

## DETEKSI OBJEK PADA FRAMEWORK YOLOV5 DENGAN PENANGANAN KESILAUAN CAHAYA MENGGUNAKAN GABUNGAN ARSITEKTUR U-NET DAN INPAINT

Firman Afrialdy\*<sup>1</sup>, Rizal Setya Perdana<sup>2</sup>, Candra Dewi<sup>3</sup>

<sup>1,2,3</sup>Universitas Brawijaya, Malang  
Email: <sup>1</sup>firmen@student.ub.ac.id, <sup>2</sup>rizalespe@ub.ac.id, <sup>3</sup>dewi\_candra@ub.ac.id  
\*Penulis Korespondensi

(Naskah masuk: 18 Maret 2024, diterima untuk diterbitkan: 19 Juni 2025)

### Abstrak

CCTV telah diterapkan untuk memantau berbagai aktivitas di lingkungan Universitas Brawijaya, termasuk lalu lintas kendaraan di gerbang kampus. Pengawasan pada malam hari dalam kondisi intensitas cahaya yang rendah merupakan tantangan tersendiri dalam penggunaan CCTV. Hal ini dikarenakan kualitas gambar yang rendah sehingga menghambat kemampuan sistem untuk mendeteksi dan mengidentifikasi objek dengan tepat. Salah satu permasalahan yang timbul dalam kasus kurangnya pencahayaan adalah munculnya *flare* atau kesilauan yang disebabkan oleh lampu kendaraan yang mengarah langsung ke CCTV. Oleh karena itu, pada penelitian ini digunakan segmentasi U-Net dan restorasi *inpaint* untuk preproses data sebelum dilakukan deteksi objek menggunakan *framework* YOLOv5. Hasil pengujian deteksi objek diperoleh nilai *precision* 0.942, *recall* 0.873, dan *F1-Score* 0.88 pada model yang dipreproses menggunakan segmentasi U-Net dan restorasi *inpaint*. Nilai tersebut lebih tinggi sebesar 0.032 pada *precision*, 0.018 pada *recall*, dan 0.3 pada *F1-Score* jika dibandingkan dengan model yang tanpa preproses.

**Kata kunci:** deteksi objek, segmentasi objek, deep learning, yolov5, inpaint

## OBJECT DETECTION IN YOLOV5 FRAMEWORK WITH LIGHT GLARE HANDLING USING COMBINED U-NET ARCHITECTURE AND INPAINT

### Abstract

CCTV has been implemented to monitor various activities within Brawijaya University, including vehicle traffic at the campus gate. Surveillance at night in low light intensity conditions is a challenge in the use of CCTV. This is due to the low image quality that hampers the system's ability to detect and identify objects correctly. One of the problems that arise in the case of lack of lighting is the appearance of flares or glare caused by vehicle lights that point directly to the CCTV. Therefore, in this research, U-Net segmentation and inpaint restoration are used to preprocess data before object detection using the YOLOv5 framework. The results of object detection testing obtained precision values of 0.942, recall 0.873, and F1-Score 0.88 on models preprocessed using U-Net segmentation and inpaint restoration. These values are higher by 0.032 in precision, 0.018 in recall, and 0.3 in F1-Score when compared to the model without preprocessing.

**Keywords:** object detection, object segmentation, deep learning, yolov5, inpaint

### 1. PENDAHULUAN

Perkembangan teknologi telah membawa perubahan signifikan dalam cara kita memandang keamanan dan pengawasan. *Closed Circuit Television* (CCTV) merupakan salah satu teknologi yang telah merasuk ke berbagai aspek kehidupan, dari lingkungan pribadi hingga lingkungan publik. CCTV adalah kamera yang digunakan untuk memantau, merekam, dan mengawasi kondisi suatu lokasi untuk tujuan keamanan (Pangestu, 2022). Penggunaan CCTV tidak hanya terbatas pada pengawasan di

rumah atau perkantoran, tetapi juga telah merambah ke lingkungan yang lebih luas, seperti area jalan dan kampus universitas.

Pengawasan visual terutama pada area jalan dan area masuk telah menjadi fokus penting dalam upaya menjaga keamanan dan efisiensi. Di Universitas Brawijaya misalnya, CCTV telah diterapkan untuk memantau berbagai aktivitas di lingkungan kampus, termasuk lalu lintas kendaraan yang masuk dan keluar dari gerbang masuk kampus. Pengawasan pada malam hari dan dalam kondisi kurangnya intensitas

cahaya yang merupakan tantangan tersendiri dalam penggunaan CCTV. Kualitas gambar yang rendah pada malam hari dapat menghambat kemampuan sistem untuk mendeteksi dan mengidentifikasi objek dengan tepat, seperti kendaraan pada gerbang masuk universitas. Salah satu permasalahan yang timbul dalam kasus kurangnya pencahayaan adalah munculnya *glare* atau kesilauan yang disebabkan oleh lampu kendaraan yang mengarah langsung ke arah CCTV sehingga pengenalan objek dapat terganggu. Oleh karena itu, diperlukan solusi yang efisien dan cepat dalam pemrosesan data CCTV, sehingga informasi mengenai pergerakan dan identifikasi kendaraan dapat diperoleh dengan tepat, mendukung efektivitas pengawasan serta responsivitas tindakan yang dibutuhkan.

Untuk mengatasi tantangan mendapatkan informasi pergerakan dan identifikasi kendaraan, pada penelitian ini dikembangkan model deteksi objek pada CCTV di Universitas Brawijaya menggunakan metode deep learning dengan YOLOv5 untuk melakukan deteksi objek kendaraan yang masuk serta pengimplementasian preproses gambar dengan menggunakan segmentasi kesilauan atau *glare* dengan arsitektur U-Net dan resotransi hasil segmentasi dengan metode *inpaint*. YOLOv5 adalah merupakan versi ke-5 dari *framework* YOLO (*you only look once*) yang dikembangkan oleh tim Ultralytics. *framework* YOLO merupakan *framework* yang dikembangkan untuk tantangan deteksi objek (Jocher et al., 2022). Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem pengawasan lalu lintas yang lebih canggih dan efisien di lingkungan kampus.

Berikut beberapa penelitian yang dijadikan sebagai lansan pustaka pada penelitian ini. Pertama, pada penelitian Bazzi dan teman-teman (2022), dilakukan penelitian objek deteksi dengan menggunakan YOLOv5 yang berfungsi sebagai asisten kendaraan dalam melakukan deteksi pada rambu kendaraan, deteksi objek pada jalan, dan deteksi lajur secara langsung atau *real time*. Tujuan dari penelitian ini adalah untuk mendapatkan hasil yang cepat dan akurat agar dapat membantu pengemudi dalam berkendara. Didapatkan hasil penggunaan *framework* YOLOv5 lebih cepat dan akurat sebanyak 95% dibandingkan *framework* lain berupa YOLOv3 dan YOLOv4.

Pada penelitian Guo dan Xu (2022), penelitian ini menggunakan YOLOv5 untuk mendeteksi objek, DeepSORT untuk melakukan *tracking* atau pelacakan, dan IPM (*Inverse perspective transformation*) untuk melakukan perhitungan kecepatan laju sebuah kendaraan. Dataset berupa video dari sebuah *drone* pada arus lalu lintas yang berkecepatan tinggi, yang menghasilkan 11.000 gambar kendaraan yang nantinya akan diekstraksi dan 150 diantaranya dijadikan data *test*. Hasil dari eksperimen ini menunjukkan rata-rata akurasi berjumlah 96% untuk deteksi kendaraan dan 98.36%

rata-rata akurasi untuk pengukuran kecepatan kendaraan. Letak perbedaan dengan penelitian ini ada pada masalah yang akan diteliti dan jenis dataset yang digunakan. Dataset yang digunakan pada penelitian ini berupa rekaman CCTV dan dalam kondisi pencahayaan rendah atau bisa disebut dalam kondisi malam. Sedangkan dalam metode yang akan digunakan bisa dilihat cukup mirip dengan penelitian Guo dan Xu (2022) yang mana akan menggunakan *framework* YOLOv5 untuk melakukan objek deteksi.

Kemudian pada penelitian yang dilakukan oleh Kutlimuratov dan teman-teman (2023) yang bertujuan mengembangkan sistem *real-time* yang akurat dan handal untuk menghitung jumlah kendaraan guna mengurangi kemacetan lalu lintas di area yang ditentukan. Penelitian tidak hanya dilakukan pada siang hari saja namun juga pada keadaan kurangnya pencahayaan pada kasus malam hari dalam keadaan bergerimis. Video yang digunakan untuk melatih model adalah tangkapan CCTV secara *real time* atau waktu nyata. Dari 10 test video, didapatkan rata-rata akurasi sebesar 98.1% dengan menggunakan metode YOLOv5 dan algoritma DeepSORT. Perbedaan dari penelitian ini adalah lokasi penelitian yang mana penelitian yang dilakukan oleh Kutlimuratov dan teman-teman dilaksanakan pada lokasi Tashkent.

Pada penelitian Mahaur dan Mishra (2023) yang melakukan penelitian objek deteksi pada objek kecil dengan menggunakan YOLOv5 untuk sistem kendaraan otomatis. objek utama yang dideteksi adalah berupa rambu kendaraan dan lampu lalu lintas dengan menggunakan bantuan *framework* YOLOv5 sekaligus melakukan pengembangan *framework* tersebut. Salah satu kriteria dataset yang digunakan adalah pada keadaan malam hari atau kurangnya pencahayaan. Hasil model yang dikembangkan diberi nama model iS-YOLOv5 berhasil meningkatkan nilai *mean Average Precision* (mAP) sebesar 3.35% pada dataset BDD100K. Meskipun demikian, model yang mereka Mahaur dan Mishra kembangkan meningkatkan kecepatan deteksi sebanyak 1.57 *frame* per detik dibandingkan model YOLOv5.

Penelitian lainnya yang menggunakan metode yang sama seperti Wei (2023) dan Guo dan Xu (2022) namun dengan tujuan penelitian berbeda berupa klasifikasi pelanggaran kendaraan pada video rekaman CCTV yang melewati garis jalan. Penelitian ini dilakukan oleh Wu, Ge, dan Zhan (2023) yang mendapatkan hasil akurasi dengan rata-rata sebesar 99.5%.

Selanjutnya pada penelitian yang berfokus dalam meningkatkan *framework* YOLOv5 dalam mengatasi permasalahan pada lingkungan kurangnya pencahayaan yang dilakukan oleh Wang dan teman-teman (2023). Pada penelitian ini berfokus dalam melakukan improvisasi pada model YOLOv5 dengan melakukan perombakan pada bagian lapisan yang ada seperti lapisan SPPF dengan menggunakan modul R-SPPF yang memberikan keuntungan dalam kecepatan

inferensi dan kemampuan pada ekspresi fitur yang kuat. Untuk dataset yang digunakan berupa dataset dalam keadaan malam dan kurangnya pencahayaan. Untuk objek yang akan dideteksi tidak hanya terbatas pada kendaraan saja. Seperti rambu lalu lintas, jalan, lampu lalu lintas, dan pejalan kaki. Pada penelitian ini juga menggunakan algoritma untuk meningkatkan kualitas gambar dalam kondisi gelap. Algoritma yang mereka gunakan adalah algoritma *RetinexNet* dan *EnlightenGAN*. Hasil pengujian dari model yang mereka improvisasi mendapatkan hasil 4.4% lebih tinggi dibandingkan model YOLOv5 dalam metrik *mAP0.5*

Pada penelitian yang dilakukan oleh Miao dan teman-teman (2020) dalam melakukan deteksi kendaraan pada kondisi malam hari atau kondisi pencahayaan rendah dengan menggunakan *framework* YOLOv3. Pada penelitian ini dilakukan preproses gambar dengan meningkatkan kualitasnya dengan mengimplementasi algoritma MSR. Penelitian ini mendapatkan hasil 93.66% dalam metrik *precision* yang mana kualitasnya 6.14% dan 3.12% lebih tinggi dibandingkan algoritma R-CNN dan SSD.

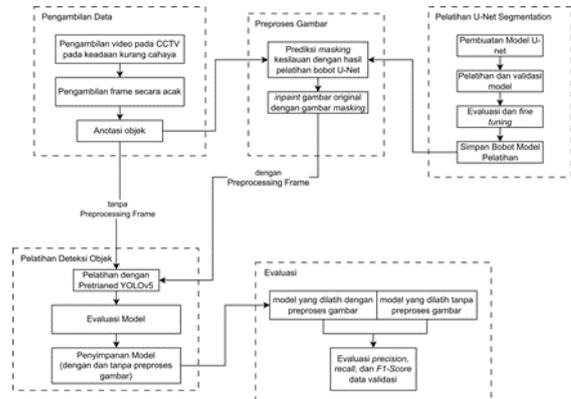
Penelitian dalam deteksi kendaraan pada malam hari yang dilakukan oleh Huang, He, dan Chen (2021) dengan menggabungkan metode mobilenet dan YOLOv3 yang diberi nama M-YOLO. Model tersebut menggunakan menggunakan *feature extraction* pada *backbone* pada *lightweight* yang ada pada mobileNet v4. Dalam pelatihan, model ini dilatih menggunakan EIoU fungsi *loss*. Hasil eksperimen menunjukkan nilai rata-rata *precision* pada model yang diajukan mencapai 94.96% dan 10 *frame* per detik dalam melakukan proses deteksi.

Terakhir pada penelitian Parvin, Islam and Rozario (2022) yang berfokus menggunakan fitur lampu atau kesiluan yang disebabkan oleh kendaraan pada lawan arah di malam hari. Penelitian ini melakukan implementasi terhadap penelitian yang sudah ada dan melakukan perbandingan terhadap penelitian-penelitian tersebut. beberapa model *deep learning* yang diuji pada penelitian ini adalah RCNN, Faster RCNN, CNN, YOLO, dan SSD. Selain itu juga mereka melakukan pengujian terhadap teknik ekstraksi fitur yang digunakan seperti SIFT, *Edge detection*, dan lain sebagainya. Didapatkan hasil tertinggi pada metrik akurasi pada penelitian Chen dan teman-teman (2011) dengan menggunakan segmentasi pada objek terang dengan *multilevel histogram thresholding* dan *clustering technique* dengan nilai akurasi 98.79% pada daerah *urban* dan 97.73 pada area jalan raya.

## 2. METODE

Bagian ini menjelaskan proses pengambilan data, preproses gambar yang digunakan, dan metode yang digunakan dalam penelitian dalam melakukan evaluasi dari deteksi objek pada kendaraan mobil dan motor di lingkungan Universitas Brawijaya pada

gerbang masuk veteran. Gambar 1 diagram operasional penelitian yang dilakukan.



Gambar 1. Diagram Operasional Penelitian

Strategi penelitian yang digunakan adalah teknik eksperimen, teknik eksperimen digunakan untuk menemukan keterkaitan metode yang digunakan dengan objek data yang dipakai, dalam kasus ini adalah deteksi objek kendaraan berupa mobil dan motor yang masuk kedalam gerbang veteran Universitas Brawijaya dalam kondisi pencahayaan rendah. Metode yang digunakan penelitian ini adalah *framework* YOLOv5 untuk melakukan deteksi objek. Sedangkan metode yang digunakan untuk menangani *glare* atau kesiluan yang disebabkan kendaraan akan menggunakan segmentasi area *glare* dengan *neural network* arsitektur U-Net dan restorasi gambar dengan menggunakan metode *inpaint*.

Pada penelitian ini digunakan teknik *image preprocessing* dengan melakukan pelatihan model U-Net untuk melakukan segmentasi terhadap *glare* dengan menggunakan dataset sekunder dari penelitian Esfahani and Wang (2021) Setelah melakukan pelatihan dengan model U-Net tersebut. Nantinya model akan disimpan dan akan digunakan saat melakukan inferensi terhadap setiap *frame* video yang akan dilakukan inferensi dengan melakukan segmentasi cahaya kemudian melakukan metode *inpainting* terhadap cahaya tersebut. Penggunaan *inpainting* sendiri bertujuan sebagai *image restoration* atau perbaikan gambar terhadap kesiluan yang diakibatkan oleh cahaya atau *glare* dari yang berlebihan dari sebuah kendaraan. Penggunaan teknik *preprocessing* ini juga bertujuan untuk mengetahui apakah ada peningkatan pada model deep learning yang diimplementasikan dan meningkatkan akurasi dalam perhitungan jumlah kendaraan yang masuk dalam Gerbang Veteran Universitas Brawijaya dalam kondisi pencahayaan rendah dibanding dengan yang tidak menggunakan teknik *preprocessing*.

Perhitungan evaluasi dilakukan terhadap hasil evaluasi pada *framework* YOLOv5 pada metrik *precision*, *recall*, dan *F1-Score*. Perbandingan kualitas akan dibandingkan terhadap model yang menggunakan metode preproses gambar dan tanpa preproses gambar terhadap dataset yang disediakan sebelum pelatihan.

## 2.1. Pengumpulan Data

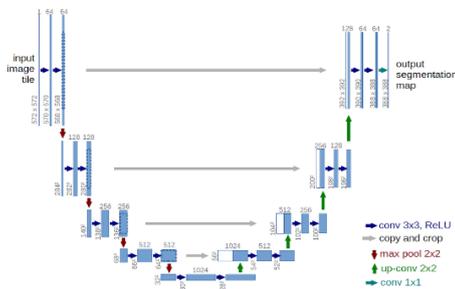
Dataset yang digunakan berupa video yang diambil dari rekaman CCTV di gerbang Universitas Brawijaya pada tanggal 22 Mei 2023, dengan rentang waktu mulai pukul 17:00 hingga 21:00. Pengambilan dibataskan pada pukul 21:00 dikarenakan gerbang masuk veteran UB ditutup. Data ini juga diambil langsung dari CCTV Universitas Brawijaya dan belum pernah digunakan pada penelitian terdahulu. Sehingga data ini bersifat primer. Penelitian ini berfokus pada perhitungan kendaraan dalam kondisi pencahayaan rendah. Jumlah gambar yang digunakan dalam pelatihan model deteksi dengan menggunakan YOLOv5 berjumlah 555 gambar dengan kelas motor berjumlah 1291 objek dan kelas mobil berjumlah 232 objek. Dengan membagi data menjadi 80 dan 20 persen pada pelatihan dan validasi model. Salah satu sampel gambar pelatihan model dapat dilihat pada Gambar 2.



Gambar 2. Sample Gambar Pelatihan Model Deteksi

## 2.2. Pelatihan U-Net Segmentasi

Arsitektur model pembelajaran mesin U-Net pertama kali diperkenalkan oleh Ronneberger, Fischer and Brox (2015) dalam melakukan segmentasi gambar terhadap citra biomedis. Arsitektur ini diberi nama U-Net dikarenakan menyerupai gambar huruf “U” pada model yang digunakan. Arsitektur model U-Net dapat dilihat pada Gambar 3.



Gambar 3. Arsitektur U-Net

Pada penelitian ini digunakan teknik *image preprocessing* dengan melakukan pelatihan model U-Net untuk melakukan segmentasi terhadap *flare* dengan menggunakan dataset sekunder dari penelitian Esfahani dan Wang (2021). Setelah melakukan pelatihan dengan model U-Net tersebut. Model disimpan dan digunakan saat melakukan

inferensi terhadap setiap *frame* video dengan melakukan segmentasi cahaya.

## 2.3. Preproses Gambar

Setelah melakukan pelatihan model segmentasi U-Net untuk melakukan *masking* area silau atau *flare*. Selanjutnya adalah proses yang digunakan untuk mengatasi kesilauan dari area yang ditandai dari hasil inferensi terhadap model yang telah dilatih dengan menggunakan metode *inpaint*. *Inpaint* merupakan salah satu teknik preprocessing gambar yang digunakan untuk melakukan perbaikan gambar (Guillemot and Meur, 2014). Menurut Yang dan teman-teman (2022), metode *inpainting* sendiri sekarang memiliki 2 jenis berupa metode tradisional dan metode pembelajaran mesin. Metode tradisional mencakup metode berbasis difusi dan berbasis tambalan yang berfokus pada fitur tingkat rendah. Metode yang terakhir menggunakan jaringan saraf *convolutional*, terutama jaringan adversarial generatif, untuk menyimpulkan konten semantik tingkat tinggi untuk mencari daerah yang hilang. Penerapan metode ini dapat dilihat pada Gambar 4.

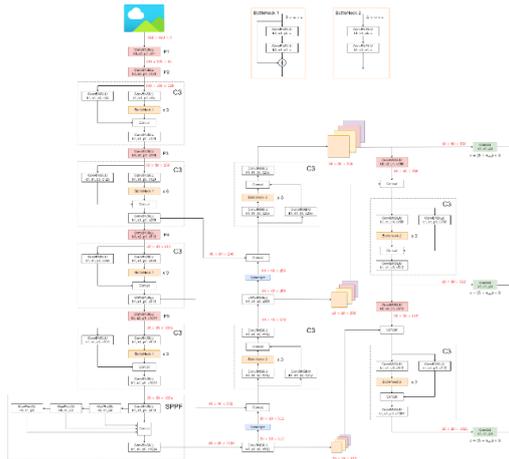


Gambar 4. Penggunaan Metode Inpaint

Pada penelitian ini, metode *inpaint* yang digunakan adalah *fast marching method* yang dikemukakan oleh Telea (2004).

## 2.4. Pelatihan Deteksi Objek

Penelitian ini menggunakan *framework* YOLOv5 untuk melakukan pendeteksian objek pada kelas motor dan mobil pada sebuah *frame* video. *Framework* YOLOv5 merupakan salah satu versi dari seri YOLO (You Only LOOK Once) versi ke-5 yang dirilis pada tahun 2020. YOLO sendiri merupakan model deteksi objek yang berbasis jaringan *Convolutional Neural Network*. YOLO memiliki pendekatan yang berbeda pada sistem deteksi objek. YOLO menyatukan komponen-komponen pada model deteksi objek menjadi sebuah single neural network. Fitur-fitur yang ada pada seluruh gambar digunakan untuk memprediksi setiap *bounding box* dan mengklasifikasikannya ke seluruh kelas secara simultan. Arsitektur dari *framework* YOLOv5 memiliki tiga bagian utama, diantaranya adalah Backbone, Neck, dan Head. Arsitektur YOLOv5 dapat dilihat pada Gambar 5.



Gambar 5. Arsitektur Framework YOLOv5

Pelatihan model deteksi akan dilakukan pada 2 jenis dataset gambar, dataset pertama pada gambar yang tidak melalui tahap preproses sebelumnya dan dataset kedua berupa gambar yang dilakukan preproses dengan menggunakan segmentasi U-Net dan *inpaint* yang bertujuan untuk mengurangi efek *flare* atau kesilauan pada gambar. Masing-masing model digunakan untuk tahap inferensi video sebelum melakukan tahap pelacakan.

## 2.5. Evaluasi

Pada penelitian ini, evaluasi dilakukan pada masing-masing 3 tahap. Yaitu tahap deteksi objek, pelacakan objek, dan perhitungan objek. Metrik evaluasi yang digunakan pada deteksi objek dan perhitungan objek berupa precision, recall, dan F1 score. Precision mengukur seberapa akurat model dalam memprediksi kelas positif. Recall mengukur seberapa banyak model mampu mengidentifikasi semua contoh positif yang sebenarnya. F1-score adalah metrik gabungan yang mempertimbangkan keseimbangan antara precision dan recall. Persamaan dari precision, recall, dan F1-score dapat dilihat pada persamaan (1) hingga (3).

$$\text{Precision} = \frac{TP}{TP+FP} \quad (1)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{F1 score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

Pada persamaan (1), TP (*True Positive*) merupakan jumlah kelas deteksi yang benar dari hasil prediksi terhadap nilai *ground truth* yang ada. FP (*False Positive*) merupakan jumlah kelas yang terdeteksi oleh model deteksi namun pada *ground truth* kelas tersebut tidak ada. Pada persamaan (2), FN (*False Negative*) merujuk kepada model yang tidak mendeteksi sebuah objek namun pada *ground truth* objek itu ada. Persamaan (3), merupakan metrik

gabungan yang mempertimbangkan keseimbangan antara precision dan recall.

Untuk mendapatkan nilai TP, FP, FN, dan TP dalam kasus deteksi objek, ada sedikit penambahan persamaan untuk melihat apakah sebuah kelas yang terdeteksi masuk ke dalam salah satu variabel *confusion matrix* tersebut. Caranya adalah dengan menggunakan persamaan *IoU* atau singkatan dari *intersection over union*. Setelah melakukan perhitungan *IoU*, akan diterapkan nilai ambang batas atau *threshold* untuk menentukan apakah sebuah objek dianggap valid atau tidak terhadap area dari *ground truth* yang ada. Persamaannya dapat dilihat pada persamaan (4).

$$\text{IoU} = \frac{A \cap B}{A \cup B} \quad (4)$$

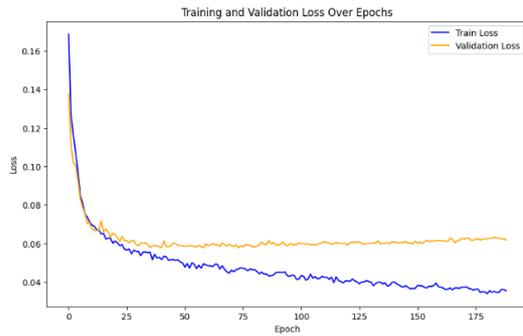
Persamaan (4),  $A \cap B$  Area tumpang tindih dari hasil area prediksi model dan area *ground truth*.  $A \cup B$  Area gabungan pada area prediksi model dan area *ground truth*.

## 3. HASIL DAN PEMBAHASAN

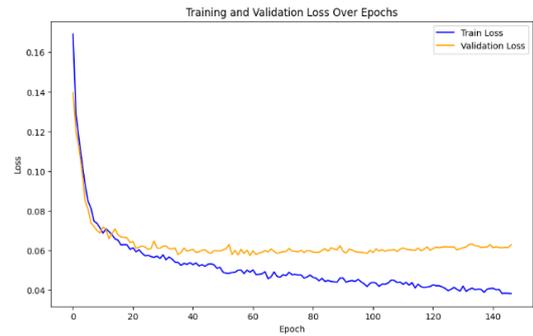
Penelitian ini akan membagi pengujian menjadi 2 tahap: pengujian deteksi objek tanpa preproses gambar dan deteksi objek dengan metode preproses gambar yang diajukan. Pada pengujian deteksi objek, dilakukan dengan melakukan perbandingan antara gambar yang menggunakan preproses gambar dan tanpa preproses. Teknik preproses gambar yang digunakan berupa segmentasi kesilauan atau *flare* dari suatu gambar kemudian menerapkan metode *inpaint* untuk melakukan restorasi pada bagian silau yang didapatkan setelah melakukan segmentasi. Masing-masing dataset memiliki gambar yang sama dengan perbedaan terletak dari dataset gambar yang dipreproses dengan gambar dataset yang tidak dipreproses sebelumnya. Masing-masing data gambar akan dilakukan pelatihan model YOLOv5 dengan menggunakan bobot yang telah dilatih pada model *yolov5s (small)* dengan dilatih sebanyak 500 *epoch* maksimal dan masing-masing data latih menggunakan nilai *batch* sebesar 4. Kemudian semua gambar akan dilakukan perseragaman ukuran gambar menjadi 640 x 640.

### 3.1. Deteksi Objek Gambar tanpa Preproses

Hasil pelatihan pada dataset gambar yang tidak menggunakan preproses sebelumnya dengan menggunakan model YOLOv5 mendapatkan nilai *loss* terendah pada *epoch* ke-113 dengan nilai total *loss* validasi terkecil sebesar 0.04092725 dengan menggunakan nilai *patience* sebesar 75 untuk mencegah *overfitting*. Pergerakan nilai *loss* dengan seiring berjalannya *epoch* pelatihan dapat dilihat pada Gambar 8.



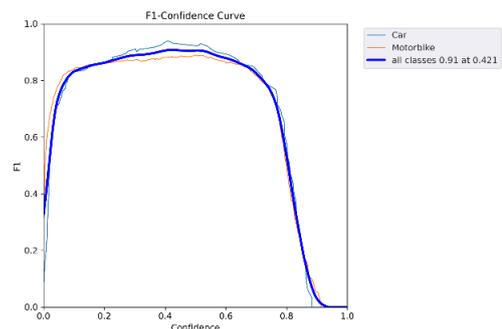
Gambar 6. Nilai Loss pada Pelatihan Model YOLOv5 pada Dataset tanpa Dipreproses



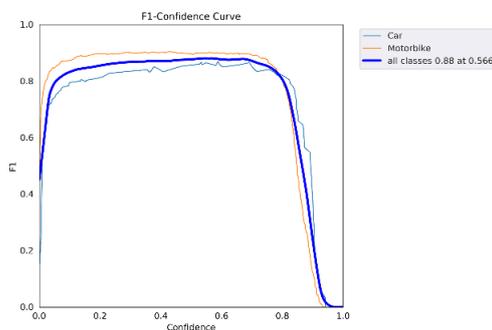
Gambar 8. Nilai Loss pada Pelatihan Model YOLOv5 pada Dataset yang Dipreproses

Nilai *F1 score* pada hasil validasi dataset, didapatkan nilai sebesar 0.88 pada dengan nilai *confidence* (kepercayaan) sebesar 0.566. Maksud dari nilai kepercayaan yang digunakan adalah melakukan penyaringan deteksi terhadap pengaturan nilai kepercayaan. Jika menggunakan nilai kepercayaan 0.566, maka akan diharapkan mendapatkan nilai *F1 score* sebesar 0.88. Kurva *F1 score* dilihat pada Gambar 9.

Metrik pengujian yang digunakan untuk analisis selanjutnya adalah *precision* dan *recall*. Nilai masing-masing *precision* dan *recall* yang didapatkan pada data validasi terhadap dataset gambar yang tidak di preproses adalah 0.91 dan 0.855.



Gambar 9. Kurva *F1 score* Validasi Data Gambar dengan Preproses



Gambar 7. Kurva *F1 score* Validasi Data Gambar tanpa Preproses

### 3.2. Deteksi Objek Gambar dengan Preproses

Hasil pelatihan pada dataset gambar yang menggunakan metode preproses sebelumnya berupa segmentasi U-Net dan *inpaint*. Setelah melakukan preproses dilanjutkan dengan pelatihan model YOLOv5. Hasil pelatihan model mendapatkan nilai *loss* terendah pada *epoch* ke-46 dengan nilai total *loss* validasi terkecil sebesar 0.0531787. Pergerakan nilai *loss* dengan seiring berjalannya *epoch* pelatihan dapat dilihat pada Gambar 10.

Nilai *F1 score* yang didapatkan dari hasil validasi model pada dataset gambar dengan melakukan preproses sebelumnya sebesar 0.91 dengan skor kepercayaan 0.421. Kurva *F1 score* dapat dilihat pada Gambar 11. Sedangkan pada nilai *precision* dan *recall* yang didapatkan pada hasil validasi dataset gambar yang dilakukan preproses bernilai 0.942 dan 0.873.

### 3.3. Pembahasan

Dari hasil perbandingan kuliatas objek deteksi dengan perbandingan penggunaan metode preproses dengan yang tidak menggunakan metode preproses dapat disimpulkan bahwa deteksi objek yang menggunakan preproses gambar terlebih dahulu dengan menggunakan segmentasi U-Net dan metode *inpaint* sedikit lebih baik. Hal ini dapat dilihat pada nilai *precision* dan *recall* yang dihasilkan mendapatkan nilai sedikit lebih unggul pada model yang dilatih tanpa proses *preprocessing* gambar sebelumnya. Namun nilai *confidence* yang didapatkan pada model tanpa menggunakan metode preproses gambar sedikit lebih tinggi namun dengan nilai *F1 score* yang lebih rendah dibanding pada model yang dilatih pada gambar menggunakan metode preproses sebelumnya. Ringkasan dari hasil pengujian dapat dilihat pada Tabel 1.

Tabel 1. Tabel Pengujian Deteksi Objek

<i>Preprocess image</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>best confidence</i>
Tidak	0.91	0.855	0.88	0.566
Ya	0.942	0.873	0.91	0.421

Penelitian ini melakukan perbandingan pada penggunaan metode preproses gambar dalam melakukan pelatihan model deteksi objek dan pelacakan objek untuk melihat apakah dapat meningkatkan performa model *deep learning*. Melihat dari hasil pengujian pada deteksi objek. Penggunaan metode preproses gambar dengan menggunakan metode segmentasi U-Net dan *inpaint*

memiliki hasil yang lebih baik dibandingkan yang tidak menggunakan metode preproses gambar dari metrik *precision*, *recall*, dan *F1 score* dengan masing-masing nilai sebesar 0.942, 0.873, dan 0.91. Namun dalam penilaian *best confidence* dimana model memberikan batas nilai kepercayaan dalam melakukan deteksi objek, model tanpa penerapan metode preprocessing sedikit lebih tinggi dengan nilai *best confidence* sebesar 0.566. Namun masih ada beberapa kekurangan dari penggunaan metode segmentasi ini. Hal ini dikarenakan pelatihan model segmentasi U-Net memiliki mayoritas kesalahan yang disebabkan oleh cahaya yang berwarna kekuningan sehingga segmentasi pada cahaya silau pada cahaya yang berwarna putih sangat sedikit terdeteksi. Selain itu jumlah dataset yang dimiliki berjumlah sangat sedikit dengan total 200 yang dipisah menjadi 80% dan 20% untuk masing-masing data pelatihan dan validasi data. Sehingga metode ini memungkinkan dapat bekerja lebih baik dalam hal deteksi objek jika memiliki lebih banyak dataset *masking flare* atau kesalahan terkhususnya pada cahaya yang berwarna putih.

#### 4. Kesimpulan

Berdasarkan analisis dan hasil pengujian yang telah dilakukan, maka dapat disimpulkan bahwa penggunaan preproses gambar dengan metode segmentasi gambar U-Net dan *inpaint* dapat meningkatkan nilai *precision* sebesar 0.032, *recall* 0.018, dan *F1-Score* sebesar 0.3 pada model deteksi objek dibandingkan model yang dilatih pada data set tanpa melakukan preproses gambar sebelumnya. Namun nilai *best confidence* masih diungguli oleh model yang dilatih tanpa preproses gambar dengan selisih 0.145.

#### DAFTAR PUSTAKA

- BAZZI, A., MURTHY, J.S., M, S.G., LAI, W., D, P.B., PATIL, S.N. and L, H.K., 2022. ObjectDetect: A RealTime Object Detection Framework for Advanced Driver Assistant Systems Using YOLOv5. *Wireless Communications and Mobile Computing*, [online] 2022, p.9444360. <https://doi.org/10.1155/2022/9444360>.
- CHEN, Y.L., WU, B.F., HUANG, H.Y. and FAN, C.J., 2011. A RealTime Vision System for Nighttime Vehicle Detection and Traffic Surveillance. *IEEE Transactions on Industrial Electronics*, 58(5), pp.2030–2044. <https://doi.org/10.1109/TIE.2010.2055771>.
- GUO, F. and XU, Y.,. Vehicle Analysis System Based on DeepSORT and YOLOv5. In: *2022 3rd International Conference on Computer Vision, Image and Deep Learning & International Conference on Computer Engineering and Applications (CVIDL & ICCEA)*. pp.175–179. <https://doi.org/10.1109/CVIDLICCEA56201.2022.9824363>.
- HUANG, S., HE, Y. and CHEN, X., 2021. MYOLO: A Nighttime Vehicle Detection Method Combining Mobilenet v2 and YOLO v3. *Journal of Physics: Conference Series*, [online] 1883(1), p.012094. <https://doi.org/10.1088/17426596/1883/1/012094>.
- JOCHER, G., CHAURASIA, A., STOKEN, A., BOROVEC, J., NANOCODE012, KWON, Y., MICHAEL, K., TAOXIE, FANG, J., IMYHXY, LORNA, 曾逸夫(ZENG YIFU, WONG, C., ABHIRAM V, MONTES, D., WANG, Z., FATI, C., NADAR, J., LAUGHING and UNGLVKITDE, 2022. ultralytics/yolov5: v7.0 - YOLOv5 SOTA Realtime Instance Segmentation. <https://doi.org/10.5281/zenodo.7347926>.
- KUTLIMURATOV, A., KHAMZAEV, J., KUCHKOROV, T., ANWAR, M.S. and CHOI, A., 2023. Applying Enhanced RealTime Monitoring and Counting Method for Effective Traffic Management in Tashkent. *Sensors*, 23(11). <https://doi.org/10.3390/s23115007>.
- MAHAUR, B. and MISHRA, K.K., 2023. Smallobject detection based on YOLOv5 in autonomous driving systems. *Pattern Recognition Letters*, [online] 168, pp.115–122. <https://doi.org/10.1016/j.patrec.2023.03.009>.
- MIAO, Y., LIU, F., HOU, T., LIU, L. and LIU, Y., 2020. A nighttime vehicle detection method based on YOLO v3. pp.6617–6621. <https://doi.org/10.1109/CAC51589.2020.9326819>.
- PANGESTU, I., 2022. *Mengenal Pengertian CCTV: Fungsi, Jenis dan Cara Kerjanya, Jasa Pembuatan Website - Metafora Indonesia Tehnology*. [online] idmetafora.com. Available at: <<https://idmetafora.com/news/read/1411/Mengenal-Pengertian-CCTV-Fungsi-Jenis-dan-Cara-Kerjanya.html>>.
- PARVIN, S., ISLAM, M.E. and ROZARIO, L.J., 2022. Nighttime Vehicle Detection Methods Based on Headlight Feature: A Review. *IAENG International Journal of Computer Science*, 49(1).
- RONNEBERGER, O., FISCHER, P. and BROX, T., 2015. U-net: Convolutional networks for biomedical image segmentation. *CoRR*, [online] abs/1505.04597. Available at: <<http://arxiv.org/abs/1505.04597>>.

- TELEA, A., 2004. An Image Inpainting Technique Based on the Fast Marching Method. *Journal of Graphics Tools*, 9. <https://doi.org/10.1080/10867651.2004.10487596>.
- WANG, J., YANG, P., LIU, Y., SHANG, D., HUI, X., SONG, J. and CHEN, X., 2023. Research on Improved YOLOv5 for LowLight Environment Object Detection. *Electronics*, 12(14). <https://doi.org/10.3390/electronics12143089>.
- WU, S., GE, F. and ZHANG, Y.,. A Vehicle LinePressing Detection Approach Based on YOLOv5 and DeepSort. In: *2022 IEEE 22nd International Conference on Communication Technology (ICCT)*. pp.1745–1749. <https://doi.org/10.1109/ICCT56141.2022.10072680>.
- YANG, Y., CHENG, Z., YU, H., ZHANG, Y., CHENG, X., ZHANG, Z. and XIE, G., 2022. MSENNet: generative image inpainting with multiscale encoder. *The Visual Computer*, [online] 38(8), pp.2647–2659. <https://doi.org/10.1007/s00371021021430>.