

BAB I

PENDAHULUAN

1.1 Latar Belakang

Total kecelakaan yang melibatkan sepeda motor di dunia menyumbang sekitar 23% dari total kematian akibat lalu lintas, dengan lebih dari setengah kasus terjadi di negara-negara yang menjadikan sepeda motor sebagai moda transportasi utama [1]. Hal ini juga didukung *Central Statistics Agency* (BPS) menunjukkan bahwa dalam periode 2019-2021 terjadi tren peningkatan kecelakaan dengan jumlah kejadian mencapai 103.645 pada tahun 2021 [2]. Jika dibandingkan dengan pengendara mobil, tingkat fatalitas pada pengendara sepeda motor bahkan dapat mencapai 26 kali lebih tinggi [3]. Selain itu, kelompok usia muda 15-34 tahun menyumbang lebih dari 60% dari total kematian yang melibatkan kendaraan roda dua dan tiga di negara dengan tingkat pendapatan rendah hingga menengah. Di Indonesia Sepeda motor tercatat sebagai penyumbang terbesar angka kematian di jalan raya dengan proporsi mencapai sekitar 81%, tren tersebut terjadi peningkatan jumlah kecelakaan lalu lintas pada periode tahun 2024 [4]. Hal ini didukung oleh data dari Korlantas Polri melalui sistem (IRMS) yang mencatat sebanyak 79.220 kasus kecelakaan hingga 5 Agustus 2024 dimana sepeda motor menjadi kendaraan yang paling dominan terlibat, yaitu sebesar 76,42% atau sekitar 552.155 unit dari total 722.470 kendaraan yang terlibat [5]. Jumlah korban tercatat mencapai 117.962 orang, dimana 7,21% di antaranya meninggal dunia, 8,26% mengalami luka berat, dan 84,51% mengalami luka ringan, sehingga menunjukkan bahwa risiko kecelakaan bagi pengendara sepeda motor di jalan raya masih tergolong tinggi [5].

Di sisi lain, penggunaan helm memiliki peranan yang sangat penting dalam mengurangi tingkat fatalitas akibat kecelakaan lalu lintas, khususnya bagi pengendara sepeda motor [6]. Menurut World Health Organization, penggunaan helm mampu menurunkan tingkat keparahan cedera hingga sekitar 72% serta mengurangi risiko kematian akibat kecelakaan lalu lintas hingga sekitar 39% [7]. Hal ini juga didukung menurut BMC *Public Health* helm diketahui mampu

menurunkan risiko cedera fatal sebesar 37% pada pengendara dan 41% pada penumpang [8]. Berdasarkan survei *National Occupant Protection Use Survey* (NOPUS), tingkat penggunaan helm yang memenuhi standar *Department of Transportation* (DOT) pada tahun 2023 mencapai 73,8%, meningkat sebesar 7,3 poin persentase dibandingkan tahun 2022 serta naik 9,5 poin persentase dalam kurun waktu 10 tahun terakhir, yang menunjukkan adanya peningkatan kesadaran masyarakat terhadap keselamatan berkendara [9]. Namun demikian, di wilayah yang belum menerapkan regulasi ketat, tingkat penggunaan helm masih relatif rendah, yakni hanya sekitar 56,2% [10]. Selain itu, temuan dari *National Library of Medicine* menunjukkan bahwa lebih dari 70% pengendara yang mengalami kecelakaan tanpa menggunakan helm meninggal di lokasi kejadian [11]. Berdasarkan fakta-fakta ini, khususnya terkait tingkat penggunaan helm di jalan raya, pengembangan sistem deteksi otomatis untuk penggunaan *helm* dalam lalu lintas menjadi penting.

Sejalan dengan kondisi tersebut, diperlukan pemanfaatan teknologi untuk membantu mengatasi permasalahan yang ada. Salah satu metode yang banyak diterapkan adalah image detection berbasis computer vision yang mampu melakukan identifikasi objek secara otomatis pada gambar digital [12]. Berbagai penelitian telah dilakukan untuk mendeteksi penggunaan helm secara otomatis menggunakan pendekatan *machine learning* dan *deep learning*. Model *Solid-State Drive* (SSD) yang digunakan untuk melakukan klasifikasi objek pada gambar dalam satu tahap proses menghasilkan nilai *precision* sebesar 0,835, *recall* sebesar 0,467, dan mAP sebesar 0,656, sehingga menunjukkan performa deteksi yang cukup cepat namun tingkat akurasi masih tergolong terbatas [13]. RetinaNet yang berfungsi untuk mengatasi ketidakseimbangan data melalui mekanisme *focal loss* memiliki *precision* 0,865, *recall* 0,892, dan mAP mencapai 0,883, meskipun kompleksitas model meningkat [14]. Faster R-CNN menghasilkan *precision* 0,719, *recall* 0,767, dan mAP 0,734 dengan jumlah parameter yang cukup besar, yaitu 137M, sehingga kurang efisien. Sementara itu [15], YOLOv3 menunjukkan keseimbangan antara kecepatan dan akurasi dengan mAP sebesar 0,803 dan kecepatan 69 fps [16]. YOLOv4 memberikan peningkatan signifikan dengan

precision 0,804, *recall* 0,827, serta *mAP* 0,817, meskipun ukuran model relatif besar [17]. Selain itu, pendekatan berbasis *image processing* dan *Backpropagation Neural Network* juga pernah digunakan untuk klasifikasi penggunaan *helm* dengan tingkat akurasi mencapai 0,867, di mana variasi *learning rate* tidak memberikan pengaruh signifikan terhadap kinerja model [18]. Meskipun berbagai metode tersebut telah menunjukkan performa yang cukup baik, masing-masing masih memiliki keterbatasan, baik dari sisi efisiensi [13][16], kompleksitas model [15][16][17], maupun kemampuan dalam mendeteksi objek kecil secara optimal dalam kondisi lingkungan yang kompleks [13][14][18]. Dengan demikian, diperlukan pengembangan metode yang lebih adaptif dan efisien untuk meningkatkan performa deteksi objek secara keseluruhan.

Pengembangan metode deteksi objek terus mengalami peningkatan melalui berbagai versi arsitektur YOLO yang dirancang untuk menghasilkan performa lebih optimal [12] [19]. Berdasarkan hasil pengujian yang dilakukan, YOLOv5 mampu memperoleh nilai *mAP* sebesar 0,819 dengan kecepatan inferensi mencapai 96,2 FPS, sehingga model tersebut dinilai cukup optimal untuk kebutuhan deteksi objek secara real-time [20][19]. Pada versi berikutnya, YOLOv6 menunjukkan peningkatan performa dengan nilai *mAP* sebesar 0,838, meskipun kecepatan pemrosesan menurun menjadi sekitar 68,4 FPS [19]. Sementara itu, YOLOv7 memperlihatkan nilai *mAP* sebesar 0,573 dengan kecepatan inferensi sekitar 52,6 FPS [19][21]. Perkembangan lebih lanjut ditunjukkan oleh YOLOv8s hingga YOLOv11s yang memberikan peningkatan baik dari sisi akurasi maupun kecepatan. YOLOv11s mampu mencapai *mAP* sebesar 0,768, yang lebih tinggi dibandingkan YOLOv8 dan YOLOv10 [22][23][24][25], terutama dalam mendeteksi objek berukuran kecil. Selain itu, YOLOv11s juga menunjukkan peningkatan kecepatan inferensi hingga 290 FPS, lebih cepat dibandingkan YOLOv10 (280 FPS) dan YOLOv8 (260 FPS) [22][23][26]. Temuan tersebut menunjukkan bahwa perkembangan arsitektur model tidak selalu menghasilkan peningkatan performa yang konsisten pada setiap versinya [19][22][23][24], dimana implementasinya secara real-time masih menghadapi keterbatasan yang cukup signifikan. Sebagian besar sistem yang dikembangkan masih menunjukkan

akurasi yang relatif rendah ketika dihadapkan pada kondisi lalu lintas yang dinamis, seperti perubahan pencahayaan, variasi sudut pandang kamera, serta kepadatan kendaraan yang tinggi [19][22].

Pengembangan model deteksi helm menunjukkan bahwa penerapan *attention mechanism* memiliki peran penting dalam meningkatkan kemampuan model untuk mengenali objek secara lebih akurat, khususnya pada kondisi yang kompleks, serta membantu meningkatkan performa deteksi secara *real-time*. [27]. Beberapa penelitian mengintegrasikan penggunaan sistem HWD-YOLO, dengan mengandalkan MSCAM untuk deteksi helm di area kerja yang kompleks, Modul *DetectBlock* untuk mendeteksi objek yang kecil dan jauh, sehingga meningkatkan akurasi dalam situasi di mana objek tersebut sulit diidentifikasi, Modul *Implicit Information* untuk meningkatkan efisiensi dan kecepatan pemrosesan, dan Modul GBS untuk efisiensi komputasi, memastikan penggunaan sumber daya yang lebih optimal selama pemrosesan data. Hasil tersebut membuat peningkatan *Mean Average Precision* (mAP) sebesar 3,4% [28]. Namun sistem tersebut masih menghadapi kesulitan dalam mendeteksi objek kecil, pengendara yang bergerak cepat, serta membedakan antara pengendara dan penumpang dalam situasi yang padat [28][29]. Pengembangan lebih lanjut menggunakan YOLOv11 berbasis MS-CAM, MultiSEAM, serta Adown untuk kegunaan *real-time*, yang berhasil mengurangi beban komputasi sekaligus meningkatkan akurasi deteksi helm di lingkungan industri, namun kecepatan deteksi di jalanan yang penuh gangguan tetap menjadi tantangan, masih terdapat banyak *false positive* dari sisi *background* dan akurasi *precision* masih di sekitar 88,89 [30][24][31]. Metode lainnya, seperti *multi-task learning* berbasis CNN, juga menunjukkan kemajuan dalam melacak motor dan mendeteksi penggunaan helm dengan *F-measure* mencapai 67,3% [32]. Meskipun menghasilkan nilai *F-measure* yang tinggi, model tersebut masih memiliki kendala pada penggunaan perangkat keras dengan sumber daya terbatas, seperti kamera CCTV atau perangkat *edge*, sehingga dapat mengurangi efisiensi dalam proses pengolahan data [32][33].

Berdasarkan dari penelitian terdahulu maka terciptanya solusi yang diusulkan dalam penelitian ini adalah mengoptimalkan performa deteksi *helm* berbasis

YOLOv11s melalui integrasi beberapa komponen pengembangan model. Arsitektur yang digunakan mengombinasikan *backbone* dan *neck* dari YOLOv11s dengan penambahan modul *attention* MSCAM yang bekerja pada proses ekstraksi fitur untuk menekankan informasi spasial dan kanal yang relevan sehingga mampu membantu model bekerja pada kondisi *real-time*. Selain itu, DetectBlock ditambahkan pada tahap deteksi untuk meningkatkan sensitivitas model dalam mengenali objek berukuran kecil maupun objek yang berada pada jarak yang lebih jauh. Pada tahap pelatihan, digunakan fungsi *loss Generalized Intersection over Union* (GIoU) untuk memperbaiki proses regresi *bounding box* dengan mempertimbangkan area *overlap* dan jarak antar kotak prediksi dengan *ground truth*. Sehingga model yang diusulkan diharapkan mampu meningkatkan akurasi dan keandalan deteksi helm pada berbagai kondisi lingkungan serta mendukung penerapan sistem pemantauan keselamatan berkendara secara otomatis.

1.2 Rumusan Masalah

Rumusan masalah dalam penelitian skripsi ini meliputi:

1. Bagaimana pemanfaatan model *object detection* YOLOv11 konvensional dalam mendeteksi penggunaan helm pada pengendara, serta sejauh mana kemampuan model tersebut dalam menghasilkan performa yang optimal ditinjau dari nilai *precision*, *recall*, mAP, dan F1-score dalam berbagai kondisi lingkungan yang kompleks?
2. Bagaimana perbandingan performa antar ukuran model YOLOv11 (n, s, m, l) serta perbandingannya dengan model YOLO versi sebelumnya seperti YOLOv5 dan YOLOv8 dalam meningkatkan kualitas deteksi objek dan *object detection* model selain YOLO seperti Faster R-CNN dan RetinaNet?
3. Bagaimana pengaruh penerapan berbagai *Attention Mechanism* seperti MSCAM, CBAM, SEBlock, ECA, SimAM, GAM, dan CA dalam meningkatkan kemampuan akurasi model YOLOv11 pada kondisi *real-time*, sehingga dapat meningkatkan ketepatan deteksi terutama pada objek kecil, objek yang terhalang, maupun kondisi latar belakang yang kompleks?

4. Bagaimana kontribusi penambahan DetectBlock dalam arsitektur YOLOv11 terhadap peningkatan kemampuan model dalam mendeteksi objek dengan ukuran kecil dan jarak yang jauh?
5. Bagaimana pengaruh penggunaan variasi *loss function* seperti CIOU, DIOU, GIOU, SIOU, dan EIOU dalam proses pelatihan model terhadap peningkatan akurasi prediksi *bounding box*?
6. Bagaimana hasil perbandingan kinerja model YOLOv11s yang sudah di optimalisasi dibandingkan algoritma yang konvensional?

1.3 Batasan Masalah

Batasan masalah dalam penelitian skripsi ini meliputi:

1. Penelitian hanya menggunakan dataset yang tersedia untuk deteksi helm di lalu lintas, tidak termasuk lingkungan industri atau konstruksi yang diambil dari Roboflow (*dataset open source*) dengan jumlah gambar 4.172 yang diambil pada tahun 2023. (<https://universe.roboflow.com/project/helmet-detection-wwlwv-ips0g/dataset/1>)
2. Metode yang digunakan terbatas pada model YOLOv11 yang dimodifikasi dengan penekanan pada peningkatan akurasi dan efisiensi.
3. Pengujian dilakukan di lingkungan simulasi dan tidak mencakup semua variasi kondisi cuaca dan pencahayaan secara *real-time*.
4. Model hanya dirancang untuk mendeteksi penggunaan helm pada pengendara motor.
5. Deteksi objek lain, seperti kendaraan non-motor atau pejalan kaki, tidak menjadi prioritas dalam penelitian ini.
6. Penelitian ini difokuskan pada pengembangan model deteksi berbasis YOLOv11 dengan penerapan beberapa teknik peningkatan performa, yaitu penggunaan *attention mechanism* (MSCAM), penambahan DetectBlock untuk optimalisasi deteksi objek kecil, serta pemanfaatan variasi fungsi *loss* seperti CIOU dan GIOU dalam proses pelatihan model.
7. Penelitian ini menggunakan *framework Cross-Industry Standard Process for Data Mining* (CRISP-DM).

1.4 Tujuan dan Manfaat Penelitian

1.4.1 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah dijelaskan, maka tujuan penelitian ini dapat dirumuskan sebagai berikut:

1. Menganalisis pemanfaatan model object detection YOLOv11 konvensional dalam mendeteksi penggunaan helm pada pengendara serta mengevaluasi performanya berdasarkan metrik *precision*, *recall*, mAP, dan *F1-score* pada berbagai kondisi lingkungan.
2. Membandingkan performa antar ukuran model YOLOv11 (n, s, m, l) serta mengevaluasi perbedaannya dengan model YOLO versi sebelumnya seperti YOLOv5 dan YOLOv8 dalam meningkatkan kualitas deteksi objek dan model *object detection* YOLO seperti Faster R-CNN dan RetinaNet.
3. Mengkaji pengaruh penerapan berbagai *attention mechanism*, seperti MSCAM, CBAM, SEBlock, ECA, SimAM, GAM, dan CA, terhadap peningkatan kemampuan model dalam memfokuskan fitur penting sehingga mampu meningkatkan akurasi deteksi secara *real-time*.
4. Menganalisis kontribusi penambahan DetectBlock dalam arsitektur YOLOv11 terhadap peningkatan kemampuan deteksi objek berukuran kecil dan objek yang berada pada jarak jauh.
5. Mengevaluasi pengaruh penggunaan variasi *loss function*, seperti CIOU, DIOU, GIOU, SIOU, dan EIOU, dalam proses pelatihan model terhadap peningkatan akurasi prediksi *bounding box* dan stabilitas model.
6. Membandingkan performa antara YOLOv11s yang sudah dioptimalisasi dengan YOLOv11s secara konvensional.

1.4.2 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan ilmu pengetahuan serta penerapan teknologi di bidang *computer vision*, khususnya pada sistem deteksi penggunaan helm bagi pengendara sepeda motor. Adapun manfaat dari penelitian ini dibagi ke dalam dua aspek, yaitu manfaat teoritis dan manfaat praktis.

1. Manfaat Teoritis

Kontribusi akademis dari penelitian ini berkaitan dengan pengembangan metode deteksi objek berbasis *deep learning*, khususnya pada peningkatan performa model YOLOv11s. Rincian manfaat teoritis adalah sebagai berikut:

- a. Memperkuat kajian ilmiah terkait *object detection* dalam konteks keselamatan berkendara, khususnya deteksi penggunaan helm dengan memanfaatkan arsitektur YOLOv11s sebagai model terkini.
- b. Memberikan pemahaman lebih mendalam mengenai pengaruh variasi arsitektur model YOLO (n, s, m, l) serta perbandingannya dengan model sebelumnya seperti YOLOv5 dan YOLOv8, dan juga model *object detection* selain YOLO seperti Faster R-CNN dan RetinaNet terhadap performa deteksi objek.
- c. Menganalisis kontribusi berbagai *attention mechanism* dalam meningkatkan kemampuan model dalam mengekstraksi fitur penting, terutama pada objek kecil.
- d. Mengevaluasi secara sistematis pengaruh variasi *loss function* terhadap kualitas prediksi *bounding box*, stabilitas pelatihan, serta peningkatan metrik evaluasi.
- e. Menghasilkan kerangka pengembangan model deteksi helm yang lebih terstruktur, mulai dari *baseline* model hingga optimasi arsitektur, yang dapat dijadikan referensi untuk penelitian lanjutan di bidang *computer vision*.

2. Manfaat Praktis

Manfaat praktis penelitian ini berfokus pada penerapan hasil penelitian dalam mendukung peningkatan keselamatan berkendara serta efektivitas pemantauan di lingkungan nyata. Adapun manfaat yang diharapkan adalah sebagai berikut:

- a. Mendukung upaya pemantauan penggunaan helm pada pengendara secara lebih akurat dan konsisten, terutama dalam kondisi lingkungan yang kompleks seperti kepadatan lalu lintas, variasi pencahayaan, dan objek yang saling terhalang.

- b. Membantu pihak terkait dalam meningkatkan efektivitas pengawasan keselamatan berkendara, sehingga dapat berkontribusi dalam menurunkan risiko kecelakaan akibat tidak menggunakan helm.
- c. Memberikan pendekatan yang lebih efisien dalam proses identifikasi pelanggaran penggunaan helm dibandingkan metode manual, sehingga dapat menghemat waktu dan tenaga dalam kegiatan *monitoring*.
- d. Menyediakan acuan dalam pengembangan teknologi deteksi objek yang memiliki keseimbangan antara tingkat akurasi dan kecepatan pemrosesan untuk kebutuhan *real-time*.
- e. Menjadi referensi dalam pengembangan lebih lanjut terkait optimasi model deteksi objek, khususnya dalam penerapan *attention mechanism*, pengolahan objek kecil, serta peningkatan kualitas prediksi *bounding box* pada berbagai kondisi lapangan.

1.5 Sistematika Penulisan

Penulisan karya ilmiah ini terdiri dari lima bab utama yang masing-masing menjelaskan sistematika penulisan. Secara garis besar, sistematika tersebut dapat dijabarkan sebagai berikut:

BAB 1 PENDAHULUAN

Bab pertama berisi penjelasan mengenai latar belakang penelitian yang mengangkat permasalahan keselamatan berkendara khususnya penggunaan helm, serta pentingnya penerapan teknologi deteksi objek secara otomatis. Selain itu, pada bab ini juga dijelaskan rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, serta sistematika penulisan. Bab ini memberikan gambaran umum mengenai arah penelitian serta kontribusi yang diharapkan.

BAB II LANDASAN TEORI

Bab kedua membahas teori-teori yang mendukung penelitian serta studi literatur yang relevan terkait deteksi objek dan penggunaan helm. Pembahasan meliputi konsep dasar *computer vision*, *object detection*, serta perkembangan algoritma seperti YOLOv5, YOLOv8, hingga YOLOv11. Selain itu, dijelaskan pula konsep *attention mechanism* (MSCAM, CBAM, SEBlock, dan lainnya), DetectBlock, serta berbagai fungsi *loss* seperti IoU, GIoU, dan CIoU yang digunakan dalam proses

pelatihan model. Bab ini juga mengulas penelitian terdahulu sebagai pembandingan dalam pengembangan metode yang diusulkan.

BAB III METODOLOGI PENELITIAN

Bab ketiga menguraikan tahapan penelitian yang dilaksanakan secara terstruktur dalam proses pengembangan penelitian, mulai dari pengumpulan dataset gambar pengendara, proses *pre-processing* data, hingga pembagian dataset. Selanjutnya, dijelaskan proses pelatihan model menggunakan arsitektur YOLOv11 dengan berbagai skenario eksperimen, seperti perbandingan ukuran model (n, s, m, l), perbandingan versi model, penerapan *attention mechanism*, penambahan DetectBlock, serta variasi *loss function*. Selain itu, dijelaskan juga metode evaluasi yang digunakan, meliputi metrik *precision*, *recall*, mAP, dan *F1-score*.

BAB IV ANALISIS DAN HASIL PENELITIAN

Bab keempat menyajikan hasil eksperimen dan analisis performa model yang telah dilakukan. Pembahasan meliputi perbandingan performa antar model, pengaruh penggunaan *attention mechanism*, kontribusi DetectBlock, serta analisis penggunaan berbagai *loss function* terhadap hasil deteksi. Selain itu, terdapat hasil model terbaik yang menunjukkan peningkatan performa dalam mendeteksi objek, khususnya pada kondisi lingkungan yang kompleks.

BAB V SIMPULAN DAN SARAN

Bab kelima memuat kesimpulan yang diperoleh dari hasil penelitian berdasarkan rumusan masalah yang telah ditetapkan. Selain itu, pada bab ini juga disampaikan beberapa saran untuk pengembangan penelitian berikutnya, khususnya dalam upaya meningkatkan performa model deteksi objek agar dapat bekerja lebih optimal pada berbagai kondisi nyata.