

Implementasi YOLOv10 untuk Deteksi Pelanggaran Sabuk Pengaman Pengemudi Mobil

Satria Anggara Wirayudha¹, Nurhadi², Yulia Arvita³

^{1,2,3} Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Dinamika Bangsa,
Jl. Jendral Sudirman Thehok, Jambi 36138, Indonesia

Email: anggara11122004@gmail.com, nurhadi.rahmad06@gmail.com, yulia_arvita@yahoo.co.id

Email Penulis Korespondensi: yulia_arvita@yahoo.co.id

Artikel Info :

Artikel History :

Submitted : 01-04-2026

Accepted : 19-04-2026

Published : 30-04-2026

Kata Kunci:

YOLOv10;

Deteksi Objek;

Sabuk Pengaman;

Pelanggaran;

Computer Vision;

Deep Learning

Abstrak- Pelanggaran penggunaan sabuk pengaman pada pengemudi mobil masih sering terjadi dan meningkatkan risiko fatalitas kecelakaan. Pengawasan manual memiliki keterbatasan jangkauan, konsistensi, dan efisiensi, sehingga diperlukan sistem otomatis berbasis *computer vision*. Penelitian ini bertujuan mengimplementasikan model YOLOv10 untuk mendeteksi pelanggaran penggunaan sabuk pengaman pada pengemudi mobil. Dataset yang digunakan adalah *Seatbelt Detection* dari Roboflow sebanyak 5.291 citra yang dibagi menjadi data latih, validasi, dan uji. Model YOLOv10n dilatih menggunakan Python pada Google Colaboratory selama 50 *epoch* dengan resolusi 640 x 640 piksel dan *batch size* 32. Evaluasi dilakukan menggunakan *precision*, *recall*, *F1-score*, *mAP@0.5*, dan *mAP@0.5:0.95*, serta dianalisis melalui *confusion matrix* dan visual hasil prediksi. Hasil penelitian menunjukkan bahwa model mencapai *precision* 0,916, *recall* 0,902, *mAP@0.5* 94,5%, dan *mAP@0.5:0.95* 64,9%. Kelas *person-seatbelt* memperoleh *mAP@0.5* 98,1%, sedangkan *person-noseatbelt* mencapai 95,6%. Temuan ini menunjukkan bahwa YOLOv10n layak digunakan sebagai dasar pengembangan sistem pengawasan kepatuhan sabuk pengaman yang efisien dan berpotensi diterapkan pada pemantauan lalu lintas otomatis.

Keywords:

YOLOv1;

Object Detection;

Seat Belt; Traffic;

Computer Vision;

Deep Learning

Abstract- Seat belt violations by car drivers remain frequent and increase the risk of traffic fatalities. Manual monitoring has limited coverage, consistency, and efficiency; therefore, an automatic computer vision-based system is needed. This study aims to implement the YOLOv10 model to detect seat belt violations in car drivers. The research used the Roboflow Seatbelt Detection dataset containing 5,291 images divided into training, validation, and test sets. The YOLOv10n model was trained in Python on Google Colaboratory for 50 epochs using 640 x 640 image resolution and a batch size of 32. Model performance was evaluated using precision, recall, F1-score, mAP@0.5, and mAP@0.5:0.95, and further analyzed through the confusion matrix and prediction visualization. The results show that the model achieved 0.916 precision, 0.902 recall, 94.5% mAP@0.5, and 64.9% mAP@0.5:0.95. The person-seatbelt class reached 98.1% mAP@0.5, while person-noseatbelt reached 95.6%. These findings indicate that YOLOv10n is feasible as a basis for developing an efficient seat belt compliance monitoring system and has strong potential for automatic traffic surveillance applications.

1. PENDAHULUAN

Perkembangan teknologi transportasi dan kecerdasan buatan mendorong lahirnya sistem pengawasan lalu lintas yang semakin cerdas. Jalan raya merupakan infrastruktur vital yang menopang mobilitas masyarakat, distribusi logistik, dan aktivitas ekonomi. Namun, peningkatan jumlah kendaraan juga berdampak pada bertambahnya potensi pelanggaran dan kecelakaan. Analisis daerah rawan kecelakaan menunjukkan bahwa permasalahan keselamatan lalu lintas tidak hanya dipengaruhi oleh kondisi geometrik jalan, tetapi juga perilaku pengguna kendaraan [1]. Data Badan Pusat Statistik menunjukkan bahwa jumlah mobil penumpang di Indonesia meningkat signifikan pada 2022, yang menandakan mobilitas masyarakat semakin tinggi [2]. Dalam lima bulan pertama 2023, data ETLE Korlantas Polri juga mencatat ratusan ribu pelanggaran lalu lintas, termasuk pelanggaran sabuk pengaman [3]. Di tingkat internasional, National Highway Traffic Safety Administration menegaskan bahwa penggunaan sabuk pengaman berkontribusi langsung terhadap penurunan tingkat fatalitas saat kecelakaan [4]. Fakta tersebut menempatkan kepatuhan penggunaan sabuk pengaman sebagai isu keselamatan yang tidak dapat diabaikan.

Masalah utama di lapangan adalah keterbatasan pengawasan manual. Aparat penegak hukum tidak selalu mampu memantau seluruh kendaraan secara konsisten, terutama pada titik dengan volume lalu lintas tinggi. Selain itu, proses observasi visual oleh manusia rentan terhadap kelelahan, subjektivitas, dan keterbatasan sudut pandang. Kondisi ini membuka kebutuhan terhadap sistem otomatis yang dapat mengenali pelanggaran secara cepat dan akurat. Bidang *computer vision* memungkinkan komputer memahami citra dan video untuk memperoleh informasi visual yang relevan [5]. Bersama dengan itu, *deep learning* menghadirkan pendekatan pembelajaran berlapis yang efektif untuk ekstraksi fitur kompleks dan pengenalan pola visual [6]. Kombinasi kedua teknologi tersebut

telah melahirkan banyak sistem deteksi objek yang mampu bekerja secara otomatis pada konteks lalu lintas, pengawasan industri, hingga analisis keamanan [7].

Salah satu pendekatan yang paling banyak digunakan untuk deteksi objek adalah keluarga model *You Only Look Once* atau YOLO. Arsitektur ini dikenal karena kemampuan melakukan prediksi lokasi dan kelas objek dalam satu tahap sehingga lebih efisien untuk kebutuhan *real-time* [8], [9]. Dalam perkembangannya, YOLOv10 hadir sebagai generasi yang menekankan efisiensi inferensi dan pemrosesan fitur multi-skala tanpa mengorbankan akurasi secara signifikan [10]. Peningkatan tersebut menjadi relevan untuk kasus pelanggaran sabuk pengaman, karena objek yang diamati berada di area kabin kendaraan, sering berukuran kecil, dan dapat mengalami oklusi oleh pilar kendaraan, kaca depan, atau pencahayaan yang berubah-ubah. Di sisi lain, karakteristik visual sabuk pengaman juga cukup menantang karena bentuknya tipis dan warnanya dapat menyatu dengan pakaian pengemudi. Oleh sebab itu, pemilihan model yang ringan tetapi tetap tangguh menjadi penting agar sistem nantinya dapat diarahkan ke implementasi *real-time*.

Penelitian terkait menunjukkan bahwa pendekatan berbasis YOLO dan jaringan konvolusional telah efektif untuk berbagai tugas pengawasan kepatuhan berkendara. Halimi *et al.* menerapkan YOLOv5 untuk deteksi penggunaan sabuk pengaman secara *real-time* dan melaporkan tingkat akurasi 92-93% [12]. Ikbal dan Saputra menggunakan YOLOv8 untuk pengenalan rambu lalu lintas dan memperoleh nilai *precision*, *recall*, mAP50, dan mAP50-95 yang sangat tinggi [13], sehingga memperkuat posisi keluarga YOLO dalam pengawasan lalu lintas. Dewi dan Nasrulloh membandingkan *backbone* ResNet-101 dan ResNet-152 untuk deteksi sabuk pengaman dan menunjukkan bahwa arsitektur yang lebih kuat dapat menghasilkan akurasi hingga 98% [14]. Pada pelanggaran lain, Meidyan dan Yustanti membuktikan bahwa YOLOv5m mampu mendeteksi pelanggaran helm dengan *precision* 1,0 dan *recall* 0,93 [15]. Khoiriyah dan Armawan juga melaporkan bahwa model YOLO dapat digunakan untuk mendeteksi pengendara motor tanpa helm dengan mAP 89,04% [16].

Meskipun berbagai penelitian tersebut menunjukkan hasil yang menjanjikan, terdapat celah penelitian yang masih terbuka. Pertama, kajian deteksi sabuk pengaman yang tersedia pada referensi skripsi ini belum banyak mengevaluasi arsitektur YOLOv10 sebagai model yang lebih mutakhir. Kedua, sebagian penelitian terdahulu berfokus pada tugas yang berbeda, seperti rambu lalu lintas atau pelanggaran helm, sehingga karakteristik objek dan kompleksitas visualnya tidak sepenuhnya sama dengan sabuk pengaman pada pengemudi mobil. Ketiga, masih diperlukan pembuktian apakah model YOLOv10 versi ringan dapat tetap menghasilkan kemampuan diferensiasi yang baik antara kelas pengemudi patuh dan tidak patuh ketika dilatih pada dataset publik dengan anotasi multikelas. Dengan demikian, penelitian ini tidak sekadar mengulangi studi sebelumnya, tetapi menguji relevansi arsitektur yang lebih baru pada persoalan keselamatan berkendara yang spesifik.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan mengimplementasikan model YOLOv10n untuk mendeteksi pelanggaran penggunaan sabuk pengaman pada pengemudi mobil, mengevaluasi akurasi model terhadap kelas *person-seatbelt* dan *person-noseatbelt*, serta menganalisis kekuatan dan keterbatasan model secara kuantitatif maupun kualitatif. Artikel ini merangkum hasil inti dari skripsi dengan menekankan kontribusi praktis, yaitu menunjukkan bahwa model YOLOv10n dapat menjadi dasar sistem pemantauan kepatuhan sabuk pengaman yang efisien, terukur, dan potensial untuk dikembangkan ke arah pengawasan lalu lintas otomatis.


2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan pendekatan eksperimen dengan memanfaatkan dataset publik dan model deteksi objek berbasis *deep learning*. Alur penelitian dirancang agar setiap tahap, mulai dari identifikasi masalah hingga interpretasi hasil, berlangsung sistematis dan dapat direplikasi. Gambar 1 menunjukkan tahapan penelitian yang digunakan. Tahap pertama adalah identifikasi masalah, yaitu merumuskan persoalan rendahnya kepatuhan penggunaan sabuk pengaman dan keterbatasan pengawasan manual. Tahap kedua adalah studi literatur untuk memperoleh dasar konseptual mengenai *computer vision*, YOLO, serta penelitian sejenis pada domain keselamatan lalu lintas. Tahap ketiga berupa pengumpulan dataset publik yang relevan dengan kasus pengemudi mobil. Tahap keempat adalah pelabelan dan validasi data agar anotasi yang dipakai sesuai untuk proses pelatihan model deteksi objek. Tahap kelima merupakan pelatihan model YOLOv10n menggunakan konfigurasi eksperimen yang telah ditetapkan. Tahap keenam adalah evaluasi dan analisis hasil menggunakan metrik kuantitatif serta pemeriksaan visual hasil deteksi. Tahap terakhir ialah penyusunan artikel jurnal berdasarkan hasil inti penelitian.

Tahapan tersebut dipilih untuk memastikan bahwa model tidak hanya dilatih, tetapi juga dievaluasi secara menyeluruh terhadap kemampuan generalisasi dan konsistensi prediksi. Pendekatan ini penting karena target sistem bukan sekadar menghasilkan nilai metrik tinggi pada data pelatihan, melainkan juga mampu mempertahankan kinerja ketika dihadapkan pada citra baru yang memiliki variasi posisi pengemudi, pencahayaan, sudut kamera, dan kualitas visual. Dengan demikian, kerangka penelitian menempatkan validitas data, stabilitas pelatihan, serta interpretasi kesalahan prediksi sebagai bagian penting dari proses penelitian.

Tahapan Penelitian Deteksi Pelanggaran Sabuk Pengaman



Gambar 1. Tahapan penelitian dan pengujian model YOLOv10

2.2 Dataset, Pelatihan, dan Evaluasi

Sumber data penelitian berasal dari dataset *Seatbelt Detection* pada platform Roboflow [17]. Dataset ini berisi 5.291 citra kendaraan dengan anotasi yang sudah kompatibel dengan format YOLO. Data dibagi menjadi 3.769 citra latih, 1.070 citra validasi, dan 452 citra uji. Empat kelas anotasi tersedia dalam dataset, yaitu *person-noseatbelt*, *person-seatbelt*, *seatbelt*, dan *windshield*. Dua kelas pertama berperan sebagai fokus utama penelitian karena merepresentasikan kondisi pelanggaran dan kepatuhan. Dua kelas lainnya dimanfaatkan sebagai kelas kontekstual untuk membantu model mengenali lokasi pengemudi dan keberadaan objek sabuk pengaman di dalam kabin kendaraan.

Pelatihan model dilakukan menggunakan bahasa pemrograman Python pada Google Colaboratory dengan dukungan GPU. Model yang dipilih adalah YOLOv10n karena varian ini relatif ringan dan sesuai untuk skenario yang mengarah ke implementasi cepat. Pelatihan menggunakan pendekatan *transfer learning* dari bobot awal *pretrained*, dengan konfigurasi 50 *epoch*, *batch size* 32, dan ukuran citra 640 x 640 piksel. Selama pelatihan, sistem memantau *box loss*, *classification loss*, *distribution focal loss*, serta metrik *precision*, *recall*, *mAP@0.5*, dan *mAP@0.5:0.95*. Setelah pelatihan selesai, model terbaik dievaluasi pada data validasi dan diuji pada citra uji untuk memperoleh gambaran performa akhir. Selain analisis numerik, penelitian ini juga memeriksa hasil prediksi secara visual untuk mengidentifikasi kasus benar, salah deteksi, dan objek yang terlewat. Kombinasi evaluasi kuantitatif dan kualitatif ini dipilih agar efektivitas model dapat dinilai secara lebih utuh, tidak hanya dari satu indikator metrik saja. Pada tahap validasi, model terbaik dipilih berdasarkan performa evaluasi tertinggi pada data validasi, sehingga bobot yang digunakan untuk pengujian bukan sekadar bobot akhir pelatihan. Strategi ini penting untuk menjaga objektivitas eksperimen dan meminimalkan risiko penggunaan model yang kebetulan hanya baik pada data latih. Selain itu, analisis hasil dilakukan secara berulang dengan membandingkan keluaran visual dan angka metrik agar keputusan evaluasi lebih konsisten.

Tabel 1. Ringkasan dataset dan konfigurasi eksperimen

Komponen	Nilai	Keterangan
Jumlah data keseluruhan	5.291 citra	Dataset Seatbelt Detection dari Roboflow.
Pembagian data	3.769 latih; 1.070 validasi; 452 uji	Digunakan untuk pelatihan, validasi, dan evaluasi akhir.
Fokus kelas	<i>person-seatbelt</i> ; <i>person-noseatbelt</i>	Merepresentasikan kepatuhan dan pelanggaran.
Kelas pendukung	<i>seatbelt</i> ; <i>windshield</i>	Memberi konteks visual pada area kabin kendaraan.
Konfigurasi pelatihan	50 epoch; batch 32; 640 x 640	Model YOLOv10n dengan transfer learning di Google Colab.

3. HASIL DAN PEMBAHASAN

3.1 Karakteristik Dataset dan Lingkungan Pelatihan

Eksperimen dimulai dengan menelaah komposisi dataset dan konteks kelas yang digunakan selama pelatihan. Walaupun fokus penelitian berada pada dua kelas utama, yaitu *person-seatbelt* dan *person-noseatbelt*, keberadaan kelas *seatbelt* dan *windshield* memberi keuntungan tambahan karena model dapat mempelajari konteks visual interior kendaraan. Komposisi label pada skripsi menunjukkan bahwa jumlah instansi *person-seatbelt* sebanyak 2.677 dan *person-noseatbelt* sebanyak 2.346, sehingga distribusinya relatif seimbang. Keseimbangan ini penting karena model tidak terdorong untuk bias hanya pada satu kelas dominan. Pada banyak kasus deteksi, ketimpangan data menyebabkan model terlalu sering memilih kelas mayoritas sehingga pelanggaran yang justru

menjadi fokus penelitian terlewat. Pada penelitian ini, distribusi yang lebih proporsional membantu model mempelajari pembeda visual antara pengemudi yang patuh dan yang melanggar secara lebih efektif.


Selain keseimbangan kelas utama, anotasi *seatbelt* dan *windshield* memberi isyarat konteks yang bermanfaat. Kelas *seatbelt* membantu model mengenali objek tali sabuk itu sendiri, sedangkan kelas *windshield* membantu model memahami area kabin dan sudut pandang pengambilan gambar. Strategi ini konsisten dengan logika deteksi objek modern: ketika model mengetahui konteks adegan, kesalahan akibat latar belakang atau objek luar kendaraan dapat dikurangi. Oleh karena itu, walaupun analisis utama artikel ini tetap tertuju pada kepatuhan sabuk pengaman, pemanfaatan kelas kontekstual berkontribusi pada kestabilan proses pembelajaran model.

3.2 Analisis Proses Pelatihan Model

Gambar 2 memperlihatkan grafik komprehensif hasil pelatihan model YOLOv10n selama 50 *epoch*. Secara umum, kurva *box loss*, *classification loss*, dan *distribution focal loss* pada data latih maupun data validasi menunjukkan tren menurun yang konsisten. Pola ini merupakan indikator penting bahwa model berhasil mempelajari hubungan antara citra dan anotasi tanpa menunjukkan gejala divergensi. Penurunan *classification loss* yang tajam pada fase awal pelatihan menandakan bahwa model relatif cepat mengenali perbedaan dasar antar kelas. Sementara itu, penurunan *box loss* dan *dfl loss* yang bertahap menunjukkan bahwa proses lokalisasi objek menjadi semakin presisi seiring bertambahnya *epoch*.

Hubungan antara kurva latih dan validasi juga menunjukkan proses pelatihan yang sehat. Jarak antar kurva tidak terlalu besar dan tidak terlihat adanya kenaikan tajam pada *validation loss* ketika *training loss* terus menurun. Kondisi ini memperlihatkan bahwa model tidak mengalami *overfitting* yang berat. Dengan kata lain, YOLOv10n tidak sekadar menghafal pola pada data latih, tetapi juga mampu mempertahankan kinerja pada data validasi yang tidak dipakai untuk pembaruan bobot. Pada metrik kinerja, kurva *precision*, *recall*, *mAP@0.5*, dan *mAP@0.5:0.95* meningkat sangat cepat pada 10-15 *epoch* pertama, lalu melandai setelah sekitar *epoch* ke-20. Pola ini mengindikasikan bahwa sebagian besar pengetahuan penting telah diperoleh model pada fase awal hingga menengah pelatihan, sedangkan fase berikutnya berfungsi untuk penyesuaian halus. Keputusan menggunakan 50 *epoch* dapat dikatakan efisien karena model telah mencapai titik konvergensi yang baik tanpa memerlukan pelatihan yang terlalu panjang.

Stabilitas pelatihan tersebut juga mendukung pemilihan varian YOLOv10n. Sebagai model ringan, YOLOv10n dirancang untuk menjaga keseimbangan antara akurasi dan efisiensi komputasi. Hasil kurva pada Gambar 2 menunjukkan bahwa varian ringan ini tetap mampu belajar dengan baik pada kasus sabuk pengaman yang secara visual cukup menantang. Temuan ini penting karena pada implementasi nyata, terutama pada perangkat dengan sumber daya terbatas atau kebutuhan pemrosesan cepat, model yang lebih ringan akan lebih mudah diadopsi.



Gambar 2. Grafik hasil pelatihan model YOLOv10n selama 50 epoch

3.3 Evaluasi Kuantitatif Model

Evaluasi kuantitatif pada model terbaik menunjukkan bahwa YOLOv10n memperoleh *precision* 0,916 dan *recall* 0,902. Nilai ini memperlihatkan bahwa sebagian besar prediksi model relevan dan mayoritas objek yang seharusnya terdeteksi berhasil ditemukan. Dari sisi kualitas deteksi keseluruhan, model mencapai *mAP@0.5* sebesar 0,945 dan *mAP@0.5:0.95* sebesar 0,649. Nilai *mAP@0.5* yang tinggi menunjukkan bahwa model sangat baik dalam menemukan objek dan mengklasifikasikannya dengan benar ketika ambang *Intersection over Union* ditetapkan pada 0,5. Adapun *mAP@0.5:0.95*, yang menuntut ketelitian lebih tinggi pada berbagai ambang IoU, tetap menunjukkan performa yang solid untuk model ringan.

Ketika dilihat per kelas sebagaimana pada Tabel 3, dua kelas terpenting memperoleh hasil yang sangat baik. Kelas *person-seatbelt* mencapai *precision* 0,950, *recall* 0,944, dan *mAP@0.5* 0,981. Sementara itu, kelas *person-noseatbelt* memperoleh *precision* 0,915, *recall* 0,908, dan *mAP@0.5* 0,956. Perbedaan kecil antara kedua kelas ini menunjukkan bahwa model mampu melakukan diferensiasi yang seimbang antara kondisi kepatuhan dan pelanggaran. Dari sudut pandang aplikasi, hasil ini sangat penting karena sistem tidak cukup hanya mampu mengenali pengemudi, tetapi harus dapat memutuskan secara akurat apakah sabuk pengaman dipakai atau tidak. Kesalahan kecil pada tahap ini akan berdampak langsung terhadap risiko *false positive* dan *false negative* dalam sistem pengawasan otomatis.

Kelas dengan performa terendah adalah *seatbelt*, khususnya pada *mAP@0.5:0.95* sebesar 0,399. Hasil ini dapat dipahami karena objek sabuk pengaman secara visual lebih sempit, tipis, dan sering terhalang oleh pakaian maupun sudut pengambilan gambar. Namun, performa yang lebih rendah pada kelas tersebut tidak serta-merta mengurangi kegunaan sistem, sebab kelas *seatbelt* pada penelitian ini berfungsi sebagai kelas pendukung yang memperkaya konteks pembelajaran model. Sebaliknya, kelas *windshield* memperoleh hasil sangat tinggi dengan *mAP@0.5* 0,994. Hal ini logis karena bentuk dan lokasinya relatif konsisten di banyak citra. Dengan demikian, distribusi metrik per kelas memperlihatkan bahwa model sangat andal pada target utama penelitian dan masih memanfaatkan kelas-kelas tambahan secara efektif sebagai konteks.

Tabel 2. Metrik kinerja utama model pada data validasi

Metrik	Nilai
Precision	0,916
Recall	0,902
mAP@0.5	0,945
mAP@0.5:0.95	0,649


Tabel 3. Rincian metrik kinerja per kelas pada data validasi

Kelas	Precision	Recall	mAP@0.5	mAP@0.5:0.95
person-noseatbelt	0,915	0,908	0,956	0,660
person-seatbelt	0,950	0,944	0,981	0,684
seatbelt	0,817	0,768	0,849	0,399
windshield	0,981	0,989	0,994	0,853

3.4 Analisis Confusion Matrix dan Prediksi Visual

Analisis lebih lanjut melalui *confusion matrix* pada Gambar 3 memperkuat temuan kuantitatif sebelumnya. Pada matriks ternormalisasi terlihat bahwa kelas *person-noseatbelt* diprediksi dengan benar pada sekitar 92% kasus, sedangkan kelas *person-seatbelt* diprediksi dengan benar pada sekitar 95% kasus. Tingkat kebingungan silang antara dua kelas utama sangat rendah, yakni sekitar 2-3%. Dalam konteks sistem pengawasan pelanggaran, angka ini sangat penting karena menandakan bahwa model relatif jarang menuduh pengemudi patuh sebagai pelanggar maupun melewati pelanggaran yang benar-benar terjadi. Artinya, reliabilitas model bukan hanya tercermin dari *mAP* yang tinggi, tetapi juga dari kemampuan mempertahankan keputusan klasifikasi yang konsisten pada dua kondisi yang sangat mirip secara visual.

Temuan tersebut sekaligus menjawab salah satu pertanyaan utama penelitian, yaitu apakah YOLOv10n cukup sensitif untuk membedakan pengemudi yang menggunakan sabuk pengaman dan yang tidak menggunakannya. Pada banyak kasus, perbedaan antara kedua kondisi ini hanya terlihat dari keberadaan tali sabuk yang melintang di tubuh pengemudi. Jika warna pakaian mirip dengan warna sabuk atau jika posisi tubuh menyulitkan, model yang kurang baik akan mudah tertukar. Namun, hasil *confusion matrix* memperlihatkan bahwa YOLOv10n masih mampu menjaga keputusan klasifikasi dengan baik. Kondisi ini menunjukkan bahwa model tidak hanya memanfaatkan satu fitur sempit, tetapi membangun representasi visual yang lebih kaya dari bentuk tubuh, posisi pengemudi, dan konteks interior kendaraan.



Gambar 3. Confusion matrix ternormalisasi

Analisis kualitatif dilakukan untuk memahami bagaimana model berperilaku pada citra individual, termasuk ketika menghadapi kondisi yang ambigu. Gambar 4 menampilkan contoh hasil prediksi model pada data validasi. Secara umum, model berhasil mendeteksi sebagian besar objek yang jelas dengan skor kepercayaan tinggi. Pada citra dengan sudut kamera yang cukup baik dan pencahayaan memadai, label *person-seatbelt* maupun *person-noseatbelt* muncul dengan penempatan *bounding box* yang rapi. Hal ini menegaskan bahwa capaian metrik kuantitatif model memang tercermin pada kualitas prediksi visual. Selain itu, model juga masih mampu bekerja pada beberapa variasi perspektif, termasuk sudut pandang dari depan kendaraan dan sudut yang lebih tinggi seperti pengamatan kamera lalu lintas.

Walaupun demikian, beberapa kelemahan tetap terlihat. Pada citra yang sangat buram, *close-up* ekstrem, atau ketika tekstur pakaian menyerupai sabuk pengaman, model dapat menghasilkan prediksi berkepercayaan rendah atau salah klasifikasi. Kasus semacam ini telah tampak pada skripsi, misalnya ketika pengemudi yang sebenarnya mengenakan sabuk diprediksi sebagai pelanggar dengan nilai kepercayaan rendah, atau sebaliknya ketika lipatan pakaian diinterpretasikan sebagai sabuk pengaman. Pola tersebut penting untuk dicatat karena menunjukkan bahwa kualitas kamera, kebersihan kaca kendaraan, dan kondisi pencahayaan berpotensi memengaruhi akurasi sistem saat diterapkan di lapangan. Dengan kata lain, keberhasilan implementasi nyata bukan hanya bergantung pada model, tetapi juga pada mutu citra yang masuk ke sistem.



Gambar 4. Contoh hasil prediksi model pada data validasi

3.5 Pembahasan

Jika dibandingkan dengan penelitian terkait, hasil YOLOv10n pada penelitian ini tergolong sangat kompetitif. Nilai mAP@0.5 sebesar 94,5% sedikit lebih tinggi daripada kisaran akurasi 92-93% yang dilaporkan Halimi *et al.* untuk YOLOv5 pada deteksi sabuk pengaman [12]. Walaupun perbandingan ini tidak sepenuhnya setara karena perbedaan komposisi data dan konfigurasi eksperimen, hasil tersebut menunjukkan bahwa generasi model yang lebih baru dapat memberikan peningkatan performa pada tugas serupa. Dibandingkan dengan studi Dewi dan Nasrulloh [14], pendekatan mereka menghasilkan akurasi sangat tinggi untuk deteksi sabuk pengaman berbasis RetinaNet dengan *backbone* ResNet. Namun, pendekatan tersebut tidak secara langsung menonjolkan aspek efisiensi inferensi seperti keluarga YOLO. Pada artikel ini, varian YOLOv10n menawarkan nilai praktis tambahan karena lebih ringan dan lebih dekat dengan kebutuhan sistem pengawasan yang kelak diharapkan bekerja secara cepat atau *real-time*.

Hasil penelitian juga selaras dengan temuan pada domain pelanggaran lalu lintas lain. Studi Meidyan dan Yustanti [15] serta Khoiriyah dan Armawan [16] menunjukkan bahwa model deteksi objek modern efektif untuk membedakan kondisi patuh dan melanggar pada kasus helm. Kemiripan ini menegaskan bahwa pelanggaran keselamatan berkendara memang dapat ditangani menggunakan paradigma deteksi objek. Meski demikian, sabuk pengaman tetap memiliki tingkat kesulitan tersendiri karena objek yang dikenali jauh lebih kecil daripada helm dan kerap tertutup sebagian. Oleh karena itu, keberhasilan YOLOv10n dalam penelitian ini menunjukkan bahwa arsitektur tersebut cukup adaptif terhadap objek yang sempit dan kontrasnya rendah.

Secara substantif, penelitian ini membuktikan bahwa YOLOv10n dapat diterapkan secara efektif pada tugas deteksi kepatuhan sabuk pengaman menggunakan dataset publik dengan anotasi multikelas yang memperlihatkan bahwa kelas kontekstual seperti *seatbelt* dan *windshield* dapat memperkuat pembelajaran model walaupun target akhir tetap berada pada status pengemudi. dan juga penelitian ini menampilkan evaluasi yang tidak hanya berfokus pada satu metrik, tetapi juga mencakup analisis kurva pelatihan, metrik per kelas, *confusion matrix*, dan hasil prediksi visual. Pendekatan evaluasi yang menyeluruh ini memberikan dasar yang lebih kuat untuk menilai kesiapan model menuju implementasi lebih lanjut.

Meskipun demikian, penelitian ini masih memiliki keterbatasan. Eksperimen belum dilakukan pada sistem *real-time* berbasis video atau terintegrasi dengan perangkat CCTV lapangan. Dataset yang digunakan juga masih berasal dari sumber publik, sehingga kemungkinan belum mewakili seluruh variasi interior kendaraan, kondisi malam hari, hujan, atau sudut pengambilan gambar yang sangat ekstrem. Keterbatasan lain terlihat pada performa kelas *seatbelt* yang lebih rendah dibanding kelas utama. Untuk penelitian lanjutan, perlu dipertimbangkan penambahan variasi data, pemrosesan video berurutan, integrasi *object tracking*, dan penggabungan dengan pembacaan pelat nomor kendaraan agar sistem dapat diarahkan ke implementasi penegakan hukum yang lebih komprehensif. Dari sisi implementasi praktis, hasil ini menunjukkan bahwa sistem berbasis YOLOv10n paling sesuai digunakan sebagai alat bantu pengawasan, bukan pengganti penuh keputusan petugas. Model dapat diposisikan untuk menyaring dugaan pelanggaran terlebih dahulu, kemudian hasilnya diverifikasi pada tahap berikutnya. Pendekatan seperti ini akan menekan beban observasi manual dan tetap menjaga akurasi keputusan. Dengan demikian, kontribusi penelitian tidak berhenti pada capaian metrik, tetapi juga pada usulan mekanisme pemanfaatan model yang realistis dan relevan untuk lingkungan pengawasan lalu lintas di Indonesia. Hal ini memperkuat kelayakan model untuk tahap pengembangan berikutnya.

4. KESIMPULAN

Berdasarkan hasil implementasi dan evaluasi yang telah dilakukan, dapat disimpulkan bahwa model YOLOv10n berhasil digunakan untuk mendeteksi pelanggaran penggunaan sabuk pengaman pada pengemudi mobil dengan performa yang tinggi. Model mampu membedakan secara efektif antara pengemudi yang menggunakan sabuk pengaman dan yang tidak menggunakannya, yang ditunjukkan oleh nilai *precision* 0,916, *recall* 0,902, mAP@0.5 94,5%, dan mAP@0.5:0.95 64,9%. Pada tingkat kelas, *person-seatbelt* mencapai mAP@0.5 98,1% dan *person-noseatbelt* mencapai 95,6%, sementara *confusion matrix* menunjukkan kebingungan silang yang rendah antara dua kelas utama. Temuan ini menandakan bahwa YOLOv10n cukup andal untuk menjadi inti sistem pengawasan otomatis terhadap kepatuhan sabuk pengaman. Analisis visual juga memperlihatkan bahwa model bekerja baik pada sebagian besar citra yang jelas, meskipun performanya dapat menurun pada kondisi kabur, oklusi tinggi, atau pencahayaan yang kurang mendukung. Secara keseluruhan, hasil penelitian ini menegaskan bahwa YOLOv10n memiliki potensi praktis untuk dikembangkan lebih lanjut pada skenario pemantauan lalu lintas otomatis berbasis kamera. Implikasi utamanya adalah bahwa teknologi ini dapat membantu meningkatkan konsistensi pengawasan keselamatan berkendara dan membuka peluang integrasi dengan sistem transportasi cerdas pada penelitian berikutnya.

REFERENCES

- [1] E. E. S. Putra, S. Y. Ratih, and L. Primantari, "Analisis Daerah Rawan Kecelakaan Lalu Lintas Jalan Raya Ngerong Cemorosewu," *J. Kacapuri J. Keilmuan Tek. Sipil*, vol. 4, no. 2, p. 255, 2022, doi: 10.31602/jk.v4i2.6432.
- [2] Kepolisian Republik Indonesia, "Perkembangan Jumlah Kendaraan Bermotor Menurut Jenis (Unit), 2022," *Badan Pusat Statistik*. [Online]. Available: <https://www.bps.go.id/id/statistics-table/2/NTcjMg==/perkembangan-jumlah-kendaraan-bermotor-menurut-jenis--unit-.html>
- [3] Pusiknas Bareskrim Polri, "Bukan hanya Satu, Pelanggar Lalu Lintas Dijerat Banyak Pasal," *Pusiknas Bareskrim Polri*. [Online]. Available: https://pusiknas.polri.go.id/detail_artikel/bukan_hanya_satu_pelanggar_lalu_lintas_dijerat_banyak_pasal
- [4] National Highway Traffic Safety Administration, "Seat Belts," *National Highway Traffic Safety Administration*. [Online]. Available: <https://www.nhtsa.gov/vehicle-safety/seat-belts>
- [5] F. Marpaung, F. Aulia, and R. C. Nabila, *Computer Vision dan Pengolahan Citra Digital*. 2022.
- [6] A. Raup, W. Ridwan, Y. Khoeriyah, S. Supiana, and Q. Y. Zaqiah, "Deep Learning dan Penerapannya dalam Pembelajaran," *JiIP - J. Ilm. Ilmu Pendidik.*, vol. 5, no. 9, pp. 3258-3267, 2022, doi: 10.54371/jiip.v5i9.805.
- [7] Q. Aini, N. Lutfiani, H. Kusumah, and M. S. Zahran, "Deteksi dan Pengenalan Objek Dengan Model Machine Learning: Model Yolo," *CESS (Journal Comput. Eng. Syst. Sci.)*, vol. 6, no. 2, p. 192, 2021, doi: 10.24114/cess.v6i2.25840.
- [8] F. Indaryanto, A. Nugroho, and A. F. Suni, "Edu Komputika Journal," *Edu Komputika*, vol. 8, no. 1, pp. 112-120, 2021.
- [9] C. Evita, R. Alfita, H. Haryanto, R. V. Nahari, M. Ulum, and M. Pramudia, "Rancang Bangun Timbangan Buah Digital Menggunakan Metode YOLO," *J. FORTECH*, vol. 3, no. 1, pp. 34-42, 2022, doi: 10.56795/fortech.v3i1.105.
- [10] Y. Li and W. Y. Leong, "YOLOv10 Algorithm for Real-Time Pedestrian Detection in Autonomous Vehicles," *ASM Sci. J.*, vol. 20, no. 1, 2025, doi: 10.32802/asmscj.2025.1977.
- [11] S. Yuliany, Aradea, and A. N. Rachman, "Implementasi Deep Learning pada Sistem Klasifikasi Hama Tanaman Padi Menggunakan Metode Convolutional Neural Network (CNN)," *J. Buana Inform.*, vol. 13, no. 1, pp. 54-65, 2022, doi: 10.24002/jbi.v13i1.5022.
- [12] K. Maulina Halimi *et al.*, "Pendeteksi Penggunaan Sabuk Pengaman Real Time Untuk Pengemudi Menggunakan Metode YOLOV5," *J. Artif. Intel. dan Sist. Penunjang Keputusan*, vol. 2, no. 2, pp. 161-165, 2024.
- [13] M. Ikbil and R. A. Saputra, "Pengenalan Rambu Lalu Lintas Menggunakan Metode YOLOv8," *JIKA (Jurnal Inform.)*, vol. 8, no. 2, p. 204, 2024, doi: 10.31000/jika.v8i2.10609.
- [14] I. A. Dewi and N. Z. Z. Nasrulloh, "Residual Network Layer Comparison for Seat Belt Detection," *J. Komput. dan Inform.*, vol. 11, no. 2, pp. 145-156, 2023, doi: 10.35508/jicon.v11i2.9903.
- [15] M. A. Meidyan and W. Yustanti, "Implementasi Metode You Only Look Once (YOLOv5) dalam Deteksi Pelanggaran Helm," vol. 05, no. 03, pp. 214-222, 2024.
- [16] K. Khoiriyah and M. F. A. A. Armawan, "Deteksi Pengendara Motor Tanpa Menggunakan Helm Dengan Algoritma Deep Learning Yolo," *JEIS J. Elektro dan Inform. Swadharma*, vol. 3, no. 2, pp. 72-82, 2023, doi: 10.56486/jeis.vol3no2.360.
- [17] "Seatbelt Detection - v1 2025-10-12 7:04pm," *Roboflow Universe*. [Online]. Available: <https://universe.roboflow.com/adit-6cphq/seatbelt-detection-esut6-vol6k/dataset/1>