingan hasil deteksi objek menggunakan YOLOv5, YOLOv8, dan YOLO11 pada citra original dan citra dengan preprocessing CLAHE

Gambar 7 menunjukkan perbandingan hasil deteksi objek pada tiga model yang diuji, baik pada citra original maupun citra dengan preprocessing CLAHE. Pada citra tanpa preprocessing, beberapa objek pada area dengan pencahayaan rendah terlihat kurang jelas dan menghasilkan bounding box yang kurang presisi. Setelah penerapan CLAHE, objek menjadi lebih kontras sehingga model mampu mendeteksi objek dengan lebih akurat.

Secara visual, terlihat bahwa jumlah objek yang terdeteksi meningkat pada citra dengan CLAHE, serta bounding box yang dihasilkan lebih stabil. YOLO11 menunjukkan performa visual terbaik dengan deteksi yang lebih konsisten dibandingkan YOLOv5 dan YOLOv8. Contoh false positive dan false negative ditunjukkan pada Gambar 8.



Gambar 8. Contoh kesalahan deteksi berupa false positive dan false negative pada kondisi pencahayaan rendah

Pada Gambar 8, false positive terjadi ketika model mendeteksi objek yang tidak sesuai dengan kondisi sebenarnya, seperti deteksi objek pada area

jalan atau pencahayaan yang menyerupai bentuk objek tertentu. Hal ini umumnya disebabkan oleh refleksi cahaya atau pola visual yang menyerupai objek pada kondisi malam hari.

Sementara itu, false negative terjadi ketika objek yang sebenarnya ada tidak berhasil terdeteksi oleh model. Pada contoh yang ditunjukkan, objek kendaraan pada jarak tertentu tidak terdeteksi, yang kemungkinan disebabkan oleh ukuran objek yang kecil serta kondisi pencahayaan yang terbatas.

Hasil ini menunjukkan bahwa meskipun performa model telah meningkat dengan preprocessing CLAHE, tantangan deteksi pada kondisi low-light masih memerlukan pengembangan lebih lanjut [9], terutama dalam menangani objek kecil dan variasi pencahayaan ekstrem.

#### 4.6. Pembahasan

Secara keseluruhan, hasil penelitian menunjukkan bahwa performa deteksi objek pada citra malam hari dipengaruhi oleh dua faktor utama, yaitu kualitas citra masukan dan kemampuan arsitektur model. CLAHE terbukti efektif dalam meningkatkan kualitas visual citra melalui peningkatan kontras lokal, distribusi intensitas yang lebih merata, serta peningkatan visibilitas objek [10], [11].

Sementara itu, perkembangan arsitektur YOLO dari YOLOv5 ke YOLOv8 dan YOLO11 menunjukkan peningkatan signifikan dalam hal precision, recall, dan mAP. Namun, peningkatan tersebut tidak selalu terjadi pada seluruh metrik, di mana beberapa model mengalami penurunan precision sebagai konsekuensi dari peningkatan recall.

Dengan demikian, kombinasi antara preprocessing citra yang tepat dan pemilihan arsitektur model yang sesuai merupakan strategi efektif dalam meningkatkan performa sistem deteksi objek lalu lintas pada kondisi pencahayaan rendah. Temuan ini memperkuat pentingnya integrasi antara image enhancement dan deep learning dalam pengembangan sistem transportasi cerdas berbasis computer vision.

#### 5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian yang telah dilakukan, penerapan Contrast Limited Adaptive Histogram Equalization (CLAHE) terbukti mampu meningkatkan kualitas citra lalu lintas pada kondisi malam hari melalui peningkatan kontras lokal. Peningkatan kualitas citra ini berdampak pada peningkatan visibilitas objek sehingga membantu model dalam proses ekstraksi fitur. Hasil eksperimen menunjukkan bahwa penerapan CLAHE secara umum meningkatkan nilai mean Average Precision (mAP) pada seluruh model yang diuji, meskipun tidak selalu diikuti oleh peningkatan pada seluruh metrik evaluasi.

Secara kuantitatif, YOLOv5 mengalami peningkatan performa paling signifikan dengan kenaikan nilai mAP dari 0,509 menjadi 0,600 (peningkatan sebesar 17,95%). YOLO11 juga mengalami peningkatan dari 0,475 menjadi 0,494



(4,09%), sedangkan YOLOv8 menunjukkan peningkatan yang relatif kecil dari 0,491 menjadi 0,497 (1,28%). Selain itu, hasil eksperimen menunjukkan adanya trade-off antara precision dan recall pada beberapa model, di mana peningkatan recall akibat CLAHE disertai dengan penurunan precision, yang mengindikasikan peningkatan sensitivitas deteksi namun juga peningkatan potensi kesalahan deteksi (false positive).

Hasil analisis komparatif menunjukkan bahwa model dengan arsitektur yang lebih sederhana seperti YOLOv5 memperoleh manfaat yang lebih besar dari preprocessing CLAHE dibandingkan model yang lebih kompleks. Sementara itu, model generasi lebih baru seperti YOLOv8 dan YOLO11 menunjukkan performa yang lebih stabil dan kemampuan generalisasi yang lebih baik pada kondisi tanpa preprocessing, sehingga peningkatan yang diperoleh relatif lebih kecil. Meskipun demikian, secara keseluruhan YOLO11 tetap menunjukkan performa terbaik dibandingkan model lainnya, khususnya dalam hal keseimbangan antara precision, recall, dan stabilitas deteksi.

Dengan demikian, dapat disimpulkan bahwa kombinasi antara peningkatan kualitas citra melalui CLAHE dan pemilihan arsitektur model yang tepat merupakan faktor penting dalam meningkatkan performa deteksi objek pada kondisi pencahayaan rendah. Namun, efektivitas CLAHE bergantung pada karakteristik model yang digunakan, sehingga penerapannya perlu disesuaikan dengan kebutuhan dan konteks sistem yang dikembangkan.

Meskipun penelitian ini memberikan hasil yang relevan, masih terdapat beberapa keterbatasan. Dataset yang digunakan relatif terbatas baik dari segi jumlah maupun variasi kondisi lingkungan, sehingga belum sepenuhnya merepresentasikan kondisi nyata seperti hujan, kabut, pencahayaan ekstrem, atau kepadatan lalu lintas yang tinggi. Selain itu, penelitian ini hanya berfokus pada evaluasi akurasi menggunakan precision, recall, dan mAP, tanpa mempertimbangkan aspek efisiensi komputasi seperti kecepatan inferensi, latency, dan performa real-time. Penggunaan satu metode preprocessing (CLAHE) serta fokus pada keluarga model YOLO juga menjadi batasan dalam eksplorasi metode yang lebih luas.

Oleh karena itu, penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih besar dan beragam agar kemampuan generalisasi model dapat diuji secara lebih komprehensif. Selain itu, eksplorasi metode preprocessing lain seperti Retinex atau deep learning-based enhancement, serta penggunaan arsitektur deteksi objek lain di luar YOLO, dapat memberikan perspektif yang lebih luas. Evaluasi terhadap aspek efisiensi komputasi dan implementasi real-time juga perlu dilakukan agar hasil penelitian dapat diterapkan secara optimal pada sistem transportasi cerdas di lingkungan nyata.

## DAFTAR PUSTAKA

- [1] Y. Zhang, X. Wang, and Z. Li, "Deep Learning-Based Object Detection for Autonomous Driving: A Survey," *Information Fusion*, vol. 73, pp. 23–45, 2021, doi: 10.1016/j.inffus.2020.10.006.
- [2] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 779–788. [Online]. Available: [https://openaccess.thecvf.com/content\\_cvpr\\_2016/html/Redmon\\_You\\_Only\\_Look\\_CVPR\\_2016\\_paper.html](https://openaccess.thecvf.com/content_cvpr_2016/html/Redmon_You_Only_Look_CVPR_2016_paper.html)
- [3] G. Jocher and others, "YOLOv5 by Ultralytics," 2021. [Online]. Available: <https://github.com/ultralytics/yolov5>
- [4] G. Jocher and others, "Ultralytics YOLOv8 Documentation," 2023. [Online]. Available: <https://docs.ultralytics.com>
- [5] Ultralytics, "Ultralytics YOLO11 Documentation," 2024. [Online]. Available: <https://docs.ultralytics.com/models/yolo11/>
- [6] J. Li, Y. Zhang, and H. Liu, "Real-Time Traffic Object Detection Based on Improved YOLO Algorithm," *Sensors*, vol. 23, no. 3, p. 1345, 2023, doi: 10.3390/s23031345.
- [7] Y.-P. Loh and C. S. Chan, "Getting to Know Low-Light Images with the Exclusively Dark Dataset," *arXiv preprint arXiv:1903.11227*, 2019, [Online]. Available: <https://arxiv.org/abs/1903.11227>
- [8] W. Wang, C. Wei, W. Yang, and J. Liu, "Deep Learning for Low-Light Image Enhancement: A Survey," *Pattern Recognit.*, vol. 124, p. 108404, 2022, doi: 10.1016/j.patcog.2021.108404.
- [9] Z. Han, Z. Yue, and L. Liu, "3L-YOLO: A Lightweight Low-Light Object Detection Algorithm," *Applied Sciences*, vol. 15, no. 1, p. 90, 2025, doi: 10.3390/app15010090.
- [10] A. M. Reza, "Realization of the Contrast Limited Adaptive Histogram Equalization (CLAHE) for Real-Time Image Enhancement," *IEEE Transactions on Consumer Electronics*, vol. 50, no. 1, pp. 38–43, 2004, doi: 10.1109/TCE.2004.1277847.
- [11] G. Yadav, S. Maheshwari, and A. Agarwal, "Contrast Limited Adaptive Histogram Equalization Based Enhancement for Real-Time Image Processing," *Optik (Stuttg.)*, vol. 252, p. 167033, 2022, doi: 10.1016/j.optik.2021.167033.
- [12] S. Kumar and R. Gupta, "Performance Analysis of CLAHE for Image Enhancement," *Multimed. Tools Appl.*, 2021, doi: 10.1007/s11042-020-09528-3.
- [13] C. Dewi, H. P. Chernovita, S. A. Philemon, C. A. Ananta, G. Dai, and A. P. S. Chen, "Integration of YOLO and Contrast Limited Adaptive Histogram Equalization for Nighttime Traffic

- Sign Detection,” *Mathematical Modelling of Engineering Problems*, vol. 12, no. 1, pp. 37–45, 2025, doi: 10.18280/mmep.120105.
- [14] E. Panja, Hendry, and C. Dewi, “YOLOv8 Analysis for Vehicle Classification Under Various Image Conditions,” *Scientific Journal of Informatics*, vol. 11, no. 1, pp. 127–138, 2024, doi: 10.15294/sji.v11i1.49038.
- [15] R. Padilla, W. L. Passos, T. L. B. Dias, S. L. Netto, and E. A. B. da Silva, “A Comparative Analysis of Object Detection Metrics with a Companion Open-Source Toolkit,” *Pattern Recognit.*, vol. 113, p. 107617, 2021, doi: 10.1016/j.patcog.2020.107617