



Optimalisasi Sistem Deteksi Parkir Menggunakan YOLOv7 dan CLAHE

Mochammad Fahmi Yasir^{*1}, Achmad Junaidi², Muhammad Muharrom Al Haromainy³

¹Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional “Veteran” Jawa Timur, Surabaya, Indonesia

Email: 21081010001@student.upnjatim.ac.id¹; achmadjunaidi.if@upnjatim.ac.id²;
muhhammad.muharrom.if@upnjatim.ac.id³

Yasir. M. F., Junaidi. A., & Al Haromainy. M. M. (2026). Optimalisasi Sistem Deteksi Parkir Menggunakan YOLOv7 dan CLAHE. *Journal Cerita: Creative Education of Research in Information Technology and Artificial Informatics*, 12(2), 220-231

DOI: <https://doi.org/10.33050/cerita.v12i2.3920>

ABSTRAK

Pertumbuhan jumlah kendaraan roda empat yang signifikan di Indonesia, khususnya di wilayah perkotaan, menimbulkan tantangan dalam pengelolaan lahan parkir yang efisien. Salah satu solusi yang dapat diterapkan adalah sistem deteksi parkir otomatis berbasis pemrosesan citra digital dan kecerdasan buatan. Penelitian ini bertujuan untuk mengembangkan sistem deteksi prototipe lahan parkir kosong menggunakan algoritma YOLOv7 yang dioptimalkan dengan metode peningkatan citra CLAHE (Contrast Limited Adaptive Histogram Equalization). Dataset citra diambil dari prototipe parkir satu lantai dengan berbagai kondisi pencahayaan, kemudian dilakukan tahap preprocessing menggunakan CLAHE untuk meningkatkan visibilitas fitur penting dalam citra, terutama pada kondisi low-light. Hasil pelatihan menunjukkan bahwa penerapan CLAHE mampu meningkatkan akurasi deteksi dibandingkan dengan YOLOv7 tanpa optimasi. Evaluasi dilakukan berdasarkan metrik seperti precision, recall, F1-score, dan mean Average Precision (mAP). Sistem yang dikembangkan menunjukkan potensi signifikan dalam meningkatkan efisiensi penggunaan ruang parkir, sekaligus mengurangi waktu pencarian dan emisi karbon dari kendaraan. Penelitian ini berkontribusi pada pengembangan teknologi parkir cerdas yang efisien dan ramah lingkungan.

Kata kunci: YOLOv7, CLAHE, deteksi parkir, pengolahan citra, deep learning

ABSTRACT

The significant increase in the number of four-wheeled vehicles in Indonesia, particularly in urban areas, presents challenges in the efficient management of parking spaces. One potential solution is the implementation of an automated parking detection system based on digital image processing and artificial intelligence. This study aims to develop a prototype system for detecting vacant parking spots using the YOLOv7 algorithm, optimized with the Contrast Limited Adaptive Histogram Equalization (CLAHE) method. The image dataset was captured from a single-level parking prototype under various lighting conditions. CLAHE preprocessing was applied to enhance the visibility of essential image features, particularly in low-light scenarios. The training results showed that the use of CLAHE improved detection accuracy compared to YOLOv7 without optimization. Evaluation metrics included precision, recall, F1-score, and mean Average Precision (mAP). The developed system demonstrates significant potential in enhancing the efficiency of parking space usage, reducing search time, and lowering vehicle emissions. This research contributes to the advancement of efficient and environmentally friendly smart parking technologies.

Keywords: YOLOv7, CLAHE, parking detection, image processing, deep learning

I. PENDAHULUAN

Pertumbuhan pesat jumlah kendaraan pribadi, khususnya kendaraan roda empat, menjadi salah satu tantangan utama dalam tata kelola transportasi di wilayah perkotaan di Indonesia. Jawa Timur, sebagai salah satu provinsi dengan tingkat urbanisasi yang tinggi, mengalami peningkatan jumlah kendaraan roda empat secara konsisten dari tahun ke tahun. Berdasarkan data Badan Pusat Statistik (2023), tercatat bahwa jumlah kendaraan roda empat meningkat dari 1.883.822 unit pada tahun 2020 menjadi 2.076.146 unit pada tahun 2023. Laju pertumbuhan tersebut mencerminkan adanya peningkatan kebutuhan mobilitas masyarakat sekaligus menunjukkan tekanan terhadap infrastruktur penunjang transportasi, termasuk sistem perparkiran.

Peningkatan jumlah kendaraan tersebut tidak diimbangi dengan ketersediaan lahan parkir yang memadai. Fenomena ini menyebabkan ketidakseimbangan antara permintaan dan suplai tempat parkir, terutama di kawasan pusat kota, area komersial, dan fasilitas umum seperti kampus, rumah sakit, maupun pusat perbelanjaan. Dalam praktiknya, pengendara sering kali kesulitan menemukan tempat parkir yang kosong. Akibatnya, banyak pengemudi menghabiskan waktu untuk berkeliling mencari lahan parkir yang tersedia. Aktivitas ini tidak hanya membuang waktu dan meningkatkan stres pengemudi, tetapi juga berkontribusi secara signifikan terhadap kemacetan lalu lintas lokal, konsumsi bahan bakar yang tidak efisien, serta peningkatan emisi karbon dioksida (CO₂) (Dhutanggara et al., 2024).

Menurut penelitian (Huang et al., 2023), waktu rata-rata yang dihabiskan pengemudi untuk mencari tempat parkir di area padat dapat mencapai 15 hingga 30 menit. Selama periode tersebut, kendaraan yang terus beroperasi dalam kecepatan rendah dan sering berhenti memperburuk kondisi lalu lintas sekaligus meningkatkan pencemaran udara di sekitar. Dengan semakin meningkatnya kesadaran terhadap isu lingkungan dan efisiensi energi, maka dibutuhkan pendekatan baru dalam pengelolaan sistem parkir di kota-kota besar.

Seiring dengan kemajuan teknologi, berbagai pendekatan cerdas mulai diimplementasikan untuk menyelesaikan masalah tersebut. Salah satu pendekatan yang kini berkembang adalah sistem parkir cerdas (smart parking system) berbasis teknologi pengolahan citra digital dan kecerdasan buatan. Teknologi ini memungkinkan sistem untuk melakukan deteksi otomatis terhadap ketersediaan ruang parkir melalui kamera pemantau dan algoritma pemrosesan citra. Salah satu metode yang populer dan terbukti efektif adalah algoritma deteksi objek You Only Look Once (YOLO). YOLO merupakan algoritma deep learning yang dirancang untuk mendeteksi objek dalam gambar atau video secara real-time dengan akurasi dan kecepatan tinggi (Rachmawati & Widhyaestoeti, 2020).

Meskipun YOLO telah terbukti efektif dalam banyak kasus, terdapat sejumlah tantangan dalam penerapannya pada sistem deteksi parkir, terutama terkait kondisi pencahayaan. Dalam situasi low-light, seperti pagi hari, sore hari, atau saat cuaca mendung, kualitas citra yang ditangkap oleh kamera bisa menurun secara

signifikan. Penurunan kualitas ini berdampak pada akurasi deteksi objek oleh sistem. Oleh karena itu, diperlukan strategi tambahan untuk meningkatkan kualitas citra sebelum proses deteksi dilakukan.

Salah satu teknik peningkatan kualitas citra yang banyak digunakan adalah Contrast Limited Adaptive Histogram Equalization (CLAHE). CLAHE merupakan teknik peningkatan kontras adaptif yang bekerja dengan cara membagi citra ke dalam blok-blok kecil dan menerapkan histogram equalization secara lokal pada tiap blok. Teknik ini terbukti efektif dalam meningkatkan kontras citra, terutama pada kondisi pencahayaan rendah atau kontras rendah. Dalam penelitian oleh (Phimphisan & Sriwiboon, 2024), penggunaan CLAHE dalam klasifikasi citra medis berhasil meningkatkan akurasi dari 97,69% menjadi 99,69%. Penelitian lain oleh (Attaqwa et al., 2024) juga menunjukkan bahwa penggunaan CLAHE mampu meningkatkan akurasi deteksi citra sebesar 20% dibandingkan metode yang tidak menggunakan pra-pemrosesan.


Integrasi antara algoritma YOLOv7 dan metode pra-pemrosesan gambar CLAHE berpotensi meningkatkan kemampuan sistem dalam mendeteksi kondisi lahan parkir secara lebih akurat pada berbagai kondisi pencahayaan. Pendekatan ini diharapkan dapat menjadi solusi yang efektif untuk mendukung implementasi aturan keselamatan berkendara, khususnya dalam situasi dengan pencahayaan rendah (Kusuma et al., 2021).

Penelitian ini memiliki kebaruan pada integrasi metode CLAHE sebagai tahap prapemrosesan citra sebelum proses deteksi menggunakan YOLOv7 pada sistem deteksi parkir. Berbeda dengan penelitian terdahulu yang umumnya hanya memanfaatkan model deteksi objek secara langsung, penelitian ini mengevaluasi pengaruh peningkatan kualitas citra terhadap performa deteksi pada berbagai kondisi pencahayaan sehingga diharapkan mampu meningkatkan akurasi sistem parkir cerdas.

II. METODE PENELITIAN

Untuk memastikan bahwa pelaksanaan penelitian berlangsung secara sistematis, terarah, dan mampu menjawab permasalahan yang dikaji, diperlukan pendekatan metodologis yang terstruktur serta berlandaskan pada konsep yang

jas. Dalam penelitian ini, berbagai metode dipilih secara cermat untuk menjamin validitas dan reliabilitas data yang dihasilkan. Selain itu, guna memberikan gambaran menyeluruh mengenai alur kerja penelitian, digunakan blok diagram sebagai representasi visual dari tahapan eksperimen yang dilakukan.



Gambar 1. Tahapan Penelitian

A. Akuisi Data

Sebagai langkah awal dalam implementasi sistem deteksi lahan parkir kosong, dilakukan proses akuisisi data yang bertujuan untuk menyediakan citra-citra yang merepresentasikan kondisi lapangan secara akurat. Prototipe lahan parkir dibangun untuk mensimulasikan area parkir di lingkungan perkotaan, yang selanjutnya menjadi objek utama dalam pengambilan gambar. Data citra diperoleh dari dua sumber, yaitu dataset publik yang diakses melalui platform Roboflow, serta citra yang diambil secara langsung menggunakan kamera ponsel. Kamera ditempatkan pada posisi strategis guna memperoleh sudut pandang optimal dan menangkap area parkir secara menyeluruh, termasuk dalam berbagai kondisi pencahayaan. Seluruh data yang dikumpulkan akan melalui tahap pra-pemrosesan sebelum digunakan dalam pelatihan dan pengujian model.

Tabel 1. Akuisisi Data


Jenis Dataset	Jumlah	Persentase
Data Latih	5.600	70%
Data Validasi	1.600	20%
Data Uji	800	10%

Untuk mendukung proses pelatihan model deteksi, pada tabel 1 dataset dibagi menjadi tiga bagian: data pelatihan, validasi, dan pengujian. Pembagian ini mengikuti proporsi umum yang digunakan dalam pengembangan model pembelajaran mesin.

B. Pre Processing

Setelah proses akuisisi data selesai dilakukan, langkah selanjutnya adalah tahap *pre processing data*. Tahap ini bertujuan untuk

memastikan bahwa data yang diperoleh memiliki kualitas yang layak dan sesuai standar, sehingga dapat digunakan secara optimal pada proses pelatihan model selanjutnya.



Gambar 2. Preprocessing Data

Gambar 2 menyajikan tahapan *pre processing* yang diterapkan untuk menyempurnakan kualitas citra mentah. Proses ini dilakukan agar data yang dihasilkan memiliki karakteristik yang lebih konsisten dan relevan, sehingga mendukung efektivitas analisis serta pelatihan model deteksi objek.

1. Pembagian Data

Tahap awal dalam proses *pre-processing* adalah pembagian dataset, yang bertujuan untuk mengorganisasi data agar siap digunakan dalam pelatihan dan pengujian model. Dataset berasal dari dua sumber utama, yaitu Roboflow (untuk pelatihan) dan citra hasil tangkapan langsung menggunakan kamera ponsel serta kamera digital (untuk pengujian). Dataset dibagi ke dalam tiga kelas utama, yakni *free* (lahan parkir kosong), *full* (lahan parkir terisi), dan *car* (kendaraan yang terdeteksi di area parkir penuh). Proses pengelolaan dataset dilakukan melalui platform Roboflow untuk efisiensi dan konsistensi data.

2. Rename Image

Tahap *rename citra* merupakan bagian penting dalam pengelolaan dataset, yang bertujuan untuk memastikan bahwa setiap file gambar memiliki nama yang konsisten, terstruktur, dan mudah dikenali. Penamaan ulang ini tidak hanya memudahkan proses identifikasi file, tetapi juga mendukung efisiensi dalam pelabelan dan pelatihan model deteksi.

Dalam penelitian ini, proses *rename* dilakukan berdasarkan kategori waktu pengambilan gambar, yaitu pagi, siang, sore, dan malam, guna merepresentasikan perbedaan kondisi pencahayaan secara natural. Setiap citra diberi nama sesuai kategorinya dengan format seperti *pagi_001*, *siang_045*, atau *malam_1000*, dan dikelompokkan ke dalam folder yang sesuai.

Meskipun proses ini dilakukan secara manual, ketelitian tetap dijaga untuk memastikan seluruh dataset memiliki format penamaan yang

seragam. Penamaan yang sistematis ini sangat membantu dalam proses *pre-processing* lanjutan, termasuk pelabelan dan pelatihan model deteksi menggunakan algoritma YOLOv7.

3. Clahe Enhancement

CLAHE merupakan pengembangan dari metode Adaptive Histogram Equalization (AHE) dengan penambahan batas peningkatan kontras guna mencegah munculnya noise berlebih atau efek *over-enhancement*. Proses ini bekerja dengan membagi citra menjadi beberapa blok kecil (*tiles*), lalu melakukan pemerataan histogram pada masing-masing blok secara independen. Agar hasilnya lebih natural dan tidak menimbulkan artefak visual, CLAHE menginterpolasi nilai piksel antar blok.

$$CDF'(x) = \frac{CDF(x) - CDF_{min}}{CDF_{max} - CDF_{min}} \times (L - 1) \quad (1)$$

Salah satu elemen penting dalam algoritma CLAHE adalah proses pemangkasan histogram berdasarkan nilai ambang yang disebut *clip limit*. Histogram yang melebihi ambang ini akan dipotong, dan nilai kelebihannya akan disebarkan secara merata ke seluruh histogram sebelum perhitungan Cumulative Distribution Function (CDF) dilakukan. Dalam konteks ini, $CDF(x)$ merepresentasikan fungsi distribusi kumulatif dari intensitas piksel x , sementara CDF_{min} dan CDF_{max} adalah nilai minimum dan maksimum dari distribusi tersebut. Parameter L menunjukkan jumlah level intensitas dalam citra (Pratama et al., 2025).

Sebagai contoh, pada sebuah citra berukuran 100×100 piksel dengan tiga kanal warna (RGB), total 30.000 piksel akan diproses secara independen melalui algoritma ini untuk memperoleh distribusi intensitas yang lebih seimbang (Pratama et al., 2025).



Gambar 3. Preprocessing Clahe

Pendekatan ini terbukti efektif dalam meningkatkan kualitas visual citra sekaligus mempertahankan struktur informasi yang

dibutuhkan untuk tahap analisis lanjutan dan pelatihan model (Mudjirahardjo, 2024)

4. Anotasi Data

Setelah tahap pembagian dataset, rename citra, dan peningkatan kualitas gambar dengan CLAHE, proses berikutnya adalah anotasi data. Anotasi bertujuan untuk memberikan label pada objek dalam citra, sehingga model YOLOv7 dapat mengenali dan membedakan objek berdasarkan kelas yang telah ditentukan.

Proses anotasi dilakukan menggunakan platform Roboflow dan LabelImg. Roboflow menawarkan antarmuka berbasis web yang memudahkan pelabelan tanpa instalasi tambahan, sedangkan LabelImg memungkinkan anotasi manual dengan fitur bounding box dan menyimpan hasil dalam format teks (.txt) yang kompatibel dengan YOLOv7.

Dalam penelitian ini digunakan tiga kelas utama: free (lahan parkir kosong), full (lahan parkir terisi), dan car (kendaraan), masing-masing ditandai dengan warna berbeda yaitu hijau, ungu, dan merah. Kualitas anotasi yang baik sangat memengaruhi performa model dalam mendeteksi objek secara real-time, sehingga proses ini dilakukan secara teliti untuk memastikan akurasi data yang tinggi.

5. Augmentasi Data

Setelah proses anotasi data selesai, tahap berikutnya adalah augmentasi data. Augmentasi merupakan proses modifikasi citra yang bertujuan untuk menambah variasi dan jumlah data dalam dataset secara efektif. Dengan memperkaya ragam citra yang tersedia, augmentasi membantu model agar lebih adaptif terhadap perubahan kondisi dan variasi visual di dunia nyata. Hal ini juga berperan penting dalam mencegah model dari risiko overfitting serta meningkatkan kemampuan generalisasi saat melakukan deteksi objek.

Pada penelitian ini, augmentasi dilakukan menggunakan platform Roboflow, yang menyediakan berbagai teknik augmentasi secara mudah dan terintegrasi. Beberapa metode augmentasi yang diterapkan meliputi: (1) Vertical Flip, yakni membalik citra secara vertikal agar model dapat mengenali objek dari sudut pandang yang berbeda; (2) Penambahan Noise berupa bintik putih dengan intensitas sebesar 0,1%, yang bertujuan mensimulasikan kondisi citra dengan gangguan visual untuk melatih model agar tetap akurat meskipun menerima input dengan kualitas rendah; (3) Rotation sebesar 15 derajat untuk menambah

variasi orientasi objek, sehingga model menjadi lebih fleksibel dalam mendeteksi objek yang diputar; (4) Rotate 90° yang dilakukan bersamaan dengan penyesuaian tingkat kecerahan gambar, sehingga model mampu mengenali objek dalam berbagai kondisi pencahayaan, baik terang maupun redup; serta (5) Shear atau transformasi geser perspektif sebesar $\pm 10^\circ$, baik secara horizontal maupun vertikal.

Transformasi shear dilakukan dengan menggeser satu bagian citra ke arah tertentu sehingga tampak miring, mensimulasikan distorsi perspektif yang mungkin terjadi akibat posisi kamera yang tidak sejajar sempurna atau kendaraan yang berada dalam sudut tidak ideal terhadap lahan parkir. Pada penelitian ini, shear horizontal dan vertikal masing-masing diterapkan hingga $\pm 10^\circ$. Teknik ini bertujuan agar model dapat lebih fleksibel mengenali objek meskipun citra yang diterima memiliki distorsi perspektif atau ketidaksimetrian akibat sudut pengambilan gambar.

Dengan berbagai teknik augmentasi tersebut, model diharapkan mampu meningkatkan ketahanan terhadap variasi visual dan kondisi nyata yang beragam. Proses augmentasi ini sangat penting dalam memperluas cakupan data pelatihan serta mengoptimalkan akurasi model deteksi YOLOv7 yang digunakan dalam penelitian.

6. Split Data

Setelah seluruh dataset citra melewati tahapan anotasi dan augmentasi, langkah berikutnya adalah proses pembagian dataset atau split data. Tahapan ini bertujuan untuk mengorganisasi data secara sistematis agar dapat digunakan secara optimal dalam pelatihan, validasi, dan pengujian model deteksi parkir berbasis YOLOv7. Dataset yang digunakan telah dilabeli menjadi tiga kelas utama, yaitu “free” untuk area parkir kosong, “full” untuk area parkir yang terisi kendaraan, dan “car” sebagai penanda objek mobil di area parkir.

Pembagian data dilakukan menggunakan platform Roboflow yang menyediakan fitur split data otomatis dengan menjaga keseimbangan distribusi kelas di setiap subset. Pada penelitian ini, data dibagi dengan proporsi 70% untuk pelatihan (training), 20% untuk validasi (validation), dan 10% untuk pengujian (testing). Data pelatihan berfungsi untuk mengajarkan model mengenali pola objek, sedangkan data validasi digunakan untuk memantau dan mengoptimalkan kinerja model selama pelatihan

guna menghindari overfitting. Data pengujian berperan dalam evaluasi akhir performa model.

Dengan pembagian dataset yang sistematis menggunakan platform andal, diharapkan model YOLOv7 yang dikembangkan mampu mendeteksi kondisi lahan parkir secara akurat dan stabil, meskipun dalam berbagai variasi pencahayaan, sudut pengambilan gambar, dan kondisi lingkungan yang kompleks.

C. YOLO

You Only Look Once (YOLO) merupakan metode deteksi objek berbasis deep learning yang dikenal luas karena kecepatan dan akurasi yang tinggi. Berbeda dengan metode tradisional yang mengandalkan teknik sliding window atau region proposal seperti R-CNN, YOLO menyederhanakan proses deteksi objek menjadi satu tahap regresi tunggal. Dengan menggunakan jaringan saraf konvolusional (CNN), YOLO secara langsung memprediksi posisi bounding box serta kelas objek dalam satu kali proses inferensi. Keunggulan kecepatan YOLO ini telah dibuktikan dalam studi oleh (Bochkovskiy et al., 2020), yang menunjukkan performa real-time dengan tingkat akurasi yang kompetitif dalam berbagai aplikasi deteksi objek.

D. YOLOv7


YOLOv7 merupakan versi terbaru dari keluarga algoritma You Only Look Once (YOLO) yang dirilis pada Juli 2022 dan menawarkan peningkatan signifikan dalam hal kecepatan dan akurasi deteksi objek. Sebagai salah satu metode deteksi objek real-time berbasis deep learning, YOLOv7 dirancang untuk memaksimalkan efisiensi baik dari sisi performa komputasi maupun ketepatan identifikasi objek dalam citra. Dibandingkan dengan pendahulunya seperti YOLOv4 dan YOLOv5, YOLOv7 berhasil melampaui performa model-model sebelumnya dalam berbagai pengujian, khususnya pada skenario real-time.

Model ini menunjukkan kemampuan luar biasa dalam kisaran kecepatan 5 hingga 160 FPS, dengan tingkat akurasi deteksi mencapai 56.8% Average Precision (AP) pada GPU V100, menjadikannya salah satu detektor tercepat dan paling akurat dalam tugas deteksi objek real-time (Cao et al., 2023). Peningkatan performa ini dicapai melalui integrasi pendekatan trainable bag-of-freebies, yang mampu meningkatkan akurasi tanpa menambah beban komputasi saat inferensi. Selain itu, YOLOv7 juga menerapkan

teknik re-parameterization dan penugasan label dinamis, yang membantu mengatasi tantangan dalam proses pelatihan model deteksi objek (Wang et al., 2023a).

Komponen E-ELAN memainkan peran penting dalam memperkuat proses pembelajaran jaringan dengan cara memperluas dan menggabungkan cardinality (jumlah jalur paralel dalam jaringan) tanpa harus mengubah struktur transisi data yang telah ada. Pendekatan ini memungkinkan jaringan untuk menyerap informasi lebih banyak dari berbagai jalur representasi, sehingga mendukung pembelajaran yang lebih dalam dan kaya.

Sebagaimana ditampilkan pada Gambar 4, YOLOv7 mencatat peningkatan kecepatan hingga 120% lebih tinggi dibandingkan YOLOv5 dan 180% lebih tinggi dari YOLOX. Bahkan ketika dibandingkan dengan model berbasis CNN dan transformer modern seperti ConvNext dan SWIN-L, YOLOv7 tetap unggul secara efisiensi dengan kecepatan 550% dan 500% lebih tinggi secara berturut-turut, tanpa penurunan akurasi (Cao et al., 2023). Dengan performa tersebut, YOLOv7 menjadi satu-satunya detektor yang mampu beroperasi di atas 30 FPS sambil tetap mempertahankan akurasi tinggi, sehingga sangat sesuai untuk digunakan dalam berbagai aplikasi deteksi objek real-time.



Gambar 4. Perbandingan Kecepatan YOLO V7

Selain itu, penggunaan *convolution group* dalam arsitektur YOLOv7 memberikan efisiensi yang lebih tinggi dalam proses ekstraksi fitur serta representasi data. Teknik ini membagi proses konvolusi menjadi beberapa bagian terpisah yang diproses secara paralel, sehingga tidak hanya mengurangi beban komputasi, tetapi juga mempertahankan kualitas informasi yang diekstrak dari citra. Dengan kombinasi elemen-elemen tersebut, YOLOv7 berhasil menciptakan model deteksi objek yang tidak hanya akurat,

tetapi juga cepat dan efisien dalam praktik nyata (Wang et al., 2023b).

E. Training Dataset

Pada tahap pelatihan model deteksi dalam penelitian ini, digunakan konfigurasi learning rate sebesar 0,001, yang merupakan nilai standar yang umum digunakan dalam pelatihan model YOLOv7. Nilai learning rate yang relatif kecil dipilih karena memberikan kestabilan dalam proses pelatihan dan membantu meningkatkan akurasi model secara bertahap. Meskipun memerlukan waktu pelatihan yang lebih lama, pendekatan ini mampu menghindari risiko ketidaksesuaian model (overfitting) terhadap data latih.

Dataset yang digunakan dalam pelatihan dibagi menjadi tiga subset utama, yaitu 70% untuk data latih (training set), 20% untuk data validasi (validation set), dan 10% untuk data uji (test set), dari total sekitar 8.000 citra. Proses pelatihan dijalankan selama 50 epoch, yang bertujuan agar model dapat mempelajari pola objek secara menyeluruh dan menghasilkan deteksi yang akurat.

Pelatihan model juga dilakukan dengan metode fine tuning, yaitu pelatihan lanjutan pada model pralatih (pre-trained) yang sebelumnya telah dilatih pada dataset berskala besar. Dalam proses ini, sebagian besar fitur awal model dibekukan (freezing) untuk mempertahankan representasi fitur dasar, sementara lapisan-lapisan tertentu dilatih ulang agar dapat menyesuaikan dengan karakteristik dataset penelitian. Penyesuaian terhadap hyperparameter seperti learning rate dan jumlah epoch juga dilakukan guna mengoptimalkan performa model deteksi dalam konteks spesifik yang diteliti.

Tabel 2. Konfigurasi *Hyperparameter*

Nama Parameter	Nilai
Jumlah Kelas	3
Ukuran dimensi citra	640
Batch Size	16
Epoch	50
Learning Rate	0.001

F. Evaluasi Model

Setelah model YOLOv7 selesai melalui proses pelatihan dan fine tuning, langkah selanjutnya adalah melakukan evaluasi terhadap performa model menggunakan data uji. Evaluasi ini bertujuan untuk menilai sejauh mana kemampuan model dalam mendeteksi objek


secara akurat dan konsisten berdasarkan data yang belum pernah dilihat sebelumnya. Proses evaluasi dilakukan menggunakan beberapa metrik utama, yaitu precision, recall, dan mean Average Precision (mAP), yang masing-masing digunakan untuk mengukur ketepatan deteksi, tingkat keberhasilan dalam menemukan objek yang benar, serta rata-rata akurasi deteksi dari seluruh kelas objek yang ada dalam dataset. Melalui evaluasi ini, dapat diketahui performa aktual model dalam kondisi nyata, serta sejauh mana model dapat diandalkan untuk mendeteksi objek pada citra dalam berbagai situasi lingkungan.

III. HASIL DAN PEMBAHASAN

Pada tahap ini membahas hasil implementasi dari sistem deteksi yang telah dirancang menggunakan model YOLOv7 dengan optimasi metode Contrast Limited Adaptive Histogram Equalization (CLAHE). Proses pengujian dilakukan terhadap dataset yang telah dilatih sebelumnya untuk mengevaluasi kemampuan model dalam mengidentifikasi ketersediaan lahan parkir mobil. Evaluasi mencakup performa deteksi pada citra dengan berbagai kondisi pencahayaan dan sudut pandang, guna memastikan efektivitas model dalam skenario nyata.

A. Evaluasi Model YOLOv7

Model YOLOv7 yang dilatih tanpa penerapan teknik preprocessing tambahan seperti CLAHE dievaluasi berdasarkan hasil confusion matrix terhadap tiga kelas utama, yaitu car, free, dan full. Evaluasi ini bertujuan untuk mengetahui sejauh mana kemampuan model dalam melakukan klasifikasi objek pada citra parkir.




Gambar 5 Matrix YOLO V7

Hasil evaluasi menunjukkan bahwa model dapat mengenali objek kendaraan (car) dengan nilai precision sebesar 81,5% dan recall sebesar 78,6%, yang mengindikasikan kinerja cukup baik dalam mendeteksi kendaraan, meskipun masih terdapat beberapa kesalahan prediksi. Pada kelas free, model menunjukkan akurasi yang lebih tinggi dengan precision sebesar 89,5% dan recall mencapai 94,4%, menandakan kemampuan yang sangat baik dalam mengenali area parkir kosong. Sementara itu, performa terbaik diperoleh pada kelas full, dengan nilai precision dan recall masing-masing sebesar 93,8%, mencerminkan tingkat akurasi yang tinggi dalam mendeteksi area parkir yang telah terisi kendaraan.

B. Evaluasi Model YOLOv7 + CLAHE

Setelah dilakukan pelatihan menggunakan model YOLOv7 yang telah dioptimalkan dengan metode Contrast Limited Adaptive Histogram Equalization (CLAHE), hasil evaluasi menunjukkan peningkatan kinerja yang signifikan dalam proses klasifikasi objek. Penerapan CLAHE bertujuan untuk memperbaiki kualitas kontras dan pencahayaan pada citra, sehingga membantu model dalam mendeteksi objek secara lebih akurat di berbagai kondisi visual.

Evaluasi dilakukan terhadap tiga kelas utama, yakni car, free, dan full. Hasil pengujian menunjukkan bahwa pada kategori car, model memperoleh precision sebesar 94,1% dan recall sebesar 96,0%, yang mencerminkan keandalan tinggi dalam mengenali kendaraan terparkir. Untuk kategori free, model mencapai precision sebesar 97,7% dan recall sebesar 96,6%, menunjukkan kemampuan luar biasa dalam mengidentifikasi area parkir kosong. Sementara pada kelas full, model mencatat precision sebesar 96,3% dan recall sebesar 95,1%, yang menandakan efektivitas kuat dalam mendeteksi area parkir yang telah terisi.




Gambar 6. Matrix YOLO V7 + CLAHE

Peningkatan performa ini mengindikasikan bahwa optimasi menggunakan CLAHE memberikan kontribusi positif terhadap kualitas hasil deteksi. Secara keseluruhan, model dengan CLAHE terbukti lebih akurat dibandingkan model tanpa preprocessing tambahan, terutama dalam kondisi pencahayaan yang bervariasi.


C. Perbandingan Grafik Model

Grafik evaluasi performa model YOLOv7 ditunjukkan pada Gambar 7 Berdasarkan grafik tersebut, performa deteksi pada masing-masing metrik seperti Recall vs Confidence, Precision vs Recall, F1 Score vs Confidence, dan Precision vs Confidence menunjukkan bahwa model memiliki kemampuan cukup baik dalam mendeteksi tiga kategori kelas: car, free, dan full. Nilai mAP@0.5 yang dicapai sebesar 0.643 mengindikasikan bahwa model cukup akurat dalam melakukan deteksi, meskipun masih terdapat beberapa prediksi yang kurang presisi pada kelas car. Hal ini terlihat dari grafik precision dan recall yang menurun lebih cepat dibandingkan kelas lainnya pada tingkat kepercayaan tinggi.



Gambar 7. Grafik Yolo V7

Pada Gambar 8 ditampilkan hasil evaluasi model YOLOv7 setelah penerapan teknik preprocessing menggunakan CLAHE. Grafik tersebut memperlihatkan peningkatan signifikan pada hampir seluruh metrik evaluasi dibandingkan model tanpa optimasi. Nilai mAP@0.5 naik menjadi 0.676, memperlihatkan bahwa model dengan CLAHE lebih andal dalam mengenali objek dalam berbagai kondisi pencahayaan. Selain itu, grafik precision dan recall untuk ketiga kelas cenderung lebih stabil dan lebih tinggi, terutama pada kelas free dan full, yang menunjukkan bahwa peningkatan kontras gambar membantu model mendeteksi objek dengan lebih akurat dan konsisten.



Gambar 8. Grafik Yolo V7 + CLAHE

Tabel 3 menyajikan perbandingan antara performa model YOLOv7 dan YOLOv7 dengan optimasi CLAHE. Dari tabel tersebut, terlihat bahwa semua metrik mengalami peningkatan setelah CLAHE diterapkan. Precision meningkat dari 0.881 menjadi 0.902, recall dari 0.883 menjadi 0.921, dan F1-score dari 0.882 menjadi 0.911. Sementara itu, mAP@0.5 juga naik dari 0.643 ke 0.676.

Tabel 3. Hasil cTrain Model YOLOv7 + CLAHE

	YOLOv7	YOLOv7 + CLAHE	Peningkatan
Precision	0.881	0.902	+2,38%
Recall	0.883	0.921	+4,30%
F1-Score	0.882	0.911	+3,29%
mAP@0.5	0.643	0.676	+5,13%


Peningkatan performa pada seluruh metrik evaluasi menunjukkan bahwa penerapan metode Contrast Limited Adaptive Histogram Equalization (CLAHE) memberikan kontribusi positif terhadap kualitas citra masukan sebelum proses deteksi dilakukan. Berdasarkan Tabel 3, nilai precision meningkat sebesar 2,38%, recall

sebesar 4,30%, F1-score sebesar 3,29%, dan mAP@0.5 sebesar 5,13% dibandingkan model YOLOv7 tanpa tahap prapemrosesan. CLAHE meningkatkan kontras lokal pada setiap bagian citra sehingga batas antara kendaraan, garis parkir, dan latar belakang menjadi lebih jelas, khususnya pada kondisi pencahayaan yang kurang optimal. Peningkatan kualitas visual tersebut memudahkan backbone YOLOv7 dalam mengekstraksi fitur objek secara lebih representatif sehingga jumlah false positive dan false negative dapat dikurangi. Temuan ini sejalan dengan penelitian Phimphisan dan Sriwiboon (2024) yang melaporkan bahwa penerapan CLAHE mampu meningkatkan kualitas fitur citra dan berkontribusi terhadap peningkatan akurasi model berbasis deep learning (Phimphisan & Sriwiboon, 2024).

Selain meningkatkan kualitas visual citra, CLAHE juga memberikan dampak terhadap kemampuan model dalam melakukan lokalisasi objek secara lebih konsisten. Hal ini ditunjukkan oleh peningkatan nilai mAP@0.5 dari 0,643 menjadi 0,676, yang mengindikasikan bahwa model lebih mampu mendeteksi posisi objek secara tepat pada berbagai kondisi pencahayaan. Dengan demikian, tahap prapemrosesan menggunakan CLAHE menjadi komponen penting dalam sistem deteksi parkir berbasis visi komputer, terutama untuk mendukung implementasi pada lingkungan nyata yang memiliki variasi intensitas cahaya sepanjang hari.


D. Hasil Visualisasi

Gambar 9 menunjukkan hasil visualisasi kinerja dari model YOLOv7 tanpa penerapan preprocessing CLAHE. Grafik pada baris atas menampilkan tren penurunan loss untuk box, objectness, dan classification, serta peningkatan nilai precision dan recall seiring bertambahnya jumlah epoch. Grafik pada baris bawah menunjukkan hasil evaluasi pada data validasi, termasuk val box loss, val objectness loss, dan val classification loss, yang semuanya menunjukkan tren menurun, mengindikasikan proses pelatihan yang stabil. Selain itu, nilai mAP@0.5 dan mAP@0.5:0.95 juga menunjukkan tren meningkat secara konsisten, yang mencerminkan bahwa model belajar untuk melakukan deteksi objek secara lebih akurat seiring waktu.



Gambar 9. Visualisasi Model YOLOv7

Pada gambar 10 yang merepresentasikan model YOLOv7 dengan optimasi CLAHE, tren penurunan loss pada box, objectness, dan classification tetap konsisten seperti model sebelumnya, namun menunjukkan nilai loss yang sedikit lebih rendah pada epoch-epoch akhir. Peningkatan signifikan terlihat pada nilai precision dan recall yang lebih tinggi dibandingkan model tanpa CLAHE. Grafik validasi juga menunjukkan peningkatan stabil, khususnya pada mAP@0.5 dan mAP@0.5:0.95 yang tampak meningkat lebih cepat dan mencapai nilai maksimum lebih awal. Hal ini menandakan bahwa penggunaan CLAHE berhasil meningkatkan kualitas fitur visual pada citra, sehingga model dapat mengenali objek dengan lebih baik.



Gambar 10. Visualisasi Model YOLOv7 + CLAHE

Berdasarkan hasil visualisasi kedua model, dapat disimpulkan bahwa model YOLOv7 yang dioptimalkan dengan CLAHE menunjukkan kinerja yang lebih baik dibandingkan model standar. Hal ini terlihat dari penurunan nilai loss yang lebih stabil, peningkatan nilai precision dan recall yang lebih signifikan, serta nilai mAP yang lebih tinggi pada data validasi. Visualisasi ini mendukung temuan sebelumnya bahwa metode CLAHE mampu meningkatkan efektivitas model dalam mendeteksi dan mengklasifikasikan kondisi lahan parkir secara lebih akurat dan konsisten.

E. Hasil Deteksi

Berdasarkan hasil implementasi model YOLOv7 yang telah dioptimasi dengan preprocessing menggunakan metode CLAHE, sistem deteksi berhasil mengidentifikasi objek pada setiap kelas dengan baik, yakni kelas car, free, dan full. Model mampu memberikan bounding box dan label yang akurat pada area parkir sesuai dengan kondisi aktual di prototipe lahan parkir yang digunakan. Penerapan CLAHE terbukti meningkatkan visibilitas fitur-fitur penting dalam citra, terutama pada area dengan pencahayaan yang tidak merata, sehingga mendukung proses klasifikasi objek secara optimal.



Gambar 11. Hasil Deteksi

Pengambilan gambar dilakukan dari sudut pandang atas (bird's eye view), yang memberikan perspektif menyeluruh terhadap seluruh area parkir. Sudut pengambilan gambar ini sangat mempengaruhi akurasi deteksi karena meminimalkan distorsi perspektif dan tumpang tindih antar objek. Dengan sudut ini, batas antar slot parkir lebih jelas terlihat, dan objek seperti mobil atau area kosong dapat dikenali secara lebih tepat oleh model. Oleh karena itu, kualitas dan sudut pengambilan gambar menjadi faktor penting dalam keberhasilan sistem deteksi ini.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem deteksi lahan parkir berbasis algoritma YOLOv7 yang dioptimalkan menggunakan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Hasil pengujian menunjukkan bahwa penerapan CLAHE mampu meningkatkan kualitas citra masukan sehingga memberikan peningkatan performa pada seluruh metrik evaluasi dibandingkan model YOLOv7

tanpa tahap prapemrosesan. Peningkatan tersebut ditunjukkan oleh nilai *precision*, *recall*, *F1-score*, dan *mAP@0.5*, yang mengindikasikan bahwa CLAHE efektif dalam membantu model mendeteksi kondisi lahan parkir secara lebih akurat pada berbagai kondisi pencahayaan.

Meskipun demikian, penelitian ini masih memiliki beberapa keterbatasan. Sistem dikembangkan dan diuji pada prototipe lahan parkir satu lantai sehingga belum sepenuhnya merepresentasikan kondisi parkir di lingkungan nyata yang lebih kompleks. Selain itu, performa deteksi masih dipengaruhi oleh posisi dan sudut pemasangan kamera, serta dapat mengalami penurunan pada kondisi pencahayaan yang sangat ekstrem, seperti bayangan yang berlebihan atau intensitas cahaya yang terlalu rendah maupun terlalu tinggi.

Untuk penelitian selanjutnya, model dapat dikembangkan menggunakan algoritma deteksi objek yang lebih mutakhir, seperti YOLOv8 atau YOLOv11, serta memanfaatkan dataset yang lebih besar dan lebih beragam agar kemampuan generalisasi model semakin baik. Pengembangan juga dapat dilakukan dengan menerapkan konfigurasi multi-kamera sehingga sistem mampu memantau area parkir yang lebih luas dan meminimalkan area yang tidak terjangkau oleh kamera.

Dari sisi implementasi, sistem yang dikembangkan memiliki potensi untuk diintegrasikan dengan ekosistem *smart parking*. Integrasi dengan perangkat *Internet of Things* (IoT), layanan *cloud monitoring*, dan aplikasi bergerak (*mobile applications*) memungkinkan informasi ketersediaan lahan parkir disajikan secara *real-time* kepada pengguna maupun pengelola. Dengan demikian, sistem tidak hanya berfungsi sebagai model deteksi objek, tetapi juga dapat menjadi bagian dari solusi manajemen parkir cerdas yang mendukung efisiensi penggunaan ruang parkir, mengurangi waktu pencarian tempat parkir, serta mendukung pengembangan kota cerdas (*smart city*).

DAFTAR PUSTAKA

Attaqwa, S. I., Puspaningrum, E. Y., Saputra, W. S. J., Pembangunan, U., Veteran, N., Timur, J., & Anyar, G. (2024). *IMPLEMENTASI CONTRAST LIMITED ADAPTIVE HISTOGRAM EQUALIZATION DALAM PENGOLAHAN GENERATIVE*. 12(3).

- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). *YOLOv4: Optimal Speed and Accuracy of Object Detection*. <http://arxiv.org/abs/2004.10934>
- Cao, L., Zheng, X., & Fang, L. (2023). The Semantic Segmentation of Standing Tree Images Based on the Yolo V7 Deep Learning Algorithm. *Electronics (Switzerland)*, 12(4). <https://doi.org/10.3390/electronics12040929>
- Dhutanggara, A., Handayani, D., Ningsih, U., & Zuliarso, E. (2024). *Optimasi Sistem Smart Parking Menggunakan Metode YOLO dan Algoritma A*(A-star)*. 852–861.
- Huang, X., Zhang, J., & Lin, Y. (2023). Intelligent Parking System Based on Big Data and Internet of Things. *Advances in Transdisciplinary Engineering*, 42, 733–742. <https://doi.org/10.3233/ATDE231013>
- Kusuma, T. A. A. H., Usman, K., & Saidah, S. (2021). People Counting for Public Transportations Using You Only Look Once Method. *Jurnal Teknik Informatika (Jutif)*, 2(1), 57–66. <https://doi.org/10.20884/1.jutif.2021.2.2.77>
- Mudjirahardjo, P. (2024). The Effect of Grayscale, CLAHE Image and Filter Images in Convolution Process. *Int. j. Adv. Multidisc. Res. Stud*, 4(3), 943–946.
- Phimphisan, S., & Sriwiboon, N. (2024). A Customized CNN Architecture with CLAHE for Multi-Stage Diabetic Retinopathy Classification. *Engineering, Technology and Applied Science Research*, 14(6), 18258–18263. <https://doi.org/10.48084/etasr.8932>
- Pratama, M. R., Hidayat, S. Z., Nuruddin, A. R., Niamaputri, H. W., & Kunci, K. (2025). *Optimasi Peningkatan Kontras Gambar Menggunakan Interval-Valued Intuitionistic Fuzzy Sets dan Contrast Limited Adaptive Histogram Equalization (CLAHE)*. 4(1), 307–317. <https://doi.org/10.31284/p.semtik.2025-1.6884>
- Rachmawati, F., & Widhyaestoeti, D. (2020). Deteksi Jumlah Kendaraan di Jalur SSA Kota Bogor Menggunakan Algoritma Deep Learning YOLO. *Prosiding LPPM UIKA Bogor*, 360–370.
- Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M.

- (2023a). *YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors*. 7464–7475. <https://doi.org/10.1109/cvpr52729.2023.00721>
- Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M. (2023b). *YOLOv7*. *Cvpr*, 7464–7475.
- Heryono, Dedy, Maslina, and LM Zainul. 2020. “Hubungan Tingkat Pengetahuan Terhadap Kepatuhan Safety Riding Pada Remaja Di Sma Negeri 8 Balikpapan.” *Identifikasi* 6(2): 314–20.
- Kusuma, Tsabita Al Asshifa Hadi, Koredianto Usman, and Sofia Saidah. 2021. “People Counting for Public Transportations Using You Only Look Once Method.” *Jurnal Teknik Informatika (Jutif)* 2(1): 57–66. doi:10.20884/1.jutif.2021.2.2.77.
- Maulidati, N, A D N Cahyo, K Irodattillah, and F Triawan. 2021. “Armadillo Modelled Foldable Motorcycle Helmet: A Preliminary Design Concept for Rider in Indonesia.” *IOP Conference Series: Materials Science and Engineering* 1098(6): 062105. doi:10.1088/1757-899x/1098/6/062105.
- Mudjirahardjo, Panca. 2024. “The Effect of Grayscale, CLAHE Image and Filter Images in Convolution Process.” *Int. j. adv. multidisc. res. stud* 4(3): 943–46. www.multiresearchjournal.com.
- Poerwandono, Edhy & Barronzoeputra, Gaoeng. 2024. “Implementasi Algoritma You Only Look Once (YOLOv8) Untuk Mendeteksi Pelanggaran Lalu Lintas Berupa Tidak Menggunakan Helm (Studi Kasus Di Jatiasih, Bekasi).” 5(3): 3237–47.
- Pratama, Muhammad Rafli, Shafira Zahrah Hidayat, Abdul Rahman Nuruddin, Hamida Wefi Niamaputri, and Kata Kunci. 2025. “Optimasi Peningkatan Kontras Gambar Menggunakan Interval-Valued Intuitionistic Fuzzy Sets Dan Contrast Limited Adaptive Histogram Equalization (CLAHE).” 4(1): 307–17. doi:10.31284/p.semtik.2025-1.6884.
- Ramadah, Fadilah, Prasetya Dwi Wibawa, and Achmad Rizal. 2022. “Sistem Deteksi Api Menggunakan Pengolahan Citra Pada Webcam Dengan Metode YOLOV3.” *e-Proceeding of Engineering* 9(2): 226–31.
- Saputra, Ardimas, Alvian Ramadan, ABIZAR ALGIFARIH, Dewi Wulandari, and Munaya Fauziah. 2021. “Description of Safety Riding Behavior and Knowledge in Adolescents in The South Tangerang Area.” *Muhammadiyah International Public Health and Medicine Proceeding* 1(1): 499–514. doi:10.53947/miphmp.v1i1.95.
- Tsai, Chun Ming, Jun Wei Hsieh, Ming Ching Chang, Guan Lin He, Ping Yang Chen, Wei Tsung Chang, and Yi Kuan Hsieh. 2023. “Video Analytics for Detecting Motorcyclist Helmet Rule Violations.” *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops* 2023-June: 5366–74. doi:10.1109/CVPRW59228.2023.00566.
- Wang, Chien-Yao, Alexey Bochkovskiy, and Hong-Yuan Mark Liao. 2023. “YOLOv7.” *Cvpr*: 7464–75.