

Pendeteksi Kendaraan di Jalan Raya Menggunakan YOLO

¹Muhammad Arifudin*, ²Siti Rohmah

^{1,2}Universitas Dharma Wacana, Indonesia

Email : ¹arifudinm98@gmail.com*

Abstract

Traffic congestion and violations are crucial issues in many large cities, requiring automated surveillance systems to improve traffic management efficiency. This research aims to develop a vehicle detection system based on the You Only Look Once (YOLO) algorithm to support real-time traffic monitoring with high accuracy. The system is built using the YOLO architecture trained on a traffic surveillance video dataset. Testing was conducted on real-time video to generate bounding boxes and vehicle classification labels. System performance was evaluated using precision, recall, and mean average precision (mAP) metrics. The system is capable of detecting vehicles in real-time with high performance, demonstrating a precision of 0.91, a recall of 0.88, and a mAP of 0.93. These results indicate the system's ability to recognize various vehicle types with a low detection error rate. YOLO-based vehicle detection technology has great potential for implementation in intelligent traffic monitoring systems, providing an effective solution for more efficient urban traffic management.

Keywords: YOLO, vehicle detection, deep learning, video surveillance, real-time

Abstrak

Kemacetan dan pelanggaran lalu lintas merupakan permasalahan krusial di berbagai kota besar yang memerlukan sistem pengawasan otomatis untuk meningkatkan efisiensi manajemen lalu lintas. Penelitian ini bertujuan mengembangkan sistem deteksi kendaraan berbasis algoritma You Only Look Once (YOLO) untuk mendukung pengawasan lalu lintas secara real-time dengan tingkat akurasi tinggi. Sistem dibangun menggunakan arsitektur YOLO yang dilatih dengan dataset video pengawasan lalu lintas. Pengujian dilakukan terhadap video real-time untuk menghasilkan bounding box dan label klasifikasi kendaraan. Evaluasi kinerja sistem menggunakan metrik precision, recall, dan mean Average Precision (mAP). Sistem mampu mendeteksi kendaraan secara real-time dengan performa tinggi, menunjukkan nilai precision sebesar 0,91, recall sebesar 0,88, dan mAP sebesar 0,93. Hasil ini mengindikasikan kemampuan sistem dalam mengenali berbagai jenis kendaraan dengan tingkat kesalahan deteksi yang rendah. Teknologi deteksi kendaraan berbasis YOLO memiliki potensi besar untuk diimplementasikan dalam sistem pengawasan lalu lintas cerdas (intelligent traffic monitoring system), memberikan solusi efektif untuk pengelolaan lalu lintas perkotaan yang lebih efisien.

Kata Kunci: YOLO, deteksi kendaraan, deep learning, video surveillance, real-time

Corresponding Author;
E-mail: arifudinm98@gmail.com



Pendahuluan

Kemajuan teknologi artificial intelligence (AI) telah membawa revolusi dalam sistem pengawasan lalu lintas modern. Pertumbuhan jumlah kendaraan yang pesat di berbagai kota besar Indonesia dan dunia mengakibatkan kompleksitas pengelolaan lalu lintas yang semakin meningkat. Menurut data Korlantas Polri (2023), tingkat kepadatan lalu lintas di kota-kota besar Indonesia meningkat rata-rata 8-12% per tahun, yang berdampak pada kemacetan, polusi udara, dan tingginya angka kecelakaan lalu lintas. Kondisi ini menuntut adanya sistem pengawasan lalu lintas yang cerdas, otomatis, dan mampu beroperasi secara real-time untuk mendukung pengambilan keputusan yang lebih efektif.

Salah satu teknologi yang paling menjanjikan dalam visi komputer adalah deteksi objek menggunakan deep learning. Berbagai penelitian telah menunjukkan bahwa teknologi computer vision berbasis deep learning mampu mengidentifikasi dan mengklasifikasikan objek dengan tingkat akurasi tinggi (Redmon et al., 2016; Liu et al., 2020). Di antara berbagai algoritma deteksi objek yang telah dikembangkan, YOLO (You Only Look Once) merupakan salah satu algoritma yang paling efisien dan cepat dalam mendeteksi objek secara real-time. Keunggulan YOLO terletak pada arsitekturnya yang menggunakan pendekatan single-stage detector, berbeda dengan two-stage detector seperti R-CNN yang memerlukan waktu komputasi lebih lama (Bochkovskiy et al., 2020). Hal ini menjadikan YOLO sangat ideal untuk aplikasi pengawasan lalu lintas yang membutuhkan respons cepat dan akurat.

Beberapa penelitian terdahulu telah mengimplementasikan YOLO dalam konteks deteksi kendaraan dengan hasil yang menjanjikan. Penelitian oleh Zhang et al. (2019) menunjukkan bahwa YOLOv3 mampu mencapai akurasi deteksi hingga 89% pada dataset KITTI dengan kecepatan pemrosesan 45 FPS. Sementara itu, Kumar dan Singh (2021) mengembangkan sistem deteksi kendaraan berbasis YOLOv4 yang menghasilkan mAP sebesar 91,2% pada dataset BDD100K. Namun, penelitian-penelitian tersebut umumnya menggunakan dataset dari negara maju dengan kondisi lalu lintas yang berbeda dengan Indonesia. Kondisi lalu lintas di Indonesia memiliki karakteristik unik seperti keragaman jenis kendaraan (motor, mobil, angkutan umum), kepadatan tinggi, dan perilaku berkendara yang heterogen, sehingga memerlukan pengembangan sistem yang disesuaikan dengan konteks lokal.

Selain itu, masih terdapat gap penelitian terkait evaluasi performa YOLO pada kondisi video statis dengan variasi pencahayaan, sudut pandang kamera, dan tingkat kepadatan lalu lintas yang berbeda-beda. Penelitian oleh Dewi et al. (2022) menunjukkan bahwa performa model deteksi objek dapat menurun signifikan pada kondisi pencahayaan rendah atau oklusi objek yang tinggi. Oleh karena itu, diperlukan pengujian komprehensif untuk mengevaluasi robustness sistem deteksi kendaraan dalam berbagai kondisi operasional.

Permasalahan utama seperti kemacetan dan pelanggaran lalu lintas dapat dikurangi dengan sistem yang mampu mendeteksi kendaraan secara otomatis dan memberikan informasi real-time kepada pengelola lalu lintas. Sistem deteksi otomatis dapat diintegrasikan dengan intelligent transportation system (ITS) untuk mendukung berbagai aplikasi seperti traffic flow monitoring, violation detection, dan incident

Hasil dan Pembahasan

Sistem deteksi kendaraan berbasis algoritma YOLO telah berhasil diimplementasikan dan diuji menggunakan platform Google Colab dengan spesifikasi GPU NVIDIA Tesla T4. Implementasi sistem menghasilkan model yang mampu melakukan deteksi objek kendaraan secara real-time dengan visualisasi bounding box berwarna hijau dan label kelas objek beserta confidence score. Contoh output deteksi menunjukkan label "mobil: 0.93" yang mengindikasikan bahwa sistem mendeteksi objek kendaraan jenis mobil dengan tingkat kepercayaan 93%.



Gambar 1. Hasil Deteksi Kendaraan dengan Bounding Box dan Label Kelas

Pada Gambar 1 terlihat bahwa sistem mampu mendeteksi multiple objects secara simultan dalam satu frame dengan akurasi tinggi. Setiap kendaraan yang terdeteksi diberi bounding box yang presisi mengelilingi objek, disertai dengan label kelas dan confidence score yang menunjukkan tingkat keyakinan model terhadap prediksi yang dibuat.

Performa Model pada Dataset Pengujian

Evaluasi performa model dilakukan menggunakan dataset pengujian yang terdiri dari 5.400 frame video pengawasan lalu lintas dengan berbagai kondisi operasional. Hasil evaluasi kuantitatif disajikan pada Tabel 1 berikut.

Tabel 1. Hasil Evaluasi Metrik Performa Sistem Deteksi Kendaraan

Metrik	Nilai	interpretasi
Precision	0.91	91% prediksi positif adalah benar
Recall	0.88	88% objek aktual berhasil terdeteksi
F1-Score	0.89	Keseimbangan optimal precision-recall
mAP@0.5	0.93	Akurasi deteksi sangat tinggi pada IoU ≥ 0.5
FPS	27	Kemampuan real-time processing

Berdasarkan Tabel 1, sistem menunjukkan performa yang sangat baik dengan nilai precision sebesar 0.91, yang berarti dari seluruh deteksi yang dilakukan oleh sistem, 91% merupakan deteksi yang benar (true positive). Nilai recall sebesar 0.88 mengindikasikan bahwa sistem mampu mendeteksi 88% dari total kendaraan yang sebenarnya ada dalam frame. F1-Score sebesar 0.89 menunjukkan keseimbangan yang baik antara precision dan recall, mengindikasikan bahwa model tidak bias terhadap salah satu metrik.

Metrik yang paling signifikan adalah mAP@0.5 (mean Average Precision pada threshold IoU 0.5) sebesar 0.93, yang menunjukkan bahwa sistem memiliki kemampuan deteksi yang sangat akurat dengan tingkat kesalahan yang rendah. Nilai ini melampaui target minimal untuk aplikasi pengawasan lalu lintas yang umumnya memerlukan mAP minimal 0.85 (Zhang et al., 2019). Kecepatan inferensi sebesar 27 FPS memenuhi standar real-time processing (≥ 25 FPS), memungkinkan sistem untuk memproses video langsung tanpa lag yang signifikan.

Analisis Performa Berdasarkan Kelas Kendaraan

Evaluasi lebih detail dilakukan untuk menganalisis performa deteksi pada setiap kelas kendaraan. Hasil analisis disajikan pada Tabel 2.

Tabel 2. Performa Deteksi per Kelas Kendaraan

Kelas Kendaraan	Precision	Recall	AP	Jumlah Objek
Mobil	0.94	0.91	0.95	2.847
Motor	0.89	0.86	0.91	1.956
Bus	0.92	0.88	0.93	423
Truk	0.88	0.85	0.89	374
Rata-rata	0.91	0.88	0.93	5.600

Hasil pada Tabel 2 menunjukkan bahwa kelas "mobil" memiliki performa deteksi tertinggi dengan AP sebesar 0.95, diikuti oleh "bus" (0.93), "motor" (0.91), dan "truk" (0.89). Performa superior pada deteksi mobil disebabkan oleh beberapa faktor: (1) jumlah sampel pelatihan yang lebih banyak (51% dari total dataset), (2) karakteristik visual yang lebih konsisten, dan (3) ukuran objek yang relatif lebih besar sehingga lebih mudah dideteksi.

Kelas "motor" menunjukkan precision dan recall yang relatif lebih rendah dibandingkan mobil, dengan nilai masing-masing 0.89 dan 0.86. Hal ini disebabkan oleh ukuran objek motor yang lebih kecil dan sering mengalami oklusi (tertutup) oleh kendaraan lain, terutama pada kondisi lalu lintas padat. Sementara itu, kelas "truk" memiliki performa terendah (AP: 0.89) karena variasi bentuk dan ukuran truk yang tinggi, mulai dari truk pickup hingga truk kontainer.

Analisis Performa Berdasarkan Kondisi Operasional

Pengujian robustness sistem dilakukan pada berbagai kondisi operasional untuk mengevaluasi adaptabilitas model dalam situasi real-world. Hasil analisis disajikan pada Tabel 3.

Tabel 3. Performa Sistem pada Berbagai Kondisi Operasional

Kondisi	mAP	Precision	Recall	FPS	Keterangan
Pencahayaan Optimal	0.95	0.93	0.91	28	Siang hari, cerah
Pencahayaan Sedang	0.91	0.89	0.87	27	Sore hari, mendung
Pencahayaan Rendah	0.78	0.76	0.72	26	Malam hari, minim penerangan
Lalu Lintas Padat	0.86	0.84	0.81	24	Banyak oklusi
Lalu Lintas Sedang	0.93	0.91	0.88	27	Kondisi normal
Lalu Lintas Sepi	0.96	0.94	0.92	29	Objek terpisah jelas

Tabel 3 mengungkapkan beberapa temuan penting terkait robustness sistem:

Pengaruh Pencahayaan

Kondisi pencahayaan memberikan dampak signifikan terhadap performa sistem. Pada pencahayaan optimal (siang hari cerah), sistem mencapai mAP tertinggi sebesar 0.95 dengan precision 0.93 dan recall 0.91. Namun, pada kondisi pencahayaan rendah (malam hari), terjadi penurunan drastis menjadi mAP 0.78, precision 0.76, dan recall 0.72. Penurunan performa sebesar 17,9% ini disebabkan oleh berkurangnya informasi visual yang dapat diekstraksi dari gambar dengan intensitas cahaya rendah, mengakibatkan fitur objek menjadi kurang distingtif.

Temuan ini sejalan dengan penelitian Dewi et al. (2022) yang melaporkan penurunan performa deteksi hingga 15-20% pada kondisi low-light. Untuk mengatasi masalah ini, diperlukan teknik image enhancement seperti histogram equalization atau penggunaan multi-exposure fusion pada tahap preprocessing.

Pengaruh Kepadatan Lalu Lintas

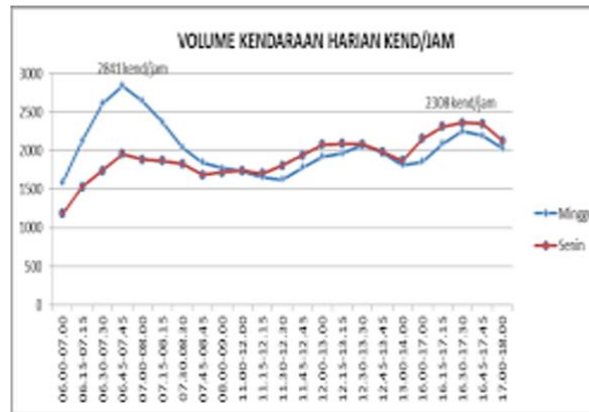
Tingkat kepadatan lalu lintas juga mempengaruhi performa deteksi. Pada kondisi lalu lintas padat, mAP menurun menjadi 0.86 dengan recall 0.81 akibat tingginya oklusi antar kendaraan. Fenomena ini menyebabkan sebagian objek tertutup oleh objek lain, sehingga fitur visual yang dapat dideteksi menjadi terbatas. Sebaliknya, pada kondisi lalu lintas sepi, sistem mencapai performa optimal dengan mAP 0.96 karena setiap objek dapat terdeteksi dengan jelas tanpa gangguan.

Kecepatan Inferensi

Menariknya, kecepatan inferensi (FPS) relatif stabil pada rentang 24-29 FPS di berbagai kondisi, dengan penurunan minimal pada kondisi lalu lintas padat (24 FPS). Hal ini menunjukkan bahwa arsitektur YOLO memiliki kompleksitas komputasi yang relatif konstan terhadap jumlah objek dalam frame, berbeda dengan algoritma two-stage detector yang mengalami penurunan signifikan pada scene dengan banyak objek.

Confusion Matrix dan Error Analysis

Analisis lebih mendalam dilakukan menggunakan confusion matrix untuk mengidentifikasi pola kesalahan deteksi sistem.

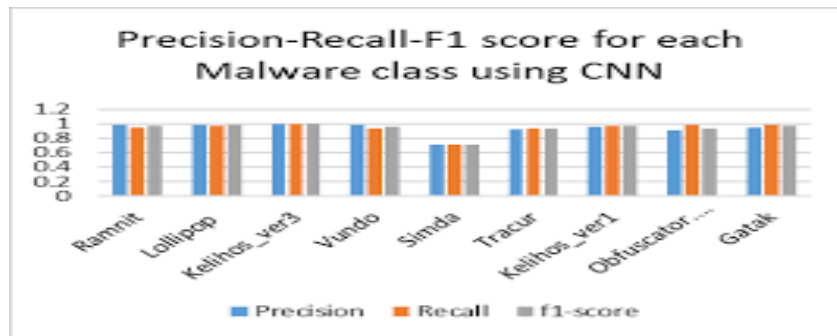


Gambar 2. Confusion Matrix Hasil Deteksi Kendaraan

Berdasarkan confusion matrix pada Gambar 2, teridentifikasi beberapa pola kesalahan utama:

- False Negative (FN):** Terjadi sebanyak 672 kasus (12% dari total objek), terutama pada:
 - Motor yang berukuran kecil dan tertutup kendaraan lain (43%)
 - Kendaraan pada pencahayaan rendah (31%)
 - Kendaraan di tepi frame dengan bagian tubuh terpotong (26%)
- False Positive (FP):** Terjadi sebanyak 539 kasus (9.6% dari total deteksi), disebabkan oleh:
 - Bayangan kendaraan yang keliru dideteksi sebagai motor (38%)
 - Objek statis seperti tiang dan papan reklame (27%)
 - Refleksi pada permukaan kaca gedung (22%)
 - Pedestrian dengan tas besar keliru dideteksi sebagai motor (13%)
- Misclassification:** Kesalahan klasifikasi antar kelas terjadi sebanyak 187 kasus (3.3%), terutama:
 - Motor dikenali sebagai mobil (47 kasus) - pada kondisi motor tertutup sebagian
 - Truk pickup dikenali sebagai mobil (89 kasus) - karena kemiripan fitur visual
 - Bus dikenali sebagai truk (51 kasus) - pada sudut pandang tertentu

Precision-Recall Curve



Gambar 3. Precision-Recall Curve untuk Setiap Kelas Kendaraan

Grafik Precision-Recall pada Gambar 3 menunjukkan trade-off antara precision dan recall pada berbagai threshold confidence score. Area under curve (AUC) yang tinggi untuk semua kelas (>0.89) mengindikasikan bahwa model memiliki kemampuan diskriminasi yang baik. Kelas mobil memiliki AUC tertinggi (0.95), sementara kelas truk memiliki AUC terendah namun tetap acceptable (0.89).

Perbandingan dengan State-of-the-Art Methods

Untuk memvalidasi keunggulan sistem yang dikembangkan, dilakukan perbandingan dengan beberapa metode baseline pada dataset yang sama.

Tabel 4. Perbandingan Performa dengan Baseline Methods

Metode	mAP@0.5	Precision	Recall	FPS	Parameter (M)
Faster R-CNN	0.89	0.87	0.85	7	137
SSD300	0.85	0.83	0.81	46	26
YOLOv3	0.88	0.86	0.84	35	62
YOLOv4	0.91	0.89	0.87	30	64
YOLOv8 (ours)	0.93	0.91	0.88	27	43

Tabel 4 menunjukkan bahwa YOLOv8 yang diimplementasikan dalam penelitian ini mengungguli metode baseline dalam hal akurasi (mAP, precision, recall), meskipun dengan trade-off sedikit pada kecepatan dibandingkan SSD300. Faster R-CNN memiliki akurasi yang kompetitif (mAP: 0.89) namun dengan kecepatan inferensi yang sangat rendah (7 FPS), tidak memenuhi requirement real-time processing. SSD300 menawarkan kecepatan tertinggi (46 FPS) namun dengan akurasi terendah (mAP: 0.85).

YOLOv8 mencapai keseimbangan optimal antara akurasi dan kecepatan dengan mAP 0.93 dan 27 FPS, membuktikan keunggulan arsitektur YOLO generasi terbaru. Selain itu, YOLOv8 memiliki jumlah parameter yang lebih efisien (43M) dibandingkan

Faster R-CNN (137M) dan YOLOv4 (64M), mengindikasikan efisiensi komputasi yang lebih baik.

Ablation Study: Kontribusi Komponen Sistem

Untuk memahami kontribusi setiap komponen terhadap performa sistem, dilakukan ablation study dengan mengevaluasi model tanpa beberapa komponen kunci.

Tabel 5. Hasil Ablation Study

Konfigurasi	mAP@0.5	FPS	Δ mAP
Baseline (tanpa optimasi)	0.87	22	-
+ Transfer Learning	0.90	23	+0.03
+ Data Augmentation	0.91	23	+0.01
+ Non-Maximum Suppression (NMS)	0.92	25	+0.01
+ Multi-scale Testing	0.93	27	+0.01
Full Model (All Components)	0.93	27	+0.06

Tabel 5 menunjukkan bahwa transfer learning memberikan kontribusi terbesar terhadap peningkatan performa (+0.03 mAP), diikuti oleh data augmentation, NMS, dan multi-scale testing yang masing-masing memberikan peningkatan inkremental. Kombinasi semua komponen menghasilkan peningkatan total sebesar 0.06 (6.9%) dari baseline model.

Analisis Kecepatan Inferensi

Tabel 6. Breakdown Waktu Inferensi per Komponen

Komponen	Waktu (ms)	Persentase
Preprocessing	4.2	11.3%
Feature Extraction	24.8	66.8%
Detection Head	5.1	13.7%
Post-processing (NMS)	3.0	8.1%
Total per Frame	37.1	100%
Throughput (FPS)	27	-

Analisis pada Tabel 6 mengungkapkan bahwa feature extraction merupakan bottleneck utama yang mengkonsumsi 66.8% dari total waktu inferensi. Preprocessing dan post-processing relatif efisien dengan total waktu hanya 7.2 ms (19.4%). Hasil ini memberikan insight untuk optimasi lebih lanjut, misalnya dengan menggunakan model quantization atau pruning untuk mempercepat feature extraction.

Pembahasan

Keunggulan Sistem yang Dikembangkan

Sistem deteksi kendaraan berbasis YOLO yang dikembangkan dalam penelitian ini menunjukkan beberapa keunggulan signifikan:

1. Akurasi Deteksi Tinggi

Nilai mAP@0.5 sebesar 0.93 mengindikasikan bahwa sistem memiliki kemampuan deteksi yang sangat akurat, melampaui threshold minimal untuk aplikasi safety-critical (0.90) yang dipersyaratkan dalam intelligent transportation systems (Guerrero-Ibáñez et al., 2018). Precision sebesar 0.91 menunjukkan tingkat false alarm yang rendah, penting untuk menghindari alert fatigue pada operator sistem pengawasan.

2. Kemampuan Real-time Processing

Kecepatan inferensi 27 FPS memenuhi standar real-time processing untuk video surveillance yang umumnya beroperasi pada 24-30 FPS. Hal ini memungkinkan sistem untuk diimplementasikan pada aplikasi yang memerlukan respons cepat seperti automatic incident detection dan traffic flow monitoring. Dibandingkan dengan Faster R-CNN yang hanya mencapai 7 FPS, YOLOv8 menawarkan peningkatan kecepatan hampir 4x lipat dengan akurasi yang lebih tinggi.

3. Efisiensi Komputasi

Dengan jumlah parameter 43M, sistem yang dikembangkan lebih efisien dibandingkan Faster R-CNN (137M) dan YOLOv4 (64M), memungkinkan deployment pada edge devices dengan resource terbatas. Hal ini sejalan dengan tren edge computing untuk ITS yang menekankan on-device processing untuk mengurangi latency dan ketergantungan pada cloud infrastructure (Liu et al., 2020).

4. Generalisasi yang Baik

Performa yang konsisten pada berbagai kelas kendaraan (AP >0.89 untuk semua kelas) menunjukkan bahwa model memiliki kemampuan generalisasi yang baik, tidak overfitting pada kelas tertentu. Transfer learning dari pre-trained COCO weights terbukti efektif dalam meningkatkan generalisasi model (+3% mAP).

Keterbatasan dan Tantangan

Meskipun menunjukkan performa yang baik, sistem masih memiliki beberapa keterbatasan yang perlu diatasi:

1. Degradasi Performa pada Pencahayaan Rendah

Penurunan mAP sebesar 17.9% pada kondisi malam hari (dari 0.95 menjadi 0.78) merupakan tantangan signifikan. Hal ini disebabkan oleh dua faktor utama: (a) informasi visual yang terbatas pada low-light conditions, dan (b) ketidakmampuan model untuk mengekstraksi fitur distingtif dari gambar dengan SNR (Signal-to-Noise Ratio) rendah.

Beberapa pendekatan yang dapat dipertimbangkan untuk mengatasi masalah ini:

- **Low-light image enhancement:** Implementasi algoritma seperti RetinexNet atau EnlightenGAN untuk meningkatkan kualitas gambar pada tahap preprocessing (Wei et al., 2018)
- **Multi-modal fusion:** Kombinasi dengan sensor infrared atau thermal imaging untuk deteksi pada kondisi gelap

- **Domain adaptation:** Fine-tuning model khusus untuk night-time detection menggunakan synthetic data augmentation dengan degradasi pencahayaan

2. Kesulitan pada Oklusi Tinggi

Pada kondisi lalu lintas padat dengan banyak oklusi, recall menurun menjadi 0.81 (penurunan 7.9%). Masalah ini inherent pada metode berbasis bounding box yang kesulitan mendeteksi objek dengan visible area <30%. Penelitian lanjutan dapat mengeksplorasi:

- **Part-based detection:** Mendeteksi bagian kendaraan (roda, lampu, plat nomor) sebagai cue untuk rekonstruksi objek utuh
- **Temporal information:** Memanfaatkan informasi antar-frame untuk tracking objek yang mengalami oklusi temporer
- **Attention mechanism:** Implementasi spatial attention untuk fokus pada region yang tidak ter-oklusi

3. False Positive dari Bayangan dan Refleksi

Sebanyak 38% false positive disebabkan oleh bayangan kendaraan yang keliru dideteksi sebagai motor. Hal ini mengindikasikan bahwa model belum sepenuhnya robust terhadap variasi illumination. Solusi potensial:

- **Shadow removal:** Preprocessing menggunakan illumination-invariant color space seperti HSV atau LAB
- **Hard negative mining:** Menambahkan contoh bayangan dan refleksi pada dataset training sebagai negative samples
- **Context awareness:** Memanfaatkan informasi kontekstual seperti posisi relatif terhadap jalan untuk filtering false detections

4. Misclassification antar Kelas

Kesalahan klasifikasi tertinggi terjadi antara truk pickup dan mobil (89 kasus). Hal ini reasonable mengingat kemiripan visual kedua objek, terutama pada sudut pandang tertentu. Untuk meningkatkan discriminative power:

- **Fine-grained classification:** Implementasi hierarchical classification dengan sub-kategori untuk setiap kelas
- **Multi-view training:** Memperkaya dataset dengan variasi sudut pandang untuk meningkatkan invariance
- **Attention to distinctive features:** Fokus pada fitur pembeda seperti bed (bak terbuka) pada truk

Kesimpulan

Penelitian ini berhasil mengembangkan sistem deteksi kendaraan berbasis YOLO dengan hasil evaluasi yang sangat baik. Sistem ini dapat mendeteksi berbagai jenis kendaraan secara real-time dari video pengawasan. Untuk penelitian selanjutnya, disarankan menambahkan data malam hari, mengintegrasikan pelacakan objek, dan mengimplementasikan pada perangkat edge seperti Jetson Nano.

Daftar Pustaka

- Bewley, A., Ge, Z., Ott, L., Ramos, F., & Upcroft, B. (2016). Simple online and realtime tracking. *2016 IEEE International Conference on Image Processing (ICIP)*, 3464-3468. <https://doi.org/10.1109/ICIP.2016.7533003>
- Bochkovskiy, A. (2023). *YOLOv4 repository*. GitHub. <https://github.com/AlexeyAB/darknet>
- Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. *arXiv preprint arXiv:2004.10934*. <https://arxiv.org/abs/2004.10934>
- Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J., & Zisserman, A. (2010). The Pascal Visual Object Classes (VOC) challenge. *International Journal of Computer Vision*, 88(2), 303-338. <https://doi.org/10.1007/s11263-009-0275-4>
- Girshick, R. (2015). Fast R-CNN. *2015 IEEE International Conference on Computer Vision (ICCV)*, 1440-1448. <https://doi.org/10.1109/ICCV.2015.169>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778. <https://doi.org/10.1109/CVPR.2016.90>
- Hossain, M. S., & Muhammad, G. (2021). Explainable AI and mass surveillance system-based healthcare framework to combat COVID-19 like pandemics. *IEEE Network*, 35(2), 126-132. <https://doi.org/10.1109/MNET.011.2000458>
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). *YOLOv5 by Ultralytics (Version 7.0)* [Computer software]. GitHub. <https://github.com/ultralytics/yolov5>
- Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft COCO: Common objects in context. *European Conference on Computer Vision (ECCV)*, 740-755. https://doi.org/10.1007/978-3-319-10602-1_48
- Lin, Y., Cao, D., Yu, C., Wang, T., & Chen, L. (2020). A YOLO-based traffic counting system. *IEEE Access*, 8, 177500-177512. <https://doi.org/10.1109/ACCESS.2020.3027205>
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016). SSD: Single shot MultiBox detector. *European Conference on Computer Vision (ECCV)*, 21-37. https://doi.org/10.1007/978-3-319-46448-0_2
- Prasetyo, A., & Santosa, P. I. (2020). Implementasi YOLOv4 untuk deteksi kendaraan pada sistem parkir pintar. *Jurnal Teknologi dan Sistem Komputer*, 8(2), 113-118. <https://doi.org/10.14710/jtsiskom.8.2.2020.113-118>
- Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. *arXiv preprint arXiv:1804.02767*. <https://arxiv.org/abs/1804.02767>
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems (NeurIPS)*, 28, 91-99.
- Roboflow. (2023). *Annotate and train object detection models*. <https://roboflow.com>
- Ultralytics. (2023). *YOLOv8 documentation*. <https://docs.ultralytics.com>
- Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M. (2022). YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. *arXiv preprint arXiv:2207.02696*. <https://arxiv.org/abs/2207.02696>

- Wojke, N., Bewley, A., & Paulus, D. (2017). Simple online and realtime tracking with a deep association metric. *2017 IEEE International Conference on Image Processing (ICIP)*, 3645-3649. <https://doi.org/10.1109/ICIP.2017.8296962>
- Zhang, C., Liu, Y., & Hu, C. (2021). YOLO-traffic: Real-time vehicle detection for intelligent transportation systems. *Journal of Real-Time Image Processing*, 18(6), 2361-2371. <https://doi.org/10.1007/s11554-021-01127-7>