Journal of Information Technology and Computer Science (INTECOMS)
Volume 9 Nomor 5, Tahun 2026
e-ISSN : 2614-1574
p-ISSN : 2621-3249

IMPLEMENTATION OF THE YOLOv8 METHOD FOR HELMET-USE DETECTION IN MOTORCYCLE RIDERS BASED ON A VISION-BASED SYSTEM

IMPLEMENTASI METODE YOLOv8 UNTUK DETEKSI PENGGUNAAN HELM PADA PENGENDARA SEPEDA MOTOR BERBASIS VISION-BASED SYSTEM

Marvin J. Mahendra Ibo[1], **Magdalena A. Ineke Pakereng**[2]
Jurusan Teknik Informatika, FTI UKSW, Salatiga[1,2,3]
[1]672022047@student.uksw.edu , [2]ineke.pakereng@uksw.edu

ABSTRACT

This research examines the application of the YOLOv8s method for detecting helmet usage among motorcycle riders, utilizing a Vision-Based System. The dataset was sourced from Roboflow and consists of two primary categories: with helmet and without helmet. The training process was conducted using Google Collaboratory, leveraging GPU resources, while image and video testing were performed through Python scripts in Visual Studio Code. The training results indicate consistent performance based on precision, recall, and mAP50 metrics. This model demonstrates a high accuracy in detecting helmeted objects under various lighting conditions and backgrounds, and it is capable of real-time inference. Visual evaluations reveal the model's success in identifying riders who are wearing and not wearing helmets, although limitations remain in scenarios involving occlusion, small objects, and motion blur. Overall, YOLOv8s shows significant potential for implementation in vision-based traffic monitoring systems to enhance road safety and facilitate automated law enforcement.

***Keywords** : YOLOv8, Helmet Detection, Vision-Based System, Deep Learning, Object Detection*

ABSTRAK

Penelitian ini mengkaji penerapan metode YOLOv8s untuk mendeteksi penggunaan helm pada pengendara sepeda motor yang berbasis pada Sistem Berbasis Visi. Dataset diperoleh dari Roboflow dan mencakup dua kategori utama, yaitu helm dan tanpa helm. Proses pelatihan dilakukan menggunakan *Google Collaboratory* dengan memanfaatkan GPU, sedangkan pengujian citra dan video dilakukan melalui skrip Python di Visual Studio Code. Hasil pelatihan menunjukkan performa yang konsisten berdasarkan nilai precision, recall, dan mAP50. Model ini mampu mendeteksi objek helm dengan akurasi tinggi dalam berbagai kondisi pencahayaan dan latar belakang, serta dapat melakukan inferensi secara real-time. Evaluasi visual menunjukkan keberhasilan model dalam mendeteksi pengendara yang mengenakan dan tidak mengenakan helm, meskipun masih terdapat keterbatasan pada kondisi occlusion, objek kecil, dan motion blur. Secara keseluruhan, YOLOv8s memiliki potensi yang signifikan untuk diterapkan dalam sistem pemantauan lalu lintas berbasis visi untuk mendukung keselamatan berkendara dan penegakan hukum otomatis.

Kata Kunci : YOLOv8, Deteksi Helm, Vision-Based System, Deep Learning, Deteksi Objek

PENDAHULUAN

Keselamatan lalu lintas adalah isu yang sangat penting di Indonesia, terutama mengingat tingginya jumlah kecelakaan yang melibatkan pengendara sepeda motor. Penggunaan helm telah terbukti secara signifikan dapat mengurangi risiko kematian saat kecelakaan terjadi. Namun, kesadaran masyarakat untuk menggunakan helm masih perlu ditingkatkan melalui pengawasan yang lebih ketat. Oleh karena itu, pengembangan Sistem Transportasi Cerdas atau Intelligent Transportation System (ITS) yang dapat memantau kepatuhan pengendara secara otomatis sangat diperlukan. Salah satu teknologi yang berkembang pesat untuk mendukung sistem ini adalah Vision-Based System (VBS) atau Sistem Berbasis Visi. VBS adalah teknologi yang memanfaatkan kamera dan algoritma pengolahan citra untuk menganalisis kondisi lingkungan secara real-time, mirip dengan cara kerja indra penglihatan manusia.

Selain tantangan keselamatan, pertumbuhan populasi dan urbanisasi menyebabkan peningkatan volume lalu lintas yang signifikan. Sistem pengawasan manual memiliki keterbatasan besar, terutama dalam memantau pelanggaran

secara konsisten di berbagai titik secara bersamaan. Penggunaan sistem berbasis visi menjadi solusi relevan untuk memperluas jangkauan pemantauan dan mengurangi ketergantungan pada observasi langsung oleh petugas. Dengan memanfaatkan kamera Closed-Circuit Television (CCTV), proses identifikasi pengendara tanpa helm dapat dilakukan secara otomatis dan seketika (real-time). Hal ini memungkinkan penerapan kebijakan keselamatan yang lebih adaptif dan efisien. Dalam bidang deteksi objek, algoritma You Only Look Once (YOLO) menonjol karena kecepatan dan akurasinya. Varian terbaru, YOLOv8, menawarkan peningkatan performa melalui optimalisasi arsitektur dan strategi augmentasi data yang lebih maju dibandingkan versi pendahulunya [1].

Berbagai penelitian menunjukan bahwa YOLOv8 dapat diterapkan dalam konteks deteksi helm, pelat nomor, serta pelanggaran lalu lintas lainnya, sehingga menunjukan fleksibilitas algoritma ini dalam menangani objek kompleks di lingkungan nyata [7]. Keunggulan tersebut menjadikan YOLOv8 sangat relevan untuk diterapkan pada sistem deteksi penggunaan helm, terutama ketika diperlukan respons yang cepat dan akurat dalam konteks jalan yang dinamis. Meskipun demikian, deteksi objek saja tidak selalu mencukupi pada sistem pengawasan lalu lintas. Dalam beberapa penelitian, proses pelacakan objek juga diperlukan untuk memastikan keberlanjutan identifikasi antara frame dan untuk menganalisis pergerakan objek secara temporal. Pada konteks pelacakan kendaraan, metode seperti Kalman Filter sering digunakan untuk memprediksi posisi objek dan mengurangi gangguan visual yang sering muncul dalam video pemantauan. Penggabungan pendeteksi berbasis deep learning dengan pelacakan probabilistik ini telah menghasilkan sistem yang stabil dan dapat beroperasi dalam kondisi lalu lintas yang padat [5].

Meskipun banyak penelitian telah dilakukan mengenai deteksi helm, masih terdapat celah penelitian (research gap) yang berkaitan dengan keseimbangan antara akurasi deteksi dan kecepatan inferensi dalam lingkungan jalan raya yang dinamis di Indonesia. Beberapa metode tradisional dan versi sebelumnya dari YOLO sering mengalami penurunan akurasi ketika menghadapi objek kecil atau kondisi cuaca yang tidak menentu. Penelitian ini bertujuan untuk mengisi celah tersebut dengan mengimplementasikan YOLOv8s (versi kecil) yang dipadukan dengan dataset dari Roboflow. Penggunaan dataset ini memberikan keuntungan berupa variasi data yang telah diaugmentasi secara khusus untuk mengatasi hambatan visual seperti pencahayaan ekstrem dan sudut pandang kamera yang beragam, yang sering kali menjadi kelemahan dalam penelitian sebelumnya. Berdasarkan latar belakang tersebut, penelitian ini berfokus pada intergrasi teknologi untuk memperkuat sistem pengawasan berbasis visi. Secara spesifik, penelitian ini bertujuan untuk:

1. Mengimplementasikan algoritma YOLOv8s dalam mendeteksi penggunaan helm pada pengendara sepeda motor.
2. Mengevaluasi performa model dalam berbagai kondisi dunia nyata, termasuk hambatan visual seperti occlusion dan motion blur.
3. Menyajikan hasil analisis yang dapat dijadikan dasar untuk pengembangan sistem keselamatan lalu lintas berbasis visi yang lebih komprehensif dan otomatis di masa depan.

TINJAUAN PUSTAKA

Pada bab ini, landasan teori dan kajian literatur yang menjadi dasar ilmiah untuk pengembangan sistem deteksi helm dalam penelitian ini akan dipaparkan. Pembahasan dimulai dengan meninjau penerapan sistem berbasis visi (vision-based system) dalam konteks pengawasan lalu lintas modern, diikuti dengan rekam jejak perkembangan metode deteksi objek yang menggunakan deep learning. Selanjutnya, bab ini akan membedah

karakteristik serta keunggulan dari arsitektur YOLOv8 yang dipilih sebagai model utama, sekaligus mengidentifikasi berbagai tantangan teknis yang dihadapi dalam deteksi objek di jalan raya. Sebagai penutup, bagian ini merumuskan posisi serta kebaruan (novelty) dari penelitian ini jika dibandingkan dengan penelitian-penelitian terdahulu yang sejenis.

2.1 Sistem Berbasis Visi dalam Pengawasan Lalu Lintas

Penggunaan Sistem Berbasis Visi (VBS) dalam pengawasan lalu lintas semakin meningkat seiring dengan kebutuhan otomasi yang terus berkembang. Teknologi ini memungkinkan identifikasi objek dan perilaku pengendara secara langsung melalui data visual yang diperoleh dari kamera CCTV [11, 12]. VBS menjadi fondasi utama dalam transportasi cerdas karena kemampuannya untuk secara otomatis mendeteksi pelanggaran penggunaan helm, yang mendukung penegakan hukum berbasis data [11]. Dalam penelitian ini, VBS berperan sebagai kerangka kerja utama untuk memproses aliran video jalan raya secara real-time.

2.2 Perkembangan Metode Deteksi Helm

Berbagai penelitian telah memanfaatkan Deep Learning untuk mengenali penggunaan helm. Awalnya, metode Convolutional Neural Network (CNN) banyak digunakan, seperti pada lingkungan industri [10]. Namun, CNN tradisional sering terkendala oleh perubahan pencahayaan dan latar belakang yang kompleks. Sebagai solusi, algoritma YOLO (You Only Look Once) mulai diimplementasikan karena mampu memberikan hasil deteksi yang baik meski variasi lingkungan tinggi [13]. Urgensi pengembangan model yang mampu menangani dinamika visual, seperti perubahan sudut pandang dan kepadatan objek, menjadi landasan mengapa penelitian ini memilih pendekatan deteksi objek berbasis single-stage detector [4].

2.3 Keunggulan Arsitektur YOLOv8

YOLOv8 adalah salah satu arsitektur deteksi objek yang paling mutakhir saat ini. Dengan mengadopsi struktur tanpa anchor, YOLOv8 mampu mencapai kecepatan inferensi yang tinggi tanpa mengorbankan akurasi, bahkan ketika dihadapkan pada dataset yang terbatas [1]. Stabilitas model ini dalam mengidentifikasi helm di lingkungan yang kompleks didukung oleh optimisasi parameter dan strategi augmentasi data yang lebih baik dibandingkan dengan versi sebelumnya [2]. Selain itu, penyesuaian pada arsitektur YOLOv8 terbukti tetap berkinerja baik dalam kondisi yang buruk, seperti pencahayaan yang minim atau objek yang saling tumpang tindih (occlusion) [6]. Fleksibilitas ini memungkinkan integrasi deteksi helm dengan sistem keamanan skala besar lainnya [7], yang telah terbukti akurat dalam pemantauan pelanggaran lalu lintas di kondisi nyata [15].

2.4 Tantangan Deteksi dan Mekanisme Perhatian

Meskipun memiliki kekuatan, deteksi objek di jalan raya menghadapi berbagai tantangan yang disebabkan oleh kecepatan tinggi kendaraan serta variasi bentuk helm. Ketidakstabilan visual memerlukan tingkat adaptabilitas model yang tinggi agar hasil deteksi tetap dapat diandalkan [3]. Selain itu, modifikasi dalam deteksi objek manusia juga sangat penting untuk meningkatkan akurasi identifikasi pengendara secara keseluruhan [14]. Penurunan akurasi sering kali terjadi pada objek berukuran mikro atau pada jarak jauh, sehingga pengintegrasian mekanisme perhatian (attention mechanism) menjadi relevan untuk dieksplorasi dalam pengembangan penelitian di masa depan
.

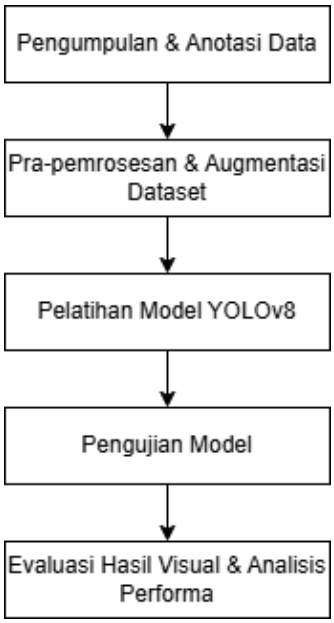
2.5 Posisi dan Kebaruan Penelitian

Berdasarkan literatur yang telah disebutkan, penelitian tentang deteksi helm menggunakan YOLOv8 menunjukkan potensi yang signifikan untuk sistem keamanan di Indonesia, yang memiliki

jumlah kendaraan roda dua yang sangat tinggi. Inovasi dari penelitian ini terletak pada pengoptimalan YOLOv8s dengan memanfaatkan dataset yang telah diaugmentasi secara khusus untuk mengatasi masalah occlusion dan motion blur yang sering terjadi pada CCTV di jalan raya, dengan tujuan untuk menghasilkan sistem pengawasan yang lebih andal dibandingkan dengan metode konvensional.

METODE PENELITIAN

Penelitian akan dilakukan melalui beberapa tahap yaitu pengumpulan dan anotasi data, pra-pemrosesan dan augmentasi dataset, pelatihan model YOLOv8, pengujian model, dan evaluasi hasil visualisasi dan analisis performa, yang diilustrasikan dalam Gambar 1.



Gambar 1. Tahapan Penelitian

3.1 Pengumpulan dan Deskripsi Dataset

Proses penelitian dimulai dengan pengumpulan dataset yang berasal dari platform Roboflow (versi 1). Dataset ini terdiri dari total 1.376 citra dengan resolusi rata-rata 640x640 piksel. Berbeda dengan dataset buatan yang seimbang, dataset yang digunakan dalam penelitian ini memiliki karakteristik kelas yang tidak seimbang (imbalanced dataset), di mana proporsi objek pada kelas helm jauh lebih dominan (lebih banyak) dibandingkan dengan kelas tanpa helm. Kondisi ketidakseimbangan kelas ini sengaja dipertahankan karena merepresentasikan distribusi data riil di lapangan, di mana secara statistik mayoritas pengendara sepeda motor di jalan raya tetap menggunakan helm dibandingkan yang melakukan pelanggaran.

Variasi data mencakup kondisi lingkungan nyata seperti pencahayaan siang dan sore hari, sudut kamera CCTV yang berbeda (tampak atas dan samping), serta tingkat kepadatan lalu lintas dari rendah hingga padat. Dataset ini dibagi secara otomatis melalui pipeline Roboflow dengan rasio 70% untuk data pelatihan (963 citra), 20% untuk data validasi (275 citra), dan 10% untuk data pengujian (138 citra) guna menjamin proses pelatihan dan evaluasi model yang objektif.

3.2 Anotasi dan Augmentasi Data

Dataset yang diperoleh dari Roboflow telah menjalani proses anotasi otomatis dengan menggunakan bounding box. Untuk meningkatkan kemampuan generalisasi model, dilakukan augmentasi data yang meliputi horizontal flip, penyesuaian kecerahan, dan augmentasi mosaik. Teknik ini memungkinkan model untuk belajar mengenali objek helm meskipun posisi pengendara berubah atau dalam kondisi pencahayaan yang kurang ideal.

3.3 Arsitektur Model YOLOv8s

Penelitian ini secara khusus menggunakan varian YOLOv8s (small), di mana pemilihan varian ini didasarkan pada perbandingan karakteristik arsitektur dengan varian lainnya seperti YOLOv8n (nano), YOLOv8m (medium), dan YOLOv8l (large). Perbedaan utama dari arsitektur ini terletak pada jumlah parameter komputasinya; YOLOv8s memiliki lebih banyak parameter dibandingkan dengan v8n, sehingga lebih akurat dalam mendeteksi objek berukuran kecil, seperti helm pada jarak pandang yang jauh.

Meskipun memiliki akurasi yang lebih baik dibandingkan varian nano, varian ini tetap jauh lebih ringan dan cepat jika dibandingkan dengan v8m atau v8l. Alasan utama pemilihan varian small ini adalah untuk mencapai keseimbangan optimal antara efisiensi penggunaan sumber daya komputasi (resource-efficient) dan target spesifikasi aplikasi yang memerlukan kecepatan inferensi tinggi agar dapat diimplementasikan secara andal pada sistem pemantauan lalu lintas jalan raya secara langsung (real-time).

3.4 Skenario Pelatihan Model dan Hyperparameter

Pelatihan model dilakukan dengan menggunakan framework Ultralytics dalam lingkungan Google Colab yang didukung oleh GPU Tesla T4. Untuk memastikan reproduksibilitas penelitian, parameter pelatihan diatur dengan mengonfigurasi optimizer dalam mode otomatis (auto), di mana sistem secara mandiri memilih algoritma AdamW untuk mencapai stabilitas optimasi bobot model yang optimal. Nilai learning rate awal (lr0) ditetapkan pada 0,01 dengan dukungan nilai weight decay sebesar 0,0005. Proses pelatihan ini dilaksanakan sebanyak 100 epoch dengan ukuran resolusi citra (image size) yang diseragamkan menjadi 640x640 piksel. Ukuran batch (batch size) ditentukan secara spesifik sebesar 16 untuk mengoptimalkan alokasi VRAM pada GPU Tesla T4 secara stabil selama proses backpropagation. Di sisi lain, fitur early stopping tidak diterapkan dengan mengatur parameter patience sebesar 100, yang bertujuan untuk memastikan bahwa model dapat terus belajar hingga mencapai titik konvergensi penuh selama seluruh siklus 100 epoch tersebut. Keputusan ini aman dari risiko overfitting karena pola penurunan grafik loss pada data pelatihan (train loss) dan data validasi (validation loss) terus dipantau secara berkala di setiap epoch. Selama nilai validation loss menunjukkan tren penurunan yang sejalan dengan train loss tanpa adanya lonjakan drastis (divergensi), maka model dipastikan mengalami konvergensi yang sehat hingga epoch terakhir.

3.5 Tahap Evaluasi

Tahap evaluasi dalam penelitian ini dilaksanakan secara komprehensif untuk menilai keberhasilan dan keandalan model melalui dua pendekatan utama, yaitu evaluasi kuantitatif dan evaluasi kualitatif. Dalam pengujian inferensi untuk mengevaluasi model, diterapkan nilai ambang batas kepercayaan (confidence threshold) sebesar 0,25 dan ambang batas Intersection over Union (IoU threshold) sebesar 0,45 untuk penyaringan bounding box. Evaluasi kuantitatif memanfaatkan metrik statistik untuk menilai performa deteksi objek secara numerik. Metrik yang digunakan mencakup precision yang berfungsi untuk mengukur tingkat akurasi dari hasil prediksi yang dihasilkan oleh model, serta recall untuk menilai kemampuan model dalam mendeteksi dan menemukan semua objek helmet maupun no-helmet yang sebenarnya terdapat dalam data pengujian. Selain itu, juga diterapkan nilai mean Average Precision pada threshold Intersection over Union 0,5 (mAP50) sebagai indikator utama untuk mengevaluasi nilai akurasi rata-rata model secara keseluruhan dari semua kelas yang diuji.

3.5.1 Evaluasi Kuantitatif

Evaluasi kuantitatif menggunakan metrik statistik untuk menilai performa deteksi objek secara numerik. Metrik yang diterapkan mencakup precision yang berfungsi untuk mengukur tingkat akurasi dari hasil prediksi yang dihasilkan oleh model, serta recall untuk menilai kemampuan model dalam mendeteksi dan menemukan semua objek helmet maupun no-helmet yang sebenarnya terdapat dalam data pengujian. Selain itu, juga digunakan nilai mean Average Precision pada threshold Intersection over Union 0,5 (mAP50) sebagai indikator utama untuk mengevaluasi nilai akurasi rata-rata model

secara keseluruhan dari semua kelas yang diuji.

3.5.2 Evaluasi Kualitatif

Sementara itu, evaluasi kualitatif dilakukan melalui uji coba visual secara langsung terhadap data video dan citra baru yang sepenuhnya tidak terlibat dalam proses pelatihan model sebelumnya. Fokus utama dari evaluasi kualitatif ini adalah untuk menganalisis sejauh mana kemampuan adaptasi model dalam menghadapi berbagai kendala nyata yang sering terjadi di lapangan. Kendala-kendala visual tersebut mencakup fenomena occlusion di mana objek helm terhalang oleh spion atau pengendara lain, efek motion blur yang menyebabkan kaburnya objek akibat laju kendaraan yang berkecepatan tinggi, serta deteksi terhadap kondisi objek berukuran kecil yang berada pada jarak pandang kamera yang cukup jauh.

Penelitian ini menerapkan pendekatan eksperimental untuk mengimplementasikan dan mengevaluasi kinerja model YOLOv8 dalam mendeteksi penggunaan helm pada pengendara sepeda motor yang berbasis pada Sistem Berbasis *Vision-Based System*. Proses penelitian dimulai dengan pengumpulan dataset yang terdiri dari citra dan video yang menunjukkan pengendara sepeda motor dalam dua kategori utama, yaitu pengendara yang mengenakan helm dan pengendara yang tidak mengenakan helm. Data diperoleh dari sumber daring serta rekaman bebas lisensi yang mencerminkan kondisi lalu lintas yang sebenarnya, termasuk variasi pencahayaan, sudut kamera, serta latar belakang yang kompleks. Seluruh data kemudian diseleksi untuk memastikan keragaman dan kualitas visual yang memadai, sehingga dapat meningkatkan kemampuan generalisasi model pada tahap pelatihan.

Tahap pra-pemrosesan data dilakukan setelah dataset diunduh melalui Roboflow, yang secara otomatis menyediakan citra beserta anotasi dalam format YOLO. Penyesuaian ukuran citra dan normalisasi piksel telah ditangani langsung oleh pipeline Roboflow sehingga mempermudah proses integrasi dengan model YOLOv8. Anotasi bounding box untuk kelas helmet dan no-helmet tidak dilakukan secara manual, melainkan mengikuti anotasi yang sudah tersedia pada dataset Roboflow, sehingga kualitas pelabelan tetap konsisten di seluruh data. Selain itu, dataset tersebut telah melalui proses augmentasi otomatis, termasuk rotasi, *horizontal flipping*, perubahan kecerahan, dan penyesuaian kontras, sehingga memperkaya variasi visual dan membantu model menghindari *overfitting.*

HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil dari penerapan, evaluasi, dan analisis kinerja model YOLOv8s dalam mendeteksi penggunaan helm oleh pengendara sepeda motor yang berbasis pada Sistem Berbasis Visi. Diskusi dilakukan melalui tiga tahap utama, yaitu hasil pelatihan model, pengujian pada data gambar dan video, serta analisis mengenai kinerja model berdasarkan metrik evaluasi dan kondisi nyata. Semua hasil yang ditampilkan merupakan keluaran langsung dari model yang dilatih menggunakan dataset Roboflow dan diimplementasikan melalui Google Collaboratory, serta diuji kembali menggunakan Visual Studio Code.

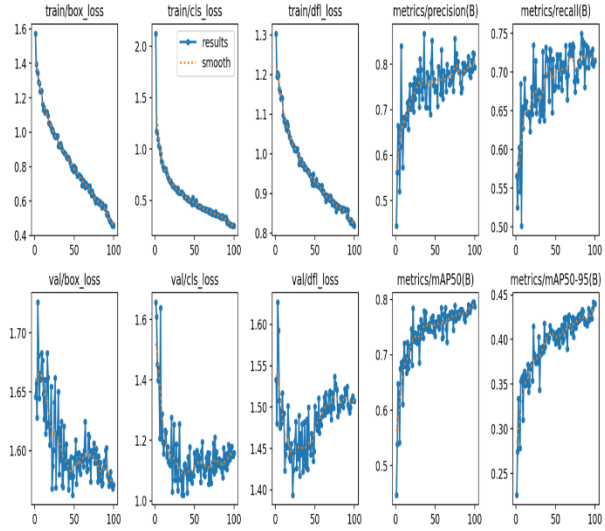
Proses pelatihan dilakukan dengan memanfaatkan arsitektur YOLOv8s sebagai model dasar, yang dipilih karena memberikan keseimbangan yang baik antara kecepatan inferensi dan akurasi. Dataset yang digunakan diperoleh dari Roboflow, yang mencakup anotasi untuk dua kelas, yaitu helmet dan no-helmet, dengan format YOLO. Model ini dilatih selama 100 epoch dengan ukuran gambar 640×640 piksel menggunakan GPU Google Collab. Setelah pelatihan selesai, model menghasilkan berkas bobot terbaik (best.pt) yang selanjutnya digunakan dalam tahap inferensi.

Selama proses pelatihan, grafik dari training loss, validation loss, precision, recall, dan mAP menunjukkan pola konvergensi yang stabil tanpa indikasi overfitting. Model mulai menunjukkan stabilitas konvergensi yang matang antara epoch ke-40 hingga ke-60, di mana nilai train/box_loss terus menurun dari angka awal 1,57 hingga mencapai nilai akhir 0,45542 pada epoch ke-100. Tren penurunan yang sejalan juga terlihat pada train/cls_loss yang berakhir pada angka 0,25146. Sepanjang siklus 100 epoch tersebut, nilai validation loss (val/box_loss dan val/cls_loss) bergerak melandai secara konsisten tanpa adanya lonjakan drastis (divergensi), yang membuktikan bahwa model tidak mengalami gejala overfitting dan berhasil mencapai konvergensi penuh. Berdasarkan evaluasi akhir, nilai mAP50 model berada dalam kategori tinggi, yang menunjukkan kemampuan deteksi yang kuat terhadap objek helm dalam berbagai kondisi visual. Hasil pengujian kuantitatif menyeluruh untuk model terbaik (best model pada epoch 99) disajikan secara eksplisit pada Tabel 1.

Tabel 1. Hasil Evaluasi Kuantitatif Per Kelas YOLOv8s

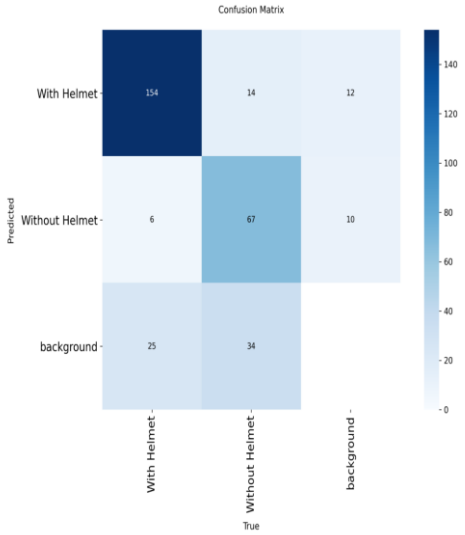
Kelas / Kategori	Precision	Recall	mAP50	mAP50-95
With Helmet (*Pengendara Berhelm*)	0.8556 (85,56 %)	0.8324 (83,24 %)	0.8540 (85,40 %)	0.4900 (49,00 %)
Without Helmet (*Pelanggar/ Minoritas*)	0.8072 (80,72 %)	0.5826 (58,26 %)	0.7354 (73,54 %)	0.3894 (38,94 %)
All Classes (*Rata-rata Keseluruhan*)	0.8556 (85,56 %)	0.7135 (71,35 %)	0.7948 (79,48 %)	0.4397 (43,97 %)

Dalam rangka meningkatkan kontribusi ilmiah dari penelitian ini, nilai akurasi rata-rata (mAP50) dari model yang diusulkan dibandingkan secara langsung dengan beberapa penelitian sebelumnya yang menerapkan algoritma serupa.



Gambar 2. *results*

Selain itu, matriks kebingungan yang dihasilkan dari pelatihan menunjukkan bahwa model lebih efektif dalam mengidentifikasi kelas "helmet" dibandingkan dengan "no-helmet". Kesalahan dalam prediksi umumnya terjadi ketika warna helm sangat mirip dengan latar belakang atau ketika objek tertutup sebagian oleh pengendara lain.



Gambar 3. *confusion matrix*

Evaluasi model dilakukan dengan memanfaatkan dataset validasi yang disediakan oleh Roboflow. Parameter yang dianalisis mencakup precision, recall, mAP50, dan mAP50-95. Tingginya nilai precision menunjukkan bahwa model jarang menghasilkan prediksi positif palsu (false positive), terutama pada kategori

"helmet". Sebaliknya, nilai recall yang konsisten menunjukkan bahwa model mampu mendeteksi sebagian besar objek helm dan non-helm dalam dataset tersebut.

Nilai mAP50 yang diperoleh tergolong tinggi dan sejalan dengan hasil penelitian sejenis, yang menggunakan YOLO sebagai algoritma utama dalam mendeteksi pelanggaran helm [15]. Kinerja yang stabil ini menunjukkan bahwa dataset yang digunakan memiliki kualitas anotasi yang baik dan arsitektur YOLOv8s cukup optimal untuk kasus deteksi helm dalam konteks lalu lintas yang nyata.

Apabila dianalisis secara kuantitatif dengan mengacu pada data yang tersaji dalam matriks kebingungan (Gambar 3), dari keseluruhan 115 sampel data uji pengendara tanpa helm, model klasifikasi berhasil mengidentifikasi 67 sampel dengan akurat. Meskipun demikian, terdapat 14 sampel yang secara keliru diklasifikasikan sebagai pengguna helm dan 34 sampel yang gagal terdeteksi karena dikategorikan sebagai elemen latar belakang. Fenomena ini mengindikasikan bahwa pada kategori pengendara tanpa helm, model menunjukkan tingkat False Negative Rate mencapai 41,74%. Persentase yang tinggi ini merupakan temuan signifikan yang perlu dipertimbangkan dalam implementasi penegakan hukum berbasis otomasi. Sebaliknya, pada kategori pengendara berhelm, tingkat kesalahan positif palsu atau False Positive Rate menunjukkan nilai yang sangat rendah, yakni hanya 3,24% (6 dari 185 sampel pengendara berhelm yang secara keliru dianggap sebagai pelanggar), kondisi ini sangat menguntungkan untuk mengurangi kesalahan dalam proses penerbitan tilang.

Pengujian citra dilakukan dengan memanfaatkan sejumlah gambar uji yang diambil dari kamera secara langsung serta beberapa gambar yang diambil dari lingkungan lalu lintas yang nyata. Hasil inferensi menunjukkan keberhasilan model dalam membedakan antara pengendara yang mengenakan helm dan yang tidak mengenakan helm melalui penggunaan bounding box serta nilai confidence. Dalam beberapa kasus, model berhasil mendeteksi helm berwarna gelap, helm dengan desain yang minimalis, serta helm yang sedikit tertutup oleh objek lain seperti rambut atau masker wajah. Namun, terdapat beberapa contoh mis-detection ketika objek lain seperti kaca spion, bagian depan motor, atau bahkan kendaraan lain memiliki bentuk visual yang mirip dengan helm.



Gambar 4. Deteksi dengan label With Helmet

Evaluasi lebih lanjut dilakukan dengan menguji model pada video menggunakan skrip inferensi di Visual Studio Code dan Google Colab. Model berhasil melakukan deteksi secara frame-by-frame dan menampilkan bounding box yang konsisten pada objek helm. Pada kondisi pencahayaan yang baik dan posisi kamera yang stabil, performa model tetap akurat dan responsif. Deteksi pada video menunjukkan bahwa model lebih sulit memberikan prediksi akurat ketika objek bergerak sangat cepat, ketika terjadi motion blur, atau ketika kamera menangkap objek dari sudut ekstrem. Meskipun demikian, secara umum model dapat mempertahankan stabilitas deteksi lintas frame dan memberikan label yang konsisten.



Gambar 5. Deteksi pada video rekaman ponsel

Hasil ini menunjukkan bahwa YOLOv8 sangat cocok untuk digunakan dalam implementasi Sistem Berbasis Visi yang berbasis CCTV atau kamera pemantau lainnya yang beroperasi secara kontinu.

Secara keseluruhan, YOLOv8s menunjukkan performa yang sangat baik dalam mendeteksi penggunaan helm oleh pengendara sepeda motor. Keunggulan utama dari model ini terletak pada kecepatan inferensi, kemampuan generalisasi, dan tingkat akurasi yang konsisten. Model ini dapat beradaptasi dengan berbagai variasi pencahayaan, latar belakang, warna helm, dan posisi kamera. Namun, terdapat beberapa keterbatasan yang perlu diperhatikan: deteksi palsu masih terjadi pada beberapa objek non-helm yang memiliki pola visual yang mirip; kondisi occlusion atau penghalang dapat mengurangi akurasi bounding box; dan jarak kamera yang terlalu jauh atau kualitas video yang rendah dapat menurunkan nilai confidence. Temuan ini sejalan dengan penelitian Achmad et al. (2025), yang menunjukkan bahwa YOLO tetap sensitif terhadap faktor pencahayaan dan motion blur pada video lalu lintas.

1. Evaluasi

Bab ini mengkaji berbagai keterbatasan dan tantangan yang muncul dalam penerapan sistem deteksi helm menggunakan YOLOv8s, serta implikasi dari temuan tersebut terhadap pengembangan sistem pemantauan lalu lintas berbasis visi komputer di masa depan. Dataset yang digunakan berasal dari Roboflow dan meskipun memiliki anotasi yang baik, variasi kondisi lingkungan masih terbatas. Model cenderung mengalami penurunan performa pada gambar malam hari, kondisi hujan atau pencahayaan rendah, gambar dengan *occlusion* tinggi, dan situasi lalu lintas yang padat. Dataset juga relatif kurang representatif terhadap jenis helm yang unik atau helm dengan warna yang sangat mirip dengan latar belakang.

Model YOLOv8s memiliki keunggulan dalam hal kecepatan, namun kapasitas representasinya lebih kecil dibandingkan dengan versi-l yang lebih besar. Akibatnya, model ini kurang optimal dalam mendeteksi objek kecil, mengalami *misdetection* ketika bentuk atau warna objek menyerupai helm, serta memiliki sensitivitas yang cukup tinggi terhadap motion blur. Dalam proses video inference, ditemukan beberapa kendala teknis seperti penurunan performa deteksi ketika frame rate tidak stabil, *motion blur* yang menyebabkan kesalahan deteksi, serta pergerakan cepat dan posisi kamera yang tinggi yang menghasilkan bounding box yang kurang presisi. Kompresi video yang diperlukan untuk mempercepat pemrosesan juga dapat mengurangi detail visual sehingga mempengaruhi akurasi.

Penelitian ini memberikan dasar yang kuat untuk implementasi sistem pemantauan lalu lintas berbasis komputer. Namun, untuk mencapai performa yang optimal, beberapa langkah peningkatan disarankan, yaitu penambahan dataset nyata dari CCTV jalan raya lokal di Indonesia, penggunaan model *backbone* yang lebih besar seperti YOLOv8m atau YOLOv8l, penerapan preprocessing video untuk mengurangi *motion blur*, *fine-tuning* lanjutan dengan teknik augmentasi yang lebih variatif, serta integrasi dengan ETLE (Electronic Traffic Law Enforcement) untuk mendukung sistem tilang otomatis.

SIMPULAN

Penelitian ini berhasil menerapkan metode YOLOv8s untuk mendeteksi penggunaan helm pada pengendara sepeda motor yang berbasis pada Sistem Berbasis Visi. Model ini dilatih dengan menggunakan dataset dari Roboflow yang telah menjalani proses pra-pemrosesan dan augmentasi otomatis, kemudian diuji melalui inferensi citra dan video menggunakan Python di Google Collaboratory dan Visual Studio Code.

Hasil dari pelatihan menunjukkan bahwa model ini mampu mencapai performa deteksi yang stabil dengan nilai precision, recall, serta mAP50 yang tinggi. Evaluasi visual mengonfirmasi bahwa model ini berfungsi dengan baik dalam berbagai variasi pencahayaan, latar belakang, serta sudut pengambilan gambar, meskipun masih terdapat keterbatasan pada objek kecil, kondisi occlusion, dan motion blur.

Secara keseluruhan, YOLOv8s terbukti efektif dalam membedakan antara pengendara yang menggunakan helm dan yang tidak, serta mampu melakukan inferensi secara real-time dengan tingkat akurasi yang konsisten. Temuan ini menunjukkan bahwa penerapan model deteksi objek berbasis deep learning memiliki potensi untuk menjadi solusi yang relevan dalam pengembangan sistem pemantauan lalu lintas modern, khususnya dalam mendukung peningkatan keselamatan berkendara dan penegakan hukum secara otomatis. Namun, penelitian lebih lanjut tetap diperlukan untuk mengatasi keterbatasan yang ada, termasuk peningkatan kualitas dataset, optimalisasi arsitektur model, serta integrasi dengan sistem pemantauan berbasis CCTV berskala besar.

DAFTAR PUSTAKA

[1] A. Aboah, B. Wang, U. Bagci, dan Y. Adu-Gyamfi, “Real-time Multi-Class Helmet Violation Detection Using Few-Shot Data Sampling Technique and YOLOv8,” arXiv preprint arXiv:2304.08256, 2023.

[2] D. Li et al., “Improvement of Helmet Detection Algorithm Based on YOLOv8,” International Journal of Advanced Network, Monitoring and Controls, vol. 9, no. 4, pp. 28–34, 2024.

[3] L. Choi dan R. Greer, “Evaluating Vision-Language Models for Zero-Shot Detection, Classification, and Association of Motorcycles, Passengers, and Helmets,” arXiv preprint arXiv:2408.02244, 2024.

[4] F. W. Siebert dan H. Lin, “Detecting Motorcycle Helmet Use with Deep Learning,” arXiv preprint arXiv:1910.13232, 2019.

[5] V. Muthuraman, D. Dejey, C. Vishaal, dan S. Balamurali, “Optimizing Helmet Detection with Hybrid YOLO Pipelines: A Detailed Analysis,” arXiv preprint arXiv:2412.19467, 2024.

[6] M. Yang, F. Rao, L. Wang, M. Bai, dan X. Zang, “A Safety Helmet Detection Method Using Adjusted YOLOv8,” Advances in Computer, Signals and Systems, vol. 8, pp. 6–11, 2024.

[7] R. Vishe, D. Prajapati, S. Sabat, S. Bhilare, dan S. Bhujbal, “Helmet Detection and Number Plate Recognition Using YOLOv8 and Tensorflow Algorithm in Machine Learning,” *International Journal of Innovative Research in Computer Science & Technology*, 2024.

[8] F. Li, Y. Chen, M. Hu, M. Luo, dan G. Wang, “Helmet-Wearing Tracking Detection Based on Strongsort,” *Sensors*, vol. 23, no. 3, p. 1682, 2023.

[9] W. Tai, Z. Wang, W. Li, J. Cheng, dan X. Hong, “Daam-Yolov5: A Helmet Detection Algorithm Combined with Dynamic Anchor Box and Attention Mechanism,” *Electronics*, vol. 12, no. 9, p. 2094, 2023.

[10] B. Widodo, H. A. Armanto, dan E. Setyati, “Deteksi Pemakaian Helm Proyek dengan Metode Convolutional Neural Network,” *Journal of Intelligent System and Computation*, vol. 3, no. 1, pp. 23–29, 2021.

[11] D. Danajaya, “Peningkatan Keselamatan Berkendara dengan Fitur Deteksi Helm pada Sistem Transportasi Cerdas,” *Seminar Nasional Inovasi Vokasi*, vol. 2, no. 1, pp. 136, 2019.

[12] I. Jaya, I. K. Swardika, dan I. B. K. Sugirianta, “Sistem Deteksi Pelanggaran Pengendara Motor dengan Computer Vision Sesi

Pelanggaran Pelindung Kepala," *Repositori Politeknik Negeri Bali*, 2022.

[13] K. Khoiriyah dan M. F. A. A. Armawan, "Deteksi Pengendara Motor Tanpa Menggunakan Helm dengan Algoritma Deep Learning YOLO," 2023.

[14] A. Setiyadi, E. Utami, dan D. Ariatmanto, "Analisa Kemampuan Algoritma YOLOv8 dalam Deteksi Objek Manusia dengan Metode Modifikasi Arsitektur," 2023.

[15] A. R. Achmad, A. R. Nugraha, dan A. R. Muttakin, "Sistem Deteksi Pelanggaran Lalu Lintas Pengendara Tanpa Helm Menggunakan Metode Deep Learning Algoritma YOLO," Jurnal Buffer Informatika, vol. 11, no. 1, pp. 57–64, Apr. 2025.