
Deteksi Varian Penggunaan Helm dari Kamera Surveilans Menggunakan Metode Berbasis Deep Learning

Farhan Faturahman¹, Prasti Eko Yunanto², Mahmud Dwi Sulistiyo³

^{1,2,3}Fakultas Informatika, Universitas Telkom, Bandung

¹faturahmanfarhanff@student.telkomuniversity.ac.id,

²gppras@telkomuniversity.ac.id, ³mahmuddwis@telkomuniversity.ac.id

Abstrak

Sepeda motor merupakan moda transportasi utama di Indonesia, tetapi tingkat kepatuhan terhadap penggunaan helm masih rendah. Rekaman kamera surveilans yang sering kali memiliki resolusi rendah menyulitkan deteksi otomatis. Selain itu, variasi helm yang digunakan, seperti full-face, half-face, non-standar, serta pengendara tanpa helm, menjadi tantangan dalam proses pendeteksian. Penelitian ini bertujuan untuk mengembangkan model deep learning berbasis YOLOv8n yang mampu mendeteksi penggunaan helm pada citra beresolusi rendah. Dataset dikumpulkan secara mandiri dengan sudut pandang serta pencahayaan yang serupa. Pengujian dilakukan dengan berbagai konfigurasi batch size dan jumlah epoch untuk menemukan parameter optimal. Hasil evaluasi menunjukkan bahwa model dengan 100 epoch dan batch size 32 memberikan performa terbaik dengan mAP@50 sebesar 0.984, mAP@50-95 sebesar 0.819, precision 0.953, recall 0.952, dan F1-score 0.953. Model ini mampu mendeteksi empat kategori helm dengan akurasi tinggi meskipun pada citra beresolusi rendah. Penelitian ini membuktikan bahwa YOLOv8n dapat digunakan untuk deteksi otomatis penggunaan helm dengan akurasi tinggi, yang dapat membantu sistem pemantauan lalu lintas dan meningkatkan keselamatan berkendara.

Kata kunci: deteksi helm, kamera surveilans, resolusi rendah, deep learning, YOLOv8

Abstract

Motorcycles are the primary mode of transportation in Indonesia; however, compliance with helmet usage remains low. Surveillance footage, often captured in low resolution, poses significant challenges for automatic detection systems. Furthermore, the diverse types of helmets—such as full-face, half-face, non-standard, and the absence of helmets—complicate the detection process. This study aims to develop a deep learning model based on YOLOv8n that is capable of accurately detecting helmet usage in low-resolution images. The dataset was independently collected with consistent viewing angles and lighting conditions to ensure data uniformity. Testing was conducted with various configurations of batch sizes and epoch numbers to determine the optimal parameters. Evaluation results indicate that the model trained for 100 epochs with a batch size of 32 achieved the best performance, recording a mAP@50 of 0.984, mAP@50-95 of 0.819, precision of 0.953, recall of 0.952, and an F1-score of 0.953. The model successfully detects four helmet categories even in low-resolution images. This research demonstrates that YOLOv8n can be effectively utilized for automatic helmet detection with high accuracy, thereby supporting advanced traffic monitoring systems and enhancing road safety.

Keywords: helmet detection, surveillance cameras, low resolution, deep learning, YOLOv8.

1. Pendahuluan

Latar Belakang

Di Indonesia, sepeda motor merupakan salah satu moda transportasi yang paling banyak digunakan. Menurut data Korlantas Polri, sampai dengan 18 Maret 2023, jumlah sepeda motor yang terdata mencapai 128 juta unit [1]. Namun, meski jumlah pengendara motor ini sangat besar, masih banyak pengendara yang tidak menggunakan helm saat berkendara. Penggunaan helm sangat penting dalam mencegah cedera kepala fatal saat terjadi kecelakaan. Sepanjang tahun 2023, terdapat sebanyak 148.307 kecelakaan lalu lintas di seluruh provinsi di Indonesia, dan sepeda motor menjadi penyumbang terbesar dengan angka 138.075 [2]. Dari total kecelakaan tersebut, sebanyak 70,5% melibatkan sepeda motor [2]. Jika dibandingkan dengan data kecelakaan sepeda motor yang terjadi pada 2022, jumlahnya adalah 128.123 [2]. Artinya, ada penambahan sebanyak 9.952 kecelakaan [2]. Mengenai hukum, di Indonesia telah dibuat undang-undang tentang kewajiban memakai helm bagi pengendara sepeda motor. Undang-undang No. 22 tahun 2009 Tentang Lalu Lintas Dan Angkutan Jalan pasal 106 ayat 8 mensyaratkan bagi semua pengendara sepeda motor dan penumpangnya untuk memakai helm yang memenuhi standar nasional Indonesia [3]. Pengendara dan atau penumpang yang tidak memakai helm dikenakan pidana kurungan paling lama 1 bulan, atau denda sebesar Rp, 250.000 (dua ratus lima puluh ribu rupiah) [3]. Sehingga, proses deteksi pelanggaran penggunaan helm menjadi suatu hal yang harus dilakukan secara komputerisasi. Selain itu, variasi jenis helm yang banyak digunakan di Indonesia menjadi salah satu

parameter yang perlu diperhatikan. Rekaman video atau gambar pada kamera surveilans sering kali ditemukan dengan resolusi yang kurang bagus, baik untuk pengamatan manusia ataupun sistem pendeteksian pada kamera surveilans [4]. Sehingga, pendeteksian penggunaan helm pada video rekaman kamera surveilans, terutama dengan menggunakan metode berbasis deep learning, dapat menjadi tantangan yang harus diperhatikan.

Saat ini, telah dilakukan sejumlah penelitian deteksi helm pada pengendara motor [5], [6], [7], [8], [9]. Menurut Penelitian yang telah dilakukan oleh Mercado Reyna, J., dkk [5], telah dilakukan penelitian dengan metode CNN, data dikumpulkan dari video lalu lintas untuk mendeteksi penggunaan helm pada pengendara sepeda motor, dari penelitian ini didapatkan hasil akurasi sebesar 97,24%. Walaupun demikian, apabila penelitian ini diterapkan pada penggunaan helm di Indonesia yang memiliki variasi helm memerlukan penelitian lebih lanjut. Hal ini dikarenakan pada penelitian tersebut hanya mengklasifikasikan dua kelas yaitu antara pengguna helm atau tidak. Waris, T., dkk [6], melakukan penelitian serupa dengan mengajukan penggunaan metode Faster R-CNN pada data repositori online dan gambar yang diambil dari video cctv yang berada di berbagai lokasi Lahore didapatkan akurasi sebesar 97,69%. Namun, penelitian tersebut hanya mendeteksi dua kelas penggunaan helm yaitu menggunakan dan tidak menggunakan helm. Pada penelitian lainnya yang dilakukan oleh Dasgupta, M., dkk [7], menggunakan kombinasi penggunaan metode CNN dan YOLOv3 pada gambar helm di internet dan video rekaman cctv lalu lintas yang digunakan untuk mendeteksi pengendara sepeda motor yang menggunakan helm dan tidak menggunakan helm, didapatkan akurasi sebesar 96,23%. Afzal, A., dkk [8], telah mengajukan penggunaan metode berbasis deep learning dengan Faster R-CNN pada gambar video rekaman dari berbagai daerah dengan berbagai sudut pandang kamera cctv untuk mendeteksi pengendara sepeda motor yang menggunakan helm atau tidak, mendapatkan hasil akurasi 97,26%. Pada penelitian berbasis deep learning serupa lainnya oleh Jakubec, M., dkk [9], pada dataset helmet detection (2022) yang berisikan sepeda, sepeda motor, dan skuter menggunakan metode YOLO dengan versi yang beragam, dibandingkan dan didapatkan hasil akurasi tertinggi menggunakan YOLOv7 sebesar 91,4% pada deteksi pengendara menggunakan helm atau tidak. Berdasarkan penelitian yang banyak dilakukan tersebut menunjukkan bahwa metode YOLO memberikan performansi di atas 90%. Hal ini memperlihatkan bahwa pendeteksian pelanggaran penggunaan helm pada pengendara sepeda motor dapat dilakukan secara komputerisasi serta memungkinkan untuk pendeteksian penggunaan helm pada kualitas resolusi rendah dengan metode YOLO yang memberikan hasil yang akurat.

Berdasarkan penelitian yang ada pada saat ini [5], [6], [7], [8], [9], deteksi penggunaan helm pada pengendara sepeda motor hanya membedakan menjadi dua kelas yaitu pengendara sepeda motor menggunakan helm dan tidak menggunakan helm. Di Indonesia terdapat berbagai variasi penggunaan helm yaitu helm full-face, helm half-face, dan helm non-standar. Sedangkan pengendara sepeda motor dikatakan melakukan pelanggaran ketika helm yang digunakan merupakan helm non-standar atau tidak menggunakan helm sama sekali. Pada penelitian ini, deteksi penggunaan helm pada pengendara sepeda motor dilakukan pada rekaman video atau gambar dari kamera surveilans yang memungkinkan resolusi video dan gambar tersebut kurang bagus atau rendah. Rendahnya kualitas resolusi pada dataset rekaman video atau gambar dari kamera surveilans dapat mempengaruhi proses pendeteksian. Sehingga diperlukan metode berbasis deep learning yang diharapkan dapat mengatasi tantangan permasalahan tersebut. Oleh karena itu, pada penelitian ini, deteksi helm dilakukan dengan menambahkan variasi kelas penggunaan helm dan mengatasi permasalahan deteksi dengan resolusi rendah pada rekaman video atau gambar kamera surveilans dengan menggunakan metode YOLO.

Topik dan Batasannya

Adapun Batasan masalah dari penelitian ini adalah sebagai berikut:

1. Dataset yang digunakan merupakan data rekaman video dari kamera surveilans yang dikumpulkan secara mandiri (self-collected dataset) dengan spesifikasi yang disesuaikan.
2. Asumsi video atau gambar resolusi dengan kualitas kurang bagus atau rendah adalah resolusi dengan kualitas 480p atau dibawahnya.
3. Kelas deteksi penggunaan helm terdiri dari 4 kelas, yaitu penggunaan helm full-face, helm half-face, helm non-standar, dan tidak menggunakan helm.
4. Asumsi helm berstandar adalah helm full-face dan half-face dan helm diasumsikan tidak standar adalah helm yang tidak memiliki kaca helm atau visor.
5. Kamera surveilans bukan merupakan kamera surveilans pada umumnya, yang dimana posisi kamera tidak ditempatkan pada posisi overhead, melainkan pada posisi head level dari para pengendara motor.
6. Skenario pengambilan dataset hanya dilakukan pada di lokasi bundaran gerbang utama Universitas Telkom pada satu sudut pandang yang sama di waktu siang hari. Hal ini menyebabkan dataset yang dihasilkan tidak memiliki variasi.
7. Model yang digunakan hanya YOLOv8n dengan mengujikan parameter epoch dan batch size tanpa membandingkan model YOLO versi lainnya.

Tujuan

Penelitian ini bertujuan untuk melatih model deep learning yang efektif dalam mendeteksi penggunaan helm dari rekaman video kamera surveilans beresolusi rendah. Selain itu, penelitian ini juga bertujuan untuk melatih model deep learning agar mampu mengenali variasi penggunaan helm, termasuk helm non-standar, helm half-face, helm full-face, dan tidak menggunakan helm, sehingga deteksi dapat dilakukan secara optimal.

Penelitian ini diharapkan dapat memberikan manfaat dalam berbagai aspek, terutama dalam meningkatkan efektivitas deteksi pelanggaran penggunaan helm menggunakan metode deep learning. Dengan model yang

diptimalisasi, sistem dapat secara otomatis mendeteksi penggunaan helm pada rekaman video kamera surveilans beresolusi rendah, sehingga membantu aparat dalam penegakan hukum dan pengawasan lalu lintas secara lebih efisien. Selain itu, kemampuan model dalam mengenali variasi jenis helm, termasuk helm full-face, helm half-face, helm non-standar, dan tidak menggunakan helm, dapat meningkatkan akurasi deteksi dan memastikan pengendara mematuhi standar keselamatan. Manfaat lainnya adalah mendukung penelitian dan pengembangan sistem pengawasan berbasis kecerdasan buatan, yang dapat diterapkan lebih luas untuk meningkatkan keselamatan berkendara dan mengurangi risiko kecelakaan di jalan raya.

Organisasi Tulisan

Metode penelitian ini terdiri dari beberapa tahap utama yang dilakukan secara sistematis. Tahap pertama adalah melakukan studi literatur untuk memahami konsep pendeteksian penggunaan helm pada pengendara sepeda motor serta metode deep learning yang telah diterapkan dalam penelitian sebelumnya. Selanjutnya, dilakukan pengumpulan dataset dengan merekam video atau gambar secara mandiri menggunakan kamera surveilans. Dataset ini mencakup empat varian kelas penggunaan helm dan akan dibagi menjadi data training, testing, dan validation. Setelah itu, model deep learning berbasis YOLOv8 dirancang dan diimplementasikan untuk mendeteksi penggunaan helm. Model yang telah dilatih kemudian dievaluasi menggunakan metrik standar guna mengukur performa deteksi. Akhirnya, seluruh hasil penelitian didokumentasikan dalam laporan yang mencakup analisis dan interpretasi dari seluruh tahapan penelitian.

2. Studi Terkait

2.1 Studi Terkait Deteksi Helm pada Pengendara Sepeda Motor

Penelitian terkait dengan deteksi penggunaan helm pada pengendara sepeda motor telah dilakukan sebelumnya. Dapat dilihat pada Tabel 2.1 beberapa penelitian yang telah dilakukan sebelumnya beserta ringkasan dari penelitian tersebut.

Tabel 2.1. Studi Terkait Penelitian Deteksi Helm pada Pengendara Sepeda Motor

Referensi	Ringkasan	
[5]	Tahun	2023
	Metodologi	Metode yang digunakan adalah <i>Convolutional Neural Network</i> (CNN), dataset yang digunakan melalui video rekaman seorang pengendara motor dengan GoPro Hero 5 pada resolusi 1080px dengan 30 fps. Pembagian kelas deteksi dibagikan menjadi “with helmet” dan “without helmet”. Akurasi didapatkan sebesar 97,24%.
	Kesimpulan	Peningkatan pada kumpulan gambar pelatihan dengan menambahkan elemen yang berpotensi membingungkan model dapat dilakukan. Penambahan jumlah subjek uji pada tahap eksperimen untuk memperkuat model deteksi helm dalam berbagai situasi.
[6]	Tahun	2022
	Metodologi	Metode berdasarkan model <i>deep learning</i> Faster R-CNN yang mengkategorikan pengendara motor menjadi dua kelas yaitu “With Helmet” dan “Without Helmet”. Dataset yang digunakan merupakan data yang dikumpulkan dari video rekaman cctv lalu lintas pada sudut pandang depan dan belakang dengan 25 fps. Akurasi yang didapatkan sebesar 97,69%.
	Kesimpulan	Dapat direncanakan untuk mengumpulkan lebih banyak data dari skenario lalu lintas yang kompleks serta melakukan uji coba pada model <i>deep learning</i> guna meningkatkan deteksi penggunaan helm oleh pengendara sepeda motor.
[7]	Tahun	2019

	Metodologi	Metode <i>deep neural network</i> untuk mengidentifikasi banyak pengendara sepeda motor dengan YOLOv3 model dan <i>deep neural network</i> lainnya diajukan untuk deteksi helm pengendara sepeda motor. Video CCTV lalu lintas dijadikan sebagai input ke CNN untuk mendeteksi pengendara sepeda motor dengan atau tanpa helm. Didapatkan akurasi sebesar 96,23%.
	Kesimpulan	Dapat diperluas ke skenario yang lebih kompleks seperti cuaca buruk untuk mendeteksi pengendara sepeda motor yang tidak memakai helm.
[8]	Tahun	2021
	Metodologi	Penggunaan metodologi dengan Faster R-CNN model berbasis <i>deep learning</i> untuk mengidentifikasi helm yang terdeteksi. Dataset merupakan rekaman video cctv dan drone pada sudut pandang depan dan belakang. Data video rekaman tersebut dikonversikan menjadi 25 fps. Data gambar tersebut dianotasikan dengan dua label yaitu “with_helmet” dan “without_helmet”. Akurasi yang didapatkan sebesar 97,26 %.
	Kesimpulan	Dapat direncanakan untuk menghasilkan lebih banyak data dari skenario lalu lintas yang rumit dan juga melakukan eksperimen pada model pembelajaran mendalam untuk meningkatkan deteksi penggunaan helm atau tidak oleh pengendara sepeda motor.
[9]	Tahun	2023
	Metodologi	Metodologi berbasis <i>deep learning</i> yang digunakan adalah YOLOv7 dengan membandingkan juga metode versi YOLO lainnya. Dataset yang digunakan merupakan data Bernama Helmet Detection (2022), yang berisikan gambar sepeda, skuter, dan sepeda motor, dan hanya memiliki dua kategori yaitu “with_helmet” dan “without_helmet”. Didapatkan akurasi terbesar pada YOLOv7 yaitu 91,4%.
	Kesimpulan	Menunjukkan bahwa kinerja model menurun saat helm terhalang atau dalam kondisi pencahayaan rendah, sehingga diperlukan pelatihan model pada gambar dari berbagai konteks dan pengumpulan data yang lebih banyak untuk mengevaluasi keakuratan sistem dalam kondisi dunia nyata.

2.2 Helm Sepeda Motor

Helm adalah bagian yang wajib digunakan oleh pengendara sepeda motor di Indonesia. Helm harus memenuhi standar desain dan pembuatan sesuai dengan Standard Nasional Indonesia (SNI) [10]. Berdasarkan SNI helm harus memenuhi persyaratan sebagai berikut:

1. Helm harus terdiri dari tempurung yang keras dan memiliki permukaan yang halus, helm juga memiliki tali pengikat ke dagu pengendara.
2. Tinggi helm tidak kurang dari 114 mm yang diukur dari puncak helm ke bidang utamanya, yaitu bagian bawah dari kedudukan bola mata dan bidang horizontal melalui lubang telinga.
3. Keliling lingkaran bagian dalam helm adalah S (antara 500 mm– 540 mm, M (540 mm – 580 mm), L (580 mm – 620 mm), XL (lebih dari 620 mm).

4. Tempurung memiliki tekstur keras dan tebal, pelindung tidak menyatu dengan pelindung muka dan mata (khusus helm half face bukan untuk helm full face).
5. Memiliki peredam beturan yang terdiri dari lapisan peredam kejutan yang dipasang pada bagian dalam tempurung, dengan tebal sekurang-kurangnya 10mm.
6. Memiliki tali pengikat dagu yang lebarnya minimal 20 mm dan harus benar-benar berfungsi sebagai pengikat helm ketika dikenakan di kepala dan dilengkapi dengan penutup telinga dan tengkuk, sesuai dengan konstruksi helm half face.
7. Tempurung helm tidak boleh memiliki tonjolan keluar yang tingginya melebihi 5 mm dari permukaan luar tempurung dan setiap tonjolan harus ditutupi dengan bahan lunak. Helm tidak boleh memiliki bagian tepi yang tajam.
8. Lebar sudut pandang sekeliling sekurang-kurangnya 105 derajat pada tiap sisi dan sudut pandang vertikal sekurang-kurangnya 30 derajat di atas dan 45 derajat di bawah bidang utama.
9. Helm harus dilengkapi dengan pelindung telinga, penutup leher, pet yang bisa dipindahkan, tameng atau tutup dagu.



Gambar 2.1. Contoh Penggunaan Helm SNI (Full - Face dan Half Face) [11], [12]



Gambar 2.2. Contoh Penggunaan Helm non SNI (Non-Standard) [13]



Gambar 2.3. Contoh tidak menggunakan Helm [14]

2.3 Kamera Surveilans

Kamera surveilans adalah sistem pengawasan yang digunakan secara luas di berbagai sektor untuk meningkatkan keamanan dan memantau aktivitas, termasuk pengawasan lalu lintas. Kamera surveilans sering kali menghadapi masalah resolusi dengan kualitas gambar atau video yang buruk [4].

2.4 Deep Learning

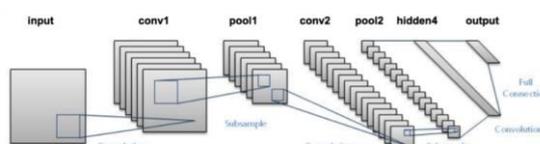
Deep learning adalah bagian dari machine learning yang meniru cara kerja otak manusia menggunakan neurons. Teknik ini berfokus pada pembuatan artificial neural networks dengan banyak hidden layers. Ada berbagai jenis deep learning networks seperti Multilayer Perceptron (MLP), Autoencoders (AE), Convolutional Neural Networks (CNN), dan Recurrent Neural Network (RNN) [15].

Deep learning telah digunakan di berbagai bidang, termasuk image recognition, natural language processing, dan autonomous driving [16]. Sebagian besar deep learning networks dapat mendeteksi objek dengan sangat cepat dan akurat. R-CNN, Fast R-CNN, Faster R-CNN, SSD, YOLO, dan sebagainya adalah beberapa deep learning networks yang paling dikenal [15]. Deteksi objek mencakup proses penentuan lokasi dan klasifikasi objek. Dengan deep learning, sistem dapat secara otomatis memahami fitur-fitur yang relevan dari data yang diberikan tanpa memerlukan fitur-fitur yang telah diprogram sebelumnya [9].

2.5 Convolutional Neural Network (CNN)

Convolutional Neural Networks (CNN) merupakan bagian dari deep learning yang khusus dirancang untuk mengatasi tugas-tugas yang melibatkan data berstruktur, seperti citra dan teks. CNN dirancang untuk secara otomatis mempelajari fitur-fitur spasial dari data masukan melalui lapisan konvolusi, pooling, dan lapisan terhubung penuh [17]. Lapisan konvolusi menerapkan filter (kernel) pada data masukan untuk mengekstraksi fitur, sedangkan lapisan pooling mengurangi ukuran peta fitur untuk mengurangi kompleksitas komputasi. Lapisan terhubung penuh di akhir jaringan menggabungkan fitur yang diekstraksi untuk membuat prediksi [17].

Dengan menerapkan operasi konvolusi, CNN dapat menangkap pola lokal pada data masukan dan secara bertahap mempelajari fitur yang lebih kompleks seiring dengan kedalaman jaringan. Gambar 2.4 adalah contoh visualisasi layer pada CNN.



- False Negative (FN): Instansi positif yang salah diprediksi sebagai negatif.

2.7.3 F1-Score

F1-Score adalah metrik yang menggabungkan precision dan recall. Tujuannya adalah untuk menemukan keseimbangan antara ketepatan dalam memprediksi data positif dan kemampuan model dalam menemukan semua instansi positif [5]. Berikut adalah rumusnya:

$$F1-Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (3)$$

- Precision: Mengukur seberapa akurat model dalam mengidentifikasi positif sejati (True Positive).
- Recall: Mengukur seberapa baik model dalam menemukan semua kasus positif sejati (True Positive) dari total kasus positif yang ada.

2.7.4 Mean Average Precision (mAP)

Mean Average Precision (mAP) adalah metrik yang umum digunakan dalam deteksi objek. Metrik ini menggabungkan precision pada berbagai nilai confidence threshold [9]. Berikut adalah rumusnya:

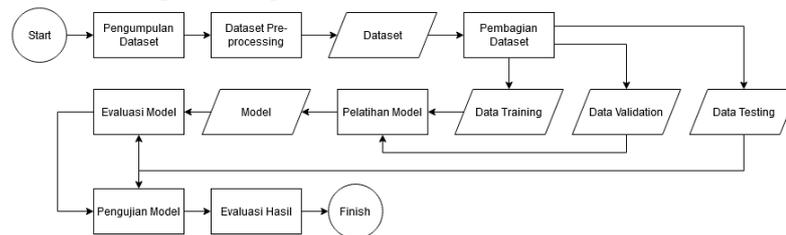
$$mAP = \frac{1}{N} \sum_{i=1}^n AP_i \quad (4)$$

- Average Precision (AP): Nilai precision rata-rata untuk setiap kelas dalam tugas deteksi objek. AP dihitung dengan menghitung area di bawah kurva precision-recall (kurva yang menggambarkan hubungan antara precision dan recall).
- N: Jumlah total kelas atau objek yang akan dievaluasi.
- \sum : Simbol sigma yang menunjukkan penjumlahan dari nilai-nilai AP untuk semua kelas.
- n: Jumlah kelas.

3. Sistem yang Dibangun

3.1. Desain Perancangan Sistem

Penelitian ini menggunakan YOLOv8 untuk membuat sistem deteksi penggunaan helm pada pengendara sepeda motor pada rekaman video kamera surveilans. Rancangan dari sistem deteksi penggunaan helm menggunakan metode YOLOv8 dapat dilihat pada Gambar 3.1.



Gambar 3.1. Flowchart Perancangan Sistem

3.2. Pengumpulan Dataset

Pengumpulan dataset dilakukan dengan merekam video menggunakan kamera DSLR yang disesuaikan dengan spesifikasi kamera surveilans, yaitu resolusi 480p. Rekaman dilakukan secara mandiri (self-collected dataset) di daerah Bandung, tepatnya di Bundaran Telkom University. Proses pengumpulan data dilakukan pada sudut persimpangan jalan untuk menangkap berbagai arah lalu lintas. Rekaman dilakukan dalam rentang waktu bulan Desember 2024 hingga bulan Januari 2025, dengan mempertimbangkan kondisi pencahayaan di siang hari serta cuaca cerah dan mendung. Volume dataset yang ditargetkan adalah setidaknya 1.000 total gambar dataset dari keempat kelas penggunaan helm yang terdiri dari helm full-face, helm half-face, helm non-standar, dan tanpa helm. Gambar-gambar ini diekstraksi dari video rekaman yang telah diambil. Gambar 3.2 menunjukkan denah lokasi dimana video dataset diperoleh dan Gambar 3.3 menunjukkan contoh gambar frame yang dihasilkan dari video yang direkam untuk dataset ini.



Gambar 3.2. Denah Lokasi Pengambilan Video Dataset



Gambar 3.3. Contoh Gambar Ekstraksi Frame dari Kamera Surveilans

3.3. Dataset Pre-processing

Dataset pre-processing merupakan tahap krusial sebelum pelatihan model untuk memastikan kualitas data yang optimal. Proses dimulai dengan extracting frames, yaitu mengekstrak frame dari video pada interval tertentu guna membentuk dataset gambar yang akan digunakan dalam pelabelan dan pelatihan model. Selanjutnya, gambar-gambar yang telah diekstrak melalui tahap anotasi dan labeling, di mana setiap gambar diklasifikasikan ke dalam empat kelas: helmet_fullface, helmet_halfface, helmet_nonstandard, dan no_helmet. Proses anotasi ini dilakukan menggunakan Roboflow dan disimpan dalam format yang sesuai dengan YOLO. Setiap dari anotasi dan labeling pada sebuah frame berisikan sebuah gambar penggunaan helm dari setiap kelas yang didapatkan.

Untuk memastikan konsistensi data, auto orientation diterapkan agar semua frame memiliki orientasi yang seragam. Setelah itu, gambar diubah ukurannya menjadi 640x640 piksel menggunakan metode stretching, yang tetap mempertahankan informasi penting dalam gambar sesuai dengan kebutuhan YOLO.

3.4. Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari gambar-gambar yang telah dianotasi dengan empat kelas:

1. helmet_fullface
2. helmet_halfface
3. helmet_nonstandard
4. no_helmet

Dataset ini diperoleh dari rekaman video yang dikumpulkan secara mandiri menggunakan kamera DSLR dengan spesifikasi yang disesuaikan menyerupai kamera surveilans. Rekaman video tersebut kemudian diproses dan dilakukan anotasi untuk keperluan pelatihan model. Dari proses pengambilan data, diperoleh sebanyak 1.118 frame gambar, dengan total anotasi label penggunaan helm mencapai 1.944 anotasi, dengan ukuran terkecil piksel helm yang dianotasikan memiliki luas bounding box sebesar 286 piksel. Distribusi proporsi kelas anotasi dapat dilihat pada Tabel 3.1 dan contoh dataset yang telah dianotasi berdasarkan kelasnya dapat dilihat pada tabel 3.2.

Tabel 3.1. Proporsi Kelas Anotasi

Kelas Anotasi	Jumlah
helmet_fullface	156 (8.02%)
helmet_halfface	706 (36.32%)
helmet_nonstandard	367 (18.88%)
no_helmet	715 (36.78%)

Tabel 3.2. Contoh Dataset yang dikumpulkan beserta Kelasnya

Kelas Penggunaan Helm	Gambar Dataset
helmet_fullface	

helmet_halfface	
helmet_nonstandard	
no_helmet	

3.5. Pembagian Dataset

Dataset yang telah dikumpulkan dan diproses selanjutnya dibagi menjadi tiga bagian utama, yaitu data training, data validation, dan data testing. Pembagian dataset ini dilakukan untuk memastikan bahwa model yang dilatih dapat dievaluasi secara adil serta memiliki kemampuan generalisasi yang baik terhadap data baru. Pembagian proporsi dataset adalah sebagai berikut: 70% untuk data training (783 gambar frame), 15% untuk data validation (168 gambar frame), dan 15% untuk data testing (167 gambar frame). Pembagian ini juga mempertimbangkan adanya class imbalance pada dataset.

3.5.1 Data Training

Data training digunakan untuk melatih model deteksi helm. Sekitar 70% (783 gambar frame) dari total proporsi dataset digunakan sebagai data training. Data training ini digunakan dengan tujuan untuk melatih model. Data ini membantu model untuk belajar mengenali pola dan fitur yang relevan untuk mendeteksi helm.

3.5.2 Data Validation

Data validation digunakan untuk mengevaluasi performa model selama proses pelatihan dan menghindari overfitting. Sekitar 15% (168 gambar frame) dari total proporsi dataset digunakan sebagai data validation. Data validation ini digunakan dengan tujuan untuk mengevaluasi performa model selama proses pelatihan. Data ini membantu dalam tuning hyperparameters dan memilih model terbaik berdasarkan performa pada data yang tidak digunakan untuk pelatihan.

3.5.3 Data Testing

Data testing digunakan untuk mengukur kinerja akhir model setelah pelatihan selesai. Sekitar 15% (167 gambar frame) dari total proporsi dataset digunakan sebagai data testing. Data testing ini digunakan dengan tujuan untuk mengukur kinerja akhir model setelah pelatihan selesai. Data ini membantu dalam mengevaluasi kemampuan generalisasi model terhadap data baru yang belum pernah dilihat sebelumnya.

3.6. Pelatihan Model

Pelatihan model menggunakan YOLOv8n (Nano) dipilih karena efisiensi komputasi dan kecepatan inferensi

yang tinggi. Model diinisialisasi dengan pre-trained weights dari yolov8n.pt, memanfaatkan fitur yang telah dipelajari sebelumnya untuk mempercepat konvergensi. Forward pass dilakukan dengan menggunakan CSPDarknet sebagai backbone dan PANet untuk deteksi multi-skala, menghasilkan bounding boxes dan class probabilities untuk empat kelas helm. Loss function terdiri dari Box Loss (CIoU), Objectness Loss, dan Classification Loss.

Dalam backward pass, model diperbarui menggunakan AdamW optimizer dengan learning rate awal 0.01 untuk stabilitas pembelajaran. Pelatihan dilakukan dengan batch size dan jumlah epoch yang disesuaikan dengan skenario pengujian, sementara parameter lainnya tetap menggunakan default YOLOv8n. Proses ini berlangsung hingga loss stabil pada dataset validation. Hyperparameter tuning hanya dilakukan pada batch size dan jumlah epoch, menyesuaikan kapasitas GPU untuk memastikan model belajar optimal tanpa overfitting.

3.7. Model

Model yang digunakan dalam penelitian ini adalah YOLOv8n (Nano), yang dipilih karena efisiensi komputasi dan kecepatan inferensinya yang tinggi, sehingga cocok untuk deteksi objek secara real-time pada gambar beresolusi rendah. Arsitektur YOLOv8n terdiri dari tiga komponen utama: CSPDarknet sebagai backbone untuk mengekstraksi fitur, Path Aggregation Network (PANet) sebagai neck untuk meningkatkan deteksi pada berbagai skala, dan head yang menghasilkan bounding boxes dan class probabilities untuk empat kelas helm yang telah ditentukan, yaitu helmet full-face, helmet half-face, helmet non-standard, dan no helmet. Model ini juga menggunakan Non-Maximum Suppression (NMS) untuk menghilangkan deteksi yang tumpang tindih dan memilih bounding box terbaik berdasarkan confidence score. Dengan arsitektur yang optimal, YOLOv8n mampu mendeteksi berbagai jenis helm dengan akurasi tinggi, bahkan pada gambar dengan resolusi rendah (480p ke bawah), sehingga memungkinkan implementasi dalam pemantauan lalu lintas secara otomatis.

3.8. Evaluasi Model

Evaluasi model dilakukan menggunakan metrik precision, recall, F1-score, dan mean Average Precision (mAP) untuk mengukur kinerja deteksi helm pada citra beresolusi rendah. Evaluasi ini diterapkan pada data validation guna membantu dalam tuning hyperparameters dan memilih model terbaik. Proses evaluasi diawali dengan evaluasi awal, di mana model diuji menggunakan metrik yang telah ditentukan untuk mendapatkan gambaran awal performanya. Selanjutnya, dilakukan identifikasi kelemahan, seperti jika precision tinggi tetapi recall rendah, yang menunjukkan bahwa model cenderung menghasilkan banyak false negatives. Berdasarkan analisis tersebut, dilakukan penyesuaian batch size dan jumlah epoch untuk memastikan pelatihan model berjalan optimal tanpa overfitting atau underfitting. Setelah parameter disesuaikan, model dievaluasi kembali dalam proses iterasi evaluasi, yang dilakukan secara berulang hingga performa model menunjukkan hasil yang stabil dan memuaskan.

3.9. Pengujian Model

Pengujian model dilakukan untuk mengevaluasi kinerja model setelah proses pelatihan dan validasi. Pengujian ini melibatkan penyesuaian parameter epoch dan batch size guna memperoleh hasil pelatihan terbaik berdasarkan performa pada data validation. Model dengan parameter optimal kemudian diuji menggunakan data testing, yang sepenuhnya terpisah dari data training dan validation, untuk menilai kemampuannya dalam mendeteksi helm pada kondisi nyata.

Alur pengujian dimulai dengan pemilihan model terbaik berdasarkan evaluasi pada data validation. Model tersebut kemudian diterapkan pada data testing yang telah dianotasi dengan label kelas helm yang tersedia. Pada tahap inferensi, YOLOv8n menerima input berupa gambar beresolusi rendah (480p ke bawah) dan mendeteksi objek helm dengan menghasilkan bounding boxes serta class probabilities. Hasil pengujian dievaluasi menggunakan metrik precision, recall, F1-score, dan mean Average Precision (mAP) untuk mengukur akurasi deteksi berdasarkan bounding boxes dan prediksi kelas yang dihasilkan.

3.10. Evaluasi Hasil

Evaluasi hasil dilakukan dengan membandingkan performa model pada data testing menggunakan metrik seperti precision, recall, F1-score, dan mean Average Precision (mAP). Analisis ini bertujuan untuk menilai kekuatan dan kelemahan model serta mengidentifikasi aspek yang perlu diperbaiki lebih lanjut. Precision mengukur proporsi prediksi positif yang benar dari keseluruhan prediksi positif, menunjukkan kemampuan model dalam mendeteksi kelas helm secara akurat tanpa banyak false positives. Recall mengukur seberapa banyak instansi yang benar-benar positif berhasil dideteksi oleh model, menilai kemampuannya dalam menangkap semua objek yang seharusnya terdeteksi. F1-score, sebagai kombinasi precision dan recall, digunakan untuk mengukur keseimbangan antara keduanya, terutama dalam kondisi dataset yang tidak seimbang. Mean Average Precision (mAP) mengukur kinerja deteksi secara menyeluruh dengan menghitung rata-rata precision pada berbagai threshold recall, memberikan gambaran tingkat kepercayaan model dalam mendeteksi objek helm.

Hasil evaluasi ini dianalisis untuk memahami sejauh mana model bekerja secara efektif dalam berbagai kondisi dan menentukan langkah-langkah perbaikan jika diperlukan. Evaluasi yang menyeluruh memastikan bahwa model siap digunakan dalam aplikasi dunia nyata dengan tingkat akurasi yang dapat diandalkan.

4. Evaluasi

4.1 Hasil Pengujian

Pada skenario pengujian, model yang digunakan adalah YOLOv8n (Nano) karena ringan, efisien, dan optimal untuk deteksi pada rekaman kamera surveilans beresolusi rendah (480p ke bawah). Model dilatih dengan imsz 640x640, learning rate 0.01, optimizer AdamW, dan weight decay 0.0005, sementara parameter lainnya menggunakan pengaturan default YOLOv8n. Kombinasi ini memastikan model tetap stabil, akurat, dan mampu mendeteksi berbagai varian penggunaan helm dalam kondisi pencahayaan serta resolusi yang sama.

4.1.1. Epoch

Pada skenario pengujian, parameter epoch diuji dengan nilai 25, 50, dan 100 untuk mengevaluasi pengaruhnya terhadap kinerja model YOLOv8n dalam deteksi helm. Evaluasi dilakukan berdasarkan mAP, precision, recall, dan F1-score untuk menentukan jumlah epoch yang optimal. Epoch 25 digunakan untuk melihat apakah model sudah cukup belajar tanpa overfitting atau underfitting, epoch 50 sebagai titik keseimbangan antara akurasi dan efisiensi pelatihan, serta epoch 100 untuk mengetahui apakah peningkatan jumlah epoch masih berdampak positif atau sebaliknya menyebabkan overfitting.

4.1.2. Batch Size

Pada skenario pengujian ini, parameter batch size diuji dengan variasi 4, 16, dan 32 untuk mengevaluasi pengaruhnya terhadap kinerja model YOLOv8n dalam mendeteksi penggunaan helm. Batch size 4 digunakan untuk mengamati stabilitas pembelajaran dengan ukuran batch kecil, meskipun proses pelatihan menjadi lebih lambat. Batch size 16 dipilih sebagai nilai tengah untuk mencapai keseimbangan antara efisiensi komputasi dan konvergensi model. Sementara itu, batch size 32 diuji untuk menilai apakah peningkatan ukuran batch dapat mempercepat pelatihan dan meningkatkan generalisasi model tanpa mengorbankan akurasi. Evaluasi dilakukan menggunakan metrik mAP, precision, recall, dan F1-score guna menentukan konfigurasi batch size yang optimal.

4.2 Analisis Hasil Pengujian

4.2.1. Pengujian Epoch dan Batch Size

Tabel 4.1 Hasil Percobaan Epoch 25 dengan Batch Size

Parameter		Metrik Evaluasi				
Epoch	Batch Size	Precision	Recall	F1-Score	mAP@50	mAP@50-95
25	4	0.874	0.809	0.841	0.913	0.721
25	16	0.870	0.852	0.859	0.925	0.733
25	32	0.875	0.854	0.864	0.915	0.726

Pada tabel 4.1 pengujian YOLOv8n dengan 25 epoch, batch size 16 memberikan hasil terbaik dengan mAP@50 sebesar 0.925, mAP@50-95 sebesar 0.733, precision 0.870, recall 0.852, dan F1-score 0.859. Sementara itu, batch size 4 memperoleh mAP@50 0.913, mAP@50-95 0.721, precision 0.874, recall 0.809, dan F1-score 0.841, yang menunjukkan recall lebih rendah. Batch size 32 mencatat mAP@50 0.915, mAP@50-95 0.726, precision 0.875, recall 0.854, dan F1-score 0.864, dengan performa mendekati batch size 16 namun kurang optimal pada mAP@50-95. Hasil ini menunjukkan bahwa batch size 16 memberikan keseimbangan terbaik dalam mendeteksi objek secara akurat.

Tabel 4.2. Hasil Percobaan Epoch 50 dengan Batch Size

Parameter		Metrik Evaluasi				
Epoch	Batch Size	Precision	Recall	F1-Score	mAP@50	mAP@50-95
50	4	0.901	0.890	0.895	0.962	0.779
50	16	0.923	0.896	0.909	0.963	0.778
50	32	0.907	0.938	0.922	0.979	0.794

Pada tabel 4.2 pengujian YOLOv8n dengan 50 epoch, batch size 32 memberikan hasil terbaik dengan mAP@50 sebesar 0.979, mAP@50-95 sebesar 0.794, precision 0.907, recall 0.938, dan F1-score 0.922, menunjukkan deteksi objek yang lebih akurat dibandingkan batch size lainnya. Batch size 16 memperoleh mAP@50 0.963, mAP@50-95 0.778, precision 0.923, recall 0.896, dan F1-score 0.909, yang masih cukup baik namun lebih rendah dari batch size 32 dalam beberapa aspek. Batch size 4 mencatat mAP@50 0.962, mAP@50-95 0.779, precision 0.901, recall 0.890, dan F1-score 0.895, menunjukkan performa yang cukup stabil tetapi lebih rendah dibandingkan batch size 16 dan 32 dalam recall dan F1-score. Hasil ini mengindikasikan bahwa peningkatan batch size cenderung meningkatkan akurasi deteksi objek, terutama dalam recall dan F1-score.

Tabel 4.3. Hasil Percobaan Epoch 100 dengan Batch Size

Parameter		Metrik Evaluasi				
Epoch	Batch Size	Precision	Recall	F1-Score	mAP@50	mAP@50-95
100	4	0.949	0.947	0.948	0.985	0.814
100	16	0.929	0.929	0.929	0.974	0.799
100	32	0.953	0.952	0.953	0.984	0.819

Pada tabel 4.3. pengujian YOLOv8n dengan 100 epoch, batch size 32 memberikan hasil terbaik dengan mAP@50 sebesar 0.984, mAP@50-95 sebesar 0.819, precision 0.953, recall 0.952, dan F1-score 0.953, menunjukkan performa yang lebih stabil dalam mendeteksi objek dibandingkan batch size lainnya. Batch size 16 memperoleh mAP@50 0.974, mAP@50-95 0.799, precision 0.929, recall 0.929, dan F1-score 0.929, yang masih cukup baik namun sedikit lebih rendah dibandingkan batch size 32 dalam beberapa aspek. Batch size 4 mencatat mAP@50 0.985, mAP@50-95 0.814, precision 0.949, recall 0.947, dan F1-score 0.948, menunjukkan performa yang sangat kompetitif namun masih kalah dalam beberapa metrik dibandingkan batch size 32. Hasil ini mengindikasikan bahwa peningkatan batch size hingga 32 memberikan performa terbaik, terutama dalam menjaga keseimbangan precision dan recall.

4.2.2. Pemilihan Parameter Terbaik

Tabel 4.4. Hasil Percobaan Terbaik Setiap Epoch

Parameter		Metrik Evaluasi				
Epoch	Batch Size	Precision	Recall	F1-Score	mAP@50	mAP@50-95
25	16	0.870	0.852	0.859	0.925	0.733
50	32	0.907	0.938	0.922	0.979	0.794
100	32	0.953	0.952	0.953	0.984	0.819

Berdasarkan hasil pengujian model YOLOv8n dengan variasi batch size (4, 16, dan 32) pada epoch 25, 50, dan 100, ditemukan bahwa batch size 32 dengan 100 epoch memberikan performa terbaik di semua metrik evaluasi. Pada konfigurasi ini, model mencapai mAP@50 sebesar 0.984, mAP@50-95 sebesar 0.819, precision sebesar 0.953, recall sebesar 0.952, dan F1-score sebesar 0.953.

Pada epoch 50, batch size 32 juga menunjukkan hasil yang cukup baik dengan mAP@50 sebesar 0.979, mAP@50-95 sebesar 0.794, precision sebesar 0.907, recall sebesar 0.938, dan F1-score sebesar 0.922. Meskipun demikian, hasil ini masih lebih rendah dibandingkan dengan batch size 32 pada epoch 100. Sementara itu, batch size 16 pada epoch 25 mencapai mAP@50 sebesar 0.925 dan mAP@50-95 sebesar 0.733, namun menunjukkan performa yang lebih rendah dalam recall dibandingkan dengan batch size 32. Model dengan parameter-parameter terbaik tersebut kemudian diuji menggunakan data baru, yaitu data testing, untuk mengevaluasi performanya pada kondisi di luar data pelatihan. Hasil evaluasi pengujian pada data testing dapat dilihat pada tabel 4.5.

Tabel 4.5. Pengujian Parameter Terbaik pada Data Testing

Parameter		Metrik Evaluasi				
Epoch	Batch Size	Precision	Recall	F1-Score	mAP@50	mAP@50-95
25	16	0.868	0.848	0.858	0.935	0.729
50	32	0.965	0.933	0.949	0.978	0.782
100	32	0.955	0.960	0.958	0.985	0.802

Hasil confusion matrix dari setiap pengujian parameter terbaik tersebut dapat dilihat pada tabel 4.6, 4.7, dan 4.8.

Tabel 4.6. Confusion Matrix Epoch 25 dengan Batch Size 16 pada Data Testing

Confusion Matrix Epoch 25 dengan Batch size 16					
Class	helmet_	helmet_	helmet_	no_helmet	background

	fullface	halfface	nonstandard		
helmet_fullface	20	8	-	-	14
helmet_halfface	3	89	12	1	44
helmet_nonstandard	1	6	45	4	23
no_helmet	-	-	-	106	31
background	-	-	-	8	-

Tabel 4.7. Confusion Matrix Epoch 50 dengan Batch Size 32 pada Data Testing

Confusion Matrix Epoch 50 dengan Batch size 32					
Class	helmet_ fullface	helmet_ halfface	helmet_ nonstandard	no_helmet	background
helmet_fullface	23	-	-	-	3
helmet_halfface	1	100	2	-	21
helmet_nonstandard	-	2	55	1	10
no_helmet	-	-	-	113	24
background	-	1	-	5	-

Tabel 4.8. Confusion Matrix Epoch 100 dengan Batch Size 32 pada Data Testing

Confusion Matrix Epoch 100 dengan Batch size 32					
Class	helmet_ fullface	helmet_ halfface	helmet_ nonstandard	no_helmet	background
helmet_fullface	24	-	-	-	3
helmet_halfface	-	100	1	1	15
helmet_nonstandard	-	1	56	-	5
no_helmet	-	-	-	115	9
background	-	2	-	3	-

Dari hasil ini, dapat disimpulkan bahwa peningkatan jumlah epoch dan penggunaan batch size yang lebih besar berkontribusi terhadap peningkatan akurasi model. Konfigurasi optimal diperoleh pada batch size 32 dengan 100 epoch, di mana model dapat mendeteksi objek dengan akurasi tinggi serta keseimbangan yang baik antara precision dan recall. Contoh hasil prediksi dari model epoch 100 dengan batch size 32 dengan data testing dapat dilihat pada Gambar 4.1.



Gambar 4.1 Hasil Prediksi Model Epoch 100 dengan Batch Size 32 pada Data Testing

5. Kesimpulan

Penelitian ini berhasil mengoptimalkan model deep learning berbasis YOLOv8n untuk mendeteksi penggunaan helm pada pengendara sepeda motor dalam kondisi citra beresolusi rendah. Model diuji dengan berbagai skenario, termasuk variasi batch size dan jumlah epoch, untuk menemukan konfigurasi optimal. Hasil pengujian menunjukkan bahwa model mampu mendeteksi empat kategori penggunaan helm full-face, half-face, non-standar, dan tidak menggunakan helm dengan akurasi yang tinggi. Penggunaan batch size 32 dan epoch 100 memberikan hasil terbaik dengan mAP@50 sebesar 0.984, precision 0.953, recall 0.952, dan F1-

score 0.953.

Dengan demikian, model yang dikembangkan dapat mengatasi tantangan deteksi helm pada rekaman kamera surveilans dengan resolusi rendah serta mampu mendeteksi variasi helm secara lebih spesifik dibandingkan penelitian sebelumnya. Hasil ini menunjukkan bahwa metode YOLOv8n efektif dalam meningkatkan akurasi deteksi helm dan dapat diterapkan dalam sistem pemantauan lalu lintas untuk meningkatkan kepatuhan pengendara terhadap regulasi keselamatan berkendara.

Untuk pengembangan penelitian selanjutnya, beberapa aspek dapat ditingkatkan agar sistem deteksi helm berbasis deep learning semakin optimal dalam mendukung keselamatan berkendara.

1. Pengembangan Dataset

Dataset yang digunakan dapat diperluas dengan menambahkan variasi sudut pandang, lokasi, pencahayaan, dan kondisi cuaca. Hal ini bertujuan untuk meningkatkan generalisasi model terhadap berbagai skenario dunia nyata, sehingga model tetap dapat mendeteksi penggunaan helm dengan akurat dalam kondisi lingkungan yang beragam.

2. Peningkatan dan Perluasan Pengujian Hyperparameter

Pengujian lebih lanjut terhadap berbagai kombinasi hyperparameter, seperti learning rate, optimizer, batch size, dan jumlah epoch, perlu dilakukan untuk menemukan konfigurasi yang lebih optimal dalam meningkatkan performa deteksi model.

3. Perbandingan dengan Model Serupa

Untuk mendapatkan wawasan yang lebih luas terkait efektivitas metode yang digunakan, penelitian mendatang dapat melakukan perbandingan dengan model deteksi objek lain seperti Faster R-CNN, EfficientDet, atau Vision Transformers. Perbandingan ini dapat membantu dalam memahami keunggulan dan keterbatasan masing-masing model terhadap tugas pendeteksian helm.

4. Integrasi dengan Sistem Pendeteksian Pelanggaran

Model yang dikembangkan dapat diintegrasikan lebih lanjut ke dalam sistem pelanggaran lalu lintas berbasis surveilans. Implementasi ini memungkinkan sistem otomatis dalam mendeteksi dan mencatat pelanggaran penggunaan helm di jalan raya, sehingga dapat mendukung kebijakan keselamatan berkendara secara lebih efektif.

Dengan pengembangan lebih lanjut dalam aspek-aspek tersebut, diharapkan sistem deteksi helm ini dapat semakin akurat, efisien, dan aplikatif untuk digunakan dalam sistem pemantauan lalu lintas di berbagai kondisi lingkungan.

Daftar Pustaka

- [1] Kompas.com, "Jumlah Sepeda Motor di Indonesia Tembus 128 Juta Unit," <https://otomotif.kompas.com/read/2023/03/19/082100215/jumlah-sepeda-motor-di-indonesia-tembus-128-juta-unit>.
- [2] Kompas.com, "Sepeda Motor Jadi Penyumbang Kecelakaan Tertinggi Sepanjang 2023," <https://otomotif.kompas.com/read/2024/01/17/071200015/sepeda-motor-jadi-penyumbang-kecelakaan-tertinggi-sepanjang-2023>.
- [3] Pemerintah Pusat Indonesia, "Undang-undang Nomor 22 Tahun 2009 tentang Lalu Lintas Dan Angkutan Jalan," <https://peraturan.bpk.go.id/Details/38654/uu-no-22-tahun-2009>.
- [4] D. Hazra and Y.-C. Byun, "Upsampling real-time, low-resolution CCTV videos using generative adversarial networks," *Electronics (Basel)*, vol. 9, no. 8, p. 1312, 2020.
- [5] J. Mercado Reyna et al., "Detection of Helmet Use in Motorcycle Drivers Using Convolutional Neural Network," *Applied Sciences*, vol. 13, no. 10, p. 5882, 2023.
- [6] T. Waris et al., "CNN-Based Automatic Helmet Violation Detection of Motorcyclists for an Intelligent Transportation System," *Math Probl Eng*, vol. 2022, no. 1, p. 8246776, 2022.
- [7] M. Dasgupta, O. Bandyopadhyay, and S. Chatterji, "Automated helmet detection for multiple motorcycle riders using CNN," in *2019 IEEE Conference on Information and Communication Technology, IEEETechConf, 2019*, pp. 1–4.
- [8] A. Afzal, H. U. Draz, M. Z. Khan, and M. U. G. Khan, "Automatic helmet violation detection of motorcyclists from surveillance videos using deep learning approaches of computer vision," in *2021 International Conference on Artificial Intelligence (ICAI), IEEE, 2021*, pp. 252–257.
- [9] M. Jakubec, E. Lieskovska, A. Brezani, and J. Tothova, "Deep learning-based automatic helmet recognition for two-wheeled road safety," *Transportation research procedia*, vol. 74, pp. 1171–1178, 2023.
- [10] A. Albert, K. Gunadi, and E. Setyati, "Deteksi Helm pada Pengguna Sepeda Motor dengan Metode Convolutional Neural Network," *Jurnal Infra*, vol. 8, no. 1, pp. 295–301, 2020.
- [11] bandungkita.id, "Pakai Helm Full Face, Masih Perlukah Kenakan Masker? Ini Penjelasan," <https://bandungkita.id/2020/06/17/pakai-helm-full-face-masih-perluakah-kenakan-masker-ini-penjelasan/>.
- [12] motorexperz.com, "Ragam Helm Motor: Half Face, Full Face, dan Modular, Apa Bedanya?," <https://motorexperz.com/read/28036/ragam-helm-motor-half-face-full-face-dan-modular-apa-bedanya>.
- [13] oto.detik.com, "Kenali 7 Jenis Helm Motor Beserta Kegunaan dan Tingkat Keamanannya," <https://oto.detik.com/motor/d-7221574/kenali-7-jenis-helm-motor-beserta-kegunaan-dan-tingkat-keamanannya>.

- [14] rsa.or.id, “Mana Helmnya?,” <https://rsa.or.id/mana-helmnya/>.
- [15] A. KM and A. KK, “A Review on Deep Learning Based Helmet Detection,” in Proceedings of the International Conference on Systems, Energy & Environment (ICSEE), 2021.
- [16] B. Yogameena, K. Menaka, and S. Saravana Perumaal, “Deep learning-based helmet wear analysis of a motorcycle rider for intelligent surveillance system,” IET Intelligent Transport Systems, vol. 13, no. 7, pp. 1190–1198, 2019.
- [17] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, “A survey of convolutional neural networks: analysis, applications, and prospects,” IEEE Trans Neural Netw Learn Syst, vol. 33, no. 12, pp. 6999–7019, 2021.
- [18] F. I. Ariwibowo and D. P. Ismi, “Transforming traffic surveillance: a YOLO-based approach to detecting helmetless riders through CCTV,” Science in Information Technology Letters, vol. 3, no. 1, pp. 45–58, 2022.
- [19] A. Amin and M. W. Kasrani, “Penerapan Metode Yolo Object Detection V1 Terhadap Proses Pendeteksian Jenis Kendaraan Di Parkiran,” Jurnal Teknik Elektro Uniba (JTE UNIBA), vol. 6, no. 1, pp. 194–199, 2021.
- [20] T. A. A. H. Kusuma, K. Usman, and S. Saidah, “People Counting for Public Transportations Using You Only Look Once Method,” Jurnal Teknik Informatika (Jutif), vol. 2, no. 1, pp. 57–66, 2021.
- [21] J. S. W. Hutauruk, T. Matulatan, and N. Hayaty, “Deteksi kendaraan secara real time menggunakan metode YOLO berbasis android,” Jurnal Sustainable: Jurnal Hasil Penelitian dan Industri Terapan, vol. 9, no. 1, pp. 8–14, 2020.
- [22] A. Hayat and F. Morgado-Dias, “Deep learning-based automatic safety helmet detection system for construction safety,” Applied Sciences, vol. 12, no. 16, p. 8268, 2022.

Lampiran

