

# Deteksi Kecelakaan Pengendara Kendaraan Berdasarkan Kamera CCTV Menggunakan Metode YOLOv9

1<sup>st</sup> Tunggal Panaluan Gabriel Sagala  
S1 Informatika  
Telkom University  
Bandung, Jawa Barat  
gabrielbjb@student.telkomuniversity.ac.id

Dr. Ema Rachmawati, S.T., M.T.  
Software Engineering and Algorithm  
Telkom University  
Bandung, Jawa Barat  
emarachmawati@telkomuniversity.ac.id

**Abstrak** — Kecelakaan lalu lintas merupakan salah satu bencana non-alam yang paling sering terjadi di Indonesia dan sering dilaporkan. Kecelakaan dapat terjadi di berbagai jenis jalan, mulai dari jalan raya, jalan tol, hingga jalan kecil. Berdasarkan tingkat keseriusannya, kecelakaan lalu lintas dapat dikategorikan sebagai ringan, sedang, atau berat. Kecelakaan ringan umumnya menyebabkan luka ringan atau bahkan tanpa luka, sementara kecelakaan dengan tingkat keseriusan sedang hingga berat dapat mengakibatkan cedera serius yang dapat mengancam nyawa pengendara. Dalam kondisi tersebut, penanganan medis yang cepat sangat penting untuk menyelamatkan nyawa korban. Untuk meminimalkan risiko korban jiwa, penting bagi pihak berwajib untuk mengetahui kondisi sekitar lokasi kecelakaan secara akurat, termasuk jumlah korban yang terlibat. Hal ini bertujuan agar bantuan medis dan tim penyelamat dapat dikirim dengan cepat dan tepat sasaran dalam memberi pertolongan. Dalam penelitian ini, penulis mengusulkan solusi berupa sistem deteksi pengendara yang terlibat kecelakaan lalu lintas dengan memanfaatkan data dari CCTV dan menggunakan metode YOLOv9 untuk deteksi objek. Hasil penelitian menunjukkan bahwa sistem yang dibuat dapat mendeteksi pengendara yang terlibat kecelakaan hanya dengan menggunakan data dari CCTV dan menunjukkan bahwa model YOLOv9 dapat meraih nilai AP@50 sebesar 0,72, *precision* 0,75, *recall* 0,61, *average confidence* 0,63 dan IoU 0,73. Dengan hasil yang diperoleh mencerminkan performa yang cukup baik dan diharapkan dapat meningkatkan efektivitas respons cepat dalam situasi darurat.

**Kata kunci**— YOLO, Deteksi Pengendara Kecelakaan, Kecelakaan, Lalu Lintas

## I. PENDAHULUAN

Kecelakaan lalu lintas merupakan peristiwa yang sering terjadi dan menjadi masalah serius dalam kehidupan sehari-hari. Berdasarkan data dari Organisasi Kesehatan Dunia (WHO), kecelakaan lalu lintas menyebabkan sekitar 1,19 juta kematian setiap tahunnya. Angka tersebut mencakup berbagai kelompok usia, mulai dari anak-anak berusia 5 tahun hingga orang dewasa berusia 29 tahun. Lebih memprihatinkan lagi, sekitar 92% dari angka kematian akibat kecelakaan lalu lintas terjadi di negara-negara berpenghasilan rendah dan menengah, meskipun negara-negara tersebut

hanya memiliki sekitar 60% kendaraan yang beredar di dunia [1][2].

Dampak kecelakaan lalu lintas tidak hanya terbatas pada angka kematian, tetapi juga mencakup trauma fisik, cedera serius, serta kecacatan permanen. Kerugian yang diakibatkan oleh kecelakaan lalu lintas, baik dari segi ekonomi maupun sosial, sangat signifikan [3]. Data dari Bareskrim Polri tahun 2023 mencatat jumlah kecelakaan lalu lintas mencapai 953.580 kasus. Sepeda motor merupakan kendaraan yang paling sering terlibat dalam kecelakaan, dengan jumlah kasus mencapai 727.043. Total kecelakaan tersebut, tercatat 60.970 orang meninggal dunia, 470.082 orang mengalami luka ringan, 37.545 orang mengalami luka berat, dan 366.748 orang tidak terluka. Selain itu, sebanyak 18.235 orang mengalami luka dengan status yang tidak dapat dipastikan. Dampak lebih lanjut dari kecelakaan ini juga berupa kerugian material yang signifikan. Pada tahun 2023, kerugian material yang tercatat akibat kecelakaan lalu lintas mencapai Rp 293.150.729.810 [4].

Kecelakaan lalu lintas yang melibatkan pengendara dengan luka serius menimbulkan risiko besar terhadap keselamatan jiwa korban. Salah satu penyebab utama kematian dalam kecelakaan adalah kehabisan darah. Kehabisan darah dapat menjadi faktor utama penyebab kematian pada pengendara yang mengalami kecelakaan [5]. Oleh karena itu, penanganan medis yang cepat dan tepat sangat penting untuk menyelamatkan nyawa pengendara yang terlibat dalam kecelakaan melalui pemberian pertolongan pertama serta meminimalkan risiko kematian atau kecacatan permanen pada korban kecelakaan [6]. Untuk memastikan perawatan dan bantuan yang cepat serta tepat, tim medis perlu mengambil keputusan dalam menangani korban kecelakaan lalu lintas, misalnya menentukan jumlah tim medis dan ambulans yang perlu dikirimkan sesuai dengan jumlah korban [7]. Terdapat berbagai faktor yang menyebabkan keterlambatan dalam penanganan korban kecelakaan. Faktor yang paling sering dialami adalah kurangnya informasi yang diperoleh tim medis dari layanan darurat mengenai jumlah dan tingkat keseriusan korban di tempat kejadian yang menyebabkan kekurangan tenaga medis serta terbatasnya ketersediaan ambulans yang tiba di lokasi kejadian, sehingga menghambat proses penanganan yang lebih cepat dan efektif [8][9]. Berbagai penelitian telah membuat sistem untuk mengatasi masalah tersebut, termasuk

sistem berbasis *Internet of Things* (IoT) [10][11][12][13]. Dua penelitian berhasil membuat sistem deteksi yang mampu mengirimkan informasi, seperti citra dan posisi GPS, ke pusat layanan darurat [11][12]. Sementara itu, terdapat penelitian membuat sistem deteksi kecelakaan dengan menggunakan kemiringan sebagai data utama dan menghasilkan akurasi rotasi sebesar 99,5%, kemiringan 99,21%, dan gerakan belok 99,5% dan akan mengirimkan data seperti lokasi GPS dan citra penumpang saat terjadi kecelakaan [10]. Meskipun sistem tersebut berhasil mendeteksi kecelakaan dan memberikan informasi kepada layanan darurat secara cepat, sistem ini memiliki beberapa keterbatasan yang perlu diperhatikan. Salah satunya adalah kemampuannya yang terbatas dalam mendeteksi hanya kendaraan yang dilengkapi dengan perangkat tersebut dan tidak dapat mengidentifikasi korban yang berada di luar kendaraan yang terlibat dalam kecelakaan yang tentunya merupakan elemen penting dalam penanganan kecelakaan secara menyeluruh.

Selain itu, penelitian lain dengan tujuan serupa juga bertujuan untuk mempercepat pengiriman bantuan melalui sistem yang dapat mendeteksi kecelakaan dan kebakaran menggunakan CCTV. Sistem ini menghasilkan nilai mAP sebesar 99,2% untuk deteksi kecelakaan dan 98,9% untuk deteksi kebakaran. Meskipun penelitian ini tidak secara langsung mendeteksi korban, sistem dirancang untuk mengurangi risiko yang dapat mengancam keselamatan pengendara di sekitarnya [14].

Oleh karena itu, penelitian ini mengusulkan pembangunan sistem deteksi kecelakaan yang lebih luas cakupannya, dengan memanfaatkan teknologi berbasis CCTV dan model deteksi YOLOv9. YOLOv9 menawarkan sejumlah keunggulan dibandingkan dengan versi sebelumnya, di antaranya adalah pengurangan signifikan dalam jumlah parameter dan kebutuhan komputasi. Keunggulan ini dicapai melalui penerapan *Programmable Gradient Information* (PGI) dan *Generalized Efficient Layer Aggregation Network* (GELAN), yang mampu mengurangi jumlah total parameter hingga 49% dan kompleksitas komputasi sebesar 43%.

## II. KAJIAN TEORI

### A. Studi Literatur Deteksi Korban Kecelakaan

Sistem deteksi kecelakaan dalam berkendara bukanlah hal yang baru, karena sejumlah penelitian sebelumnya telah membuat sistem serupa. Berbagai teknologi, seperti citra dari CCTV hingga giroskop, telah digunakan untuk mendeteksi terjadinya kecelakaan kendaraan.

Sebagai contoh, dalam salah satu penelitian, sistem deteksi kecelakaan dibuat dengan menggunakan data dari akselerometer dan giroskop. Sistem tersebut tidak memanfaatkan perangkat IoT secara langsung, namun ketika kecelakaan terdeteksi, perangkat IoT akan mengambil citra penumpang melalui kamera yang terpasang di dalam kendaraan. Selain itu, sistem juga dilengkapi dengan teknologi GPS yang menyediakan data lokasi kendaraan pada saat kecelakaan terjadi, serta dapat mendeteksi tekanan ban kendaraan. Penelitian tersebut mendapatkan hasil akurasi rotasi adalah 99,5%, kemiringan 99,21%, dan gerakan belok 99,5% untuk mendeteksi kecelakaan. Hasil pengujian GPS masing-masing untuk garis bujur dan garis lintang adalah 99,99% [10].

Penelitian lain membuat sistem deteksi kecelakaan menggunakan sensor getaran piezoelektrik untuk mendeteksi getaran yang ditimbulkan oleh kecelakaan, serta *limit switch* untuk mendeteksi indikasi benturan signifikan. Hasil dari penelitian tersebut menunjukkan keberhasilan dalam mendeteksi kecelakaan menggunakan berbagai sensor untuk memantau parameter fisiologis seperti detak jantung, suhu tubuh, dan status koma, serta mengirimkan informasi tersebut ke pusat perawatan darurat melalui modul GSM/GPS [11].

Penelitian lainnya memanfaatkan sensor lentur dan akselerometer untuk mendeteksi kecelakaan. Apabila kecelakaan terdeteksi, sistem secara otomatis mengirimkan pesan kepada rumah sakit terdekat, disertai dengan informasi lokasi GPS korban, serta menyiarkan secara langsung tampilan kamera yang ada di dalam kendaraan untuk memberikan gambaran situasi di dalam kendaraan. Hasil dari penelitian menunjukkan bahwa sistem dapat mengeluarkan data GPS dalam format NMEA, termasuk informasi tentang *latitude* dan *longitude*, serta berhasil mengirimkan pesan teks yang berisi informasi tersebut kepada layanan darurat [12].

Sebuah penelitian lebih lanjut membuat sistem deteksi kecelakaan yang memanfaatkan berbagai sensor, seperti akselerometer tiga sumbu, sensor kemiringan, GPS, dan akselerometer pada ponsel. Setelah kecelakaan terdeteksi, sistem secara otomatis langsung menghubungi layanan darurat dan memberikan informasi penting seperti nomor kendaraan, tipe kendaraan, waktu terjadinya kecelakaan, serta lokasi kendaraan. Selain itu, sistem tersebut menggunakan kamera inframerah untuk mendeteksi penumpang dengan cara memindai wajah penumpang tersebut. Hasil penelitian menunjukkan bahwa sistem deteksi kecelakaan yang dibuat mampu mendeteksi kecelakaan dengan akurasi 100% dalam simulasi yang dilakukan. Penggunaan akselerometer dan giroskop sebagai sensor utama terbukti efektif dalam menentukan skala kecelakaan. Dalam pengujian, sistem berhasil mendeteksi semua kecelakaan dan *rollover* yang disimulasikan, dengan nilai ambang akselerasi yang ditetapkan pada 4,5 g untuk deteksi kecelakaan dan sudut *rollover* 60 derajat [13].

Penelitian lain yang menggunakan CCTV menggabungkan teknologi DeepSORT dan YOLOv5 untuk mendeteksi kecelakaan kendaraan. Selain mendeteksi kecelakaan, sistem tersebut juga dapat mendeteksi potensi kebakaran yang mungkin timbul akibat kecelakaan dan secara otomatis menghubungi pemadam kebakaran jika api terdeteksi di sekitar lokasi kecelakaan. Peneliti juga merancang sistem tersebut untuk menilai tingkat keseriusan kecelakaan lalu lintas. Hasil penelitian menunjukkan bahwa model deteksi kendaraan dan pelacakan menggunakan algoritma YOLOv5 dan DeepSORT mencapai mAP sebesar 99,2%. Model kedua, yang mengklasifikasikan tingkat keseriusan kecelakaan, juga menggunakan YOLOv5 dan mencapai mAP sebesar 83,3%. Untuk deteksi kebakaran pasca-kecelakaan, model yang dibangun dengan arsitektur ResNet152 berhasil mencapai akurasi 98,95% [14]. Meskipun penelitian tersebut tidak secara langsung mendeteksi kondisi korban, sistem tersebut dirancang untuk mengurangi risiko yang dapat membahayakan keselamatan pengendara dan pengguna jalan lainnya di sekitar lokasi kecelakaan.

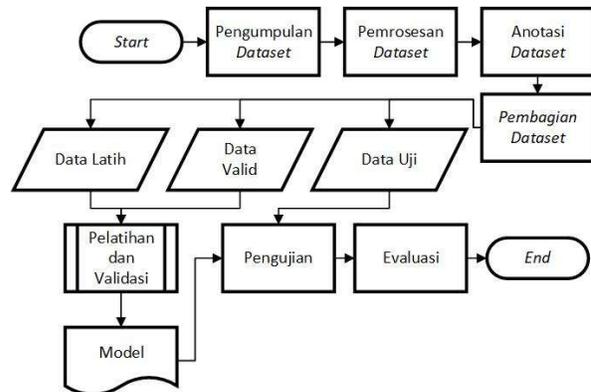
## B. Deteksi Objek

Deteksi objek merupakan salah satu aspek fundamental dalam visi komputer, yang bertujuan untuk mengidentifikasi dan mengklasifikasikan objek-objek yang terdapat dalam citra atau video [15]. Proses tersebut tidak hanya mencakup pengenalan jenis objek, tetapi juga penentuan posisi objek melalui penggunaan *bounding box*. Deteksi objek memainkan peran yang sangat penting dalam berbagai aplikasi, seperti pengenalan wajah [16], deteksi pejalan kaki [17], dan kendaraan otomatis [18]. Dengan kemampuan untuk mengidentifikasi dan melacak berbagai objek dalam konteks visual, teknologi tersebut menjadi elemen kunci untuk meningkatkan interaksi antara sistem komputasi dan dunia nyata. Tantangan utama dalam deteksi objek mencakup berbagai aspek yang berkaitan dengan variasi objek dan konteks lingkungan. Tantangan tersebut mencakup deteksi objek yang mengalami rotasi dan perubahan skala, termasuk objek kecil, serta kesulitan dalam menentukan lokasi objek secara akurat. Selain itu, deteksi objek yang padat dan saling menutupi menjadi kendala signifikan, terutama dalam *dataset* dengan objek yang terdistribusi secara kompleks. Kecepatan juga menjadi perhatian, karena kebutuhan untuk mengoptimalkan proses deteksi agar dapat diterapkan secara *real-time*. Hal tersebut semakin diperparah oleh variasi sudut pandang, pencahayaan, dan variasi intra-kelas, yang menyebabkan peningkatan kompleksitas algoritma yang harus mampu menangani berbagai skenario [19].

## C. Deteksi Kecelakaan Kendaraan

Deteksi kecelakaan berkendara merupakan salah satu aspek penting dalam meningkatkan keselamatan lalu lintas. Dengan meningkatnya jumlah kendaraan di jalan raya, risiko kecelakaan juga semakin tinggi. Pembuatan sistem deteksi kecelakaan memiliki berbagai varian, mulai dari pengembangan sistem deteksi menggunakan *Internet of Things* (IoT) dengan data dari sensor hingga penggunaan CCTV untuk mendeteksi kecelakaan kendaraan. Sistem deteksi kecelakaan terbukti efektif dalam mengurangi angka kematian akibat kecelakaan. Terdapat penelitian yang mengukur efektivitas *Lane Keeping Assist* (LKA), sebuah teknologi yang memberikan peringatan kepada pengemudi saat kendaraannya melenceng dari jalur. Kendaraan yang dilengkapi dengan LKA diperkirakan memiliki kemungkinan 24% (dengan interval kepercayaan 95% antara 2% hingga 42%) lebih kecil untuk terlibat dalam kecelakaan fatal akibat keluar dari jalur, dibandingkan dengan kendaraan yang tidak dilengkapi LKA [24]. Terdapat banyak variasi dan metode untuk mendeteksi kecelakaan berkendara, dan dalam penelitian ini digunakan citra dari CCTV untuk mendeteksi korban kecelakaan kendaraan dengan cara mengidentifikasi pengendara yang terjatuh di jalan raya.

## III. METODE

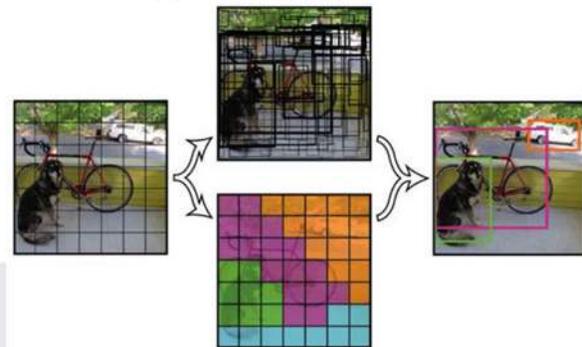


GAMBAR 1

Proses perancangan sistem yang telah dikerjakan.

## A. Metode

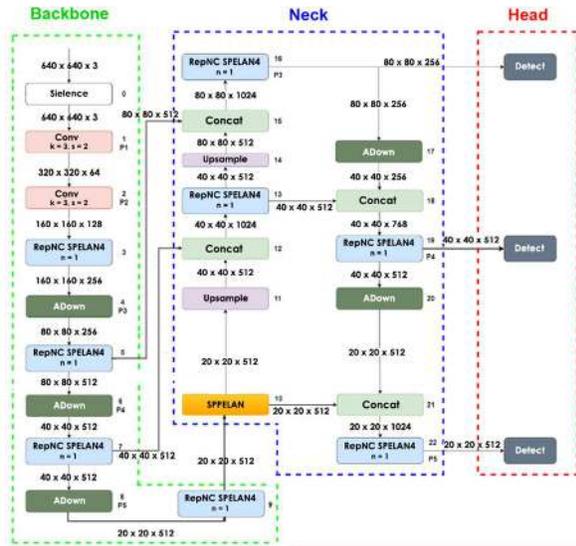
*You Only Look Once* (YOLO) merupakan pendekatan inovatif dalam deteksi objek pada citra, yang dirancang untuk mencapai keseimbangan optimal antara kecepatan dan akurasi dalam aplikasi visi komputer. YOLO memformulasikan deteksi objek sebagai masalah regresi yang memprediksi koordinat *bounding box* dan probabilitas kelas secara bersamaan dan terpisah secara spasial, menggunakan satu jaringan neural untuk melakukan prediksi langsung dari citra utuh dalam satu evaluasi. Karena seluruh *pipeline* deteksi objek dibangun menggunakan satu jaringan neural tunggal, proses ini dapat dioptimalkan secara *end-to-end* untuk meningkatkan kinerja deteksi.



GAMBAR 2

Proses YOLO melakukan pembagian citra menjadi  $S \times S$  grid [20].

Prinsip kerja YOLO melibatkan pembagian citra menjadi *grid* dengan ukuran  $S \times S$ . Setiap sel *grid* memprediksi  $B$  *bounding boxes* beserta skor confidence untuk setiap kotak, yang mencerminkan tingkat confidence model terhadap keberadaan objek dalam kotak tersebut serta akurasi prediksi posisi *bounding box*. Selain itu, setiap sel *grid* juga memprediksi probabilitas bersyarat untuk masing-masing kelas objek. Dengan menggabungkan skor confidence dan probabilitas kelas ini, YOLO dapat menghasilkan prediksi *bounding box* dan kelas objek secara efisien dalam satu langkah pemrosesan [20].



GAMBAR 3  
Ilustrasi arsitektur YOLOv9 [21].

YOLOv9 memiliki sejumlah keunggulan utama yang membedakannya dari *real-time object detection* lainnya. Salah satu inovasi utama dalam YOLOv9 adalah penerapan *Generalized Efficient Layer Aggregation Network* (GELAN), yang merupakan pengembangan dari *Efficient Layer Aggregation Network* (ELAN). GELAN dirancang untuk meningkatkan efisiensi komputasi dengan memanfaatkan blok komputasi konvensional secara lebih optimal, sehingga dapat mengurangi kompleksitas dan mengoptimalkan penggunaan parameter.

Arsitektur YOLOv9 terdiri dari tiga komponen utama, yang masing-masing memiliki peran penting dalam proses deteksi korban kecelakaan. Komponen pertama adalah *backbone*, yang berfungsi untuk mengekstraksi ciri-ciri dari citra. Pada tahap ini, dilakukan identifikasi elemen-elemen penting, seperti pola korban dalam citra yang diterima. YOLOv9 mengadopsi arsitektur GELAN sebagai *backbone*, yang merupakan pengembangan dari CSPNet dan ELAN. Setelah ekstraksi selesai, data diteruskan ke tahap *neck* untuk mengintegrasikan informasi multi-skala yang dihasilkan oleh *backbone*. Teknik seperti *Feature Pyramid Network* (FPN) dan *Path Aggregation Network* (PAN) digunakan untuk memperkaya data dari *backbone* guna meningkatkan akurasi deteksi. Komponen terakhir adalah *head*, yang bertanggung jawab untuk memprediksi *bounding boxes* dan label kelas 'Korban' dalam citra, dengan memanfaatkan hasil yang diperoleh dari *backbone* dan *neck* [22][23].

B. Pengambilan dan Pengumpulan Dataset

Penelitian ini menggunakan berbagai sumber *dataset*, yang mencakup *dataset* dari Roboflow yang berisi citra CCTV dari Thailand, serta *dataset* yang diperoleh langsung dari Dinas Perhubungan Kota Bandung dan Dinas Perhubungan Kota Banjarmasin. Dinas Perhubungan Kota Bandung terdiri dari 82 video, sedangkan Dinas Perhubungan Kota Banjarmasin terdiri dari 6 video. Selain itu, *dataset* dari Roboflow terdiri dari 532 citra CCTV dari Thailand [25]. Setelah memperoleh *dataset* dari kedua dinas, dilakukan pemeriksaan manual terhadap video yang ada. Video yang teridentifikasi sebagai duplikat, buram, atau memiliki

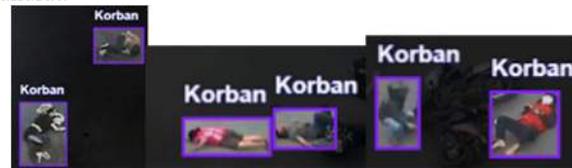
kualitas visual yang tidak memadai dihapus. Sebagai hasil dari proses pemeriksaan ini, *dataset* yang digunakan dalam penelitian ini terdiri dari 20 video dari Dinas Perhubungan Kota Bandung dan 3 video dari Dinas Perhubungan Kota Banjarmasin. Setelah penggabungan, jumlah citra yang diperoleh mencapai 815 citra.

C. Pemrosesan Dataset

Agar model dapat memahami dataset, pemrosesan video yang diperoleh dari Dinas Perhubungan dilakukan dengan mengonversi video tersebut menjadi citra dalam format *Joint Photographic Experts Group* (JPEG). Proses konversi ini dilakukan dengan cara mengambil satu *frame* setiap detik dari video, yang kemudian dijadikan citra. Setelah proses konversi selesai, ukuran citra yang diperoleh dari rekaman CCTV tersebut diubah menjadi 640 x 360 piksel.

D. Anotasi Dataset

Setiap citra yang diperoleh diberi tanda menggunakan *bounding box* yang mengelilingi objek yang relevan dalam citra. Dalam sistem ini, terdapat satu kelas yang digunakan untuk anotasi, yaitu kelas 'korban'. Anotasi ini bertujuan untuk memberikan informasi yang jelas dan terstruktur bagi model, agar dapat mengenali objek yang dimaksud dengan akurat.



GAMBAR 4

Citra yang sudah diberikan label dengan kelas korban.

E. Data Latih, Data Validasi, dan Data Uji

Setelah dataset diproses, citra yang diperoleh dibagi untuk tujuan pemisahan dataset dengan komposisi 80% untuk data pelatihan, 10% untuk data validasi, dan 10% untuk data pengujian. Proses pemisahan ini dilakukan secara acak. Dari total 815 citra, pembagian data menghasilkan rincian sebagai berikut: 652 citra untuk data pelatihan, 82 citra untuk data validasi, dan 81 citra untuk data pengujian.

F. Pelatihan dan Validasi

Setelah tahap pelatihan dan validasi selesai, langkah selanjutnya adalah melakukan pengujian untuk mengevaluasi performa model secara menyeluruh menggunakan data pengujian. Tujuan dari tahap pengujian ini adalah untuk menilai sejauh mana model dapat menggeneralisasi dan mendeteksi pengemudi yang mengalami kecelakaan kendaraan dalam kondisi yang variatif dan tidak terduga

G. Pengujian

Langkah terakhir dalam proses ini adalah melatih model deteksi kecelakaan. Pada tahap ini, model dikembangkan untuk menerima masukan berupa citra kecelakaan dan mendeteksi pengemudi yang terlibat. Proses pelatihan ini penting untuk memastikan model dapat melakukan deteksi secara akurat dalam situasi nyata. Setelah selesai dilatih dan validasi, model diuji menggunakan data pengujian yang terdiri atas sejumlah citra untuk mengevaluasi kinerjanya.

H. Persamaan

Penelitian ini menggunakan metrik precision, recall, dan average precision untuk mengevaluasi kinerja model secara menyeluruh. Evaluasi ini bertujuan untuk menilai sejauh mana model dapat mendeteksi pengendara yang mengalami kecelakaan dengan tingkat akurasi yang tinggi. Average precision dihitung berdasarkan nilai setiap kelas sesuai dengan persamaan (1), dengan menggunakan perhitungan precision yang dirumuskan dalam persamaan (2) dan nilai recall yang dirumuskan dalam persamaan (3).

$$Average\ Precision = \int_0^1 P(R)dR \tag{1}$$

$$Precision = \frac{TP}{TP + FP} \tag{2}$$

$$Recall = \frac{TP}{TP + FN} \tag{3}$$

Kemudian, perhitungan rata-rata confidence dilakukan dengan menggunakan persamaan (4), yang bertujuan untuk mengukur tingkat keyakinan model dalam mendeteksi pengendara yang mengalami kecelakaan dengan tepat. Selain itu, perhitungan *intersection over union* (IoU) juga diperlukan untuk mengukur seberapa besar tumpang tindih antara *bounding box* prediksi dan *ground truth* bertujuan untuk menghitung metrik precision yang lebih akurat pada model. Perhitungan IoU dilakukan dengan menggunakan persamaan (5).

$$Average\ Confidence = \frac{\sum Confidence\ Scores}{Total\ of\ Detection} \tag{4}$$

$$IoU = \frac{Intersection\ Area}{Union\ Area} \tag{5}$$

IV. HASIL DAN PEMBAHASAN

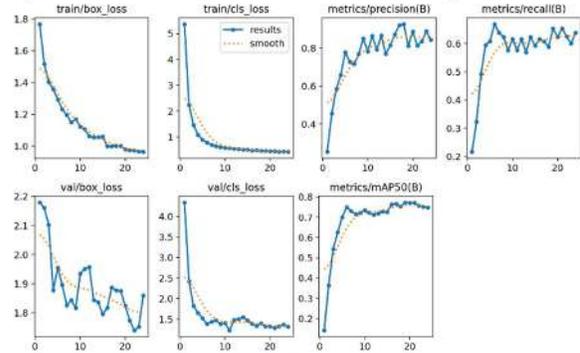
Setelah melakukan beberapa skenario pelatihan pada model YOLOv9, diperoleh hasil yang bervariasi dengan perubahan pada *batch size* dan *learning rate*. Tabel 1 menyajikan hasil pelatihan dengan berbagai pengaturan *hyperparameter*.

Tabel 1  
Hasil pelatihan hyperparameter

lr	Batch	AP@50	Precision	Recall	Average Confiden ce	IoU
0,005	8	0,77	0,82	0,65	0,66	0,79
0,0003	8	0,76	0,75	0,69	0,65	0,78
0,0001	8	0,69	0,82	0,55	0,61	0,76
0,0005	4	0,76	0,82	0,65	0,65	0,78
0,0003	4	0,73	0,8	0,64	0,67	0,78
0,0001	4	0,68	0,73	0,62	0,57	0,76

Berdasarkan hasil yang ditampilkan dalam Tabel 4.1, terdapat beberapa konfigurasi *hyperparameter* yang digunakan dalam model YOLOv9. Model ini menggunakan versi "e" (dikenal sebagai YOLOv9 *extensive*) dengan 58,1 juta parameter dan FLOPs sebesar 192,5. Hasil terbaik dicapai pada pengaturan *batch size* 8 dan *learning rate* 0,0005, yang menghasilkan AP@50 sebesar 0,77 dan IoU sebesar 0,79. Pengaturan *batch size* 8 dan *learning rate* 0,0003 memberikan *recall* tertinggi sebesar 0,69, sementara pengaturan *batch size* 4 dan *learning rate* 0,0005 menghasilkan *precision* tertinggi sebesar 0,82. Pengaturan

*batch size* 4 dan *learning rate* 0,0003 mendapatkan *average confidence* terbaik adalah 0,67 yang menunjukkan tingkat *confidence* moderat model dalam melakukan prediksi.



GAMBAR 5

Hasil grafik pelatihan dari model YOLOv9e.

Gambar 5 menunjukkan grafik yang dihasilkan oleh model selama proses pelatihan. Pada grafik *train/box\_loss* dan *train/cls\_loss*, terlihat tren penurunan yang konsisten seiring bertambahnya *epoch*. Penurunan ini menandakan bahwa model semakin baik dalam memprediksi *bounding box* objek pada data pelatihan. Tren serupa juga terlihat pada bagian validasi di bawahnya *val/box\_loss* dan *val/cls\_loss*, meskipun fluktuasi lebih besar terjadi, yang umum karena validasi dilakukan pada data yang tidak dilatih langsung oleh model. Selain itu, metrik evaluasi, *precision*(B) mengalami peningkatan yang signifikan di awal pelatihan dan kemudian cenderung stabil pada nilai tinggi. *Precision* mengukur proporsi prediksi yang benar dari total prediksi positif, yang menunjukkan bahwa model mampu menghasilkan prediksi yang relevan tanpa banyak kesalahan. *Recall*(B) juga menunjukkan peningkatan yang stabil, yang menandakan bahwa model semakin mampu mendeteksi semua kejadian kecelakaan yang ada dalam data. Selain itu, nilai mAP50(B) meningkat hingga mendekati nilai 0,8, yang mengindikasikan bahwa model memiliki tingkat keakuratan tinggi dalam mendeteksi dan menentukan lokasi *bounding box* pada objek target. Setelah proses pelatihan model selesai, tahap selanjutnya adalah pengujian model menggunakan hasil *hyperparameter tuning* dari pelatihan dengan *learning rate* sebesar 0,0005 dan *batch size* 8. Pengujian dilakukan dengan menggunakan data pengujian untuk menilai performa model yang telah dilatih.

Tabel 2  
Hasil pengujian model.

Learning Rate	Batch	AP@50	Precision	Recall	Average Confiden ce	IoU
0,0005	8	0,72	0,75	0,61	0,63	0,73

Tabel 2 menunjukkan hasil pengujian model YOLOv9 dengan *learning rate* 0,0005 dan *batch size* 8. Nilai AP@50 sebesar 0,72 menunjukkan akurasi deteksi yang baik pada *threshold* 50%. *Precision* sebesar 0,75 mengindikasikan bahwa 0,75 prediksi model adalah benar dan *recall* sebesar

0,61 menunjukkan bahwa model berhasil mendeteksi sekitar 0,61 objek yang ada.

*Average confidence* sebesar 0,63 mengindikasikan bahwa model memiliki tingkat *confidence* moderat dalam prediksi yang dihasilkannya, menunjukkan bahwa meskipun akurasi model cukup baik dengan nilai IoU 0,73 yang menandakan akurasi pemetaan objek yang memadai. Analisis dilakukan untuk melihat hasil yang diperoleh dari model, dengan tujuan untuk mengevaluasi kinerja dan efektivitas model dalam mendeteksi objek.

A. Data Uji dengan Kehadiran Penolong



GAMBAR 6

Kesalahan deteksi menganggap penolong sebagai korban.

Gambar 6 menunjukkan contoh kesalahan deteksi yang terjadi pada seseorang yang sedang memberi pertolongan. Model salah mendeteksi individu yang tidak terlibat dalam kecelakaan sebagai korban di lokasi kejadian. Padahal, orang yang terdeteksi sebenarnya sedang berusaha membantu korban kecelakaan, bukan sebagai korban. Penyebab kesalahan ini adalah posisi penolong yang terlihat membungkuk saat memberikan bantuan, yang membuat model mengira bahwa orang tersebut adalah korban. Kondisi ini menunjukkan bahwa model kesulitan dalam membedakan orang yang sedang memberikan pertolongan dari orang yang benar-benar mengalami kecelakaan. Terdapat 8 dari 45 citra yang mengalami kesalahan deteksi pada kategori ini.

B. Data Uji dengan Objek Terdekat



GAMBAR 7

Kesalahan deteksi saat korban berdekatan dengan motor atau korban lainnya.

Gambar 7 menunjukkan kesalahan deteksi yang terjadi ketika korban berada terlalu dekat dengan objek lain, seperti sepeda motor atau penolong. Model kesulitan mendeteksi pengendara yang mengalami kecelakaan dalam kondisi ini. Penyebab kesalahan deteksi ini adalah posisi pengendara yang dekat dengan objek lain, sehingga model kesulitan dalam membedakan korban dari objek di sekitarnya. Hal ini kemungkinan disebabkan oleh keterbatasan variasi dalam *dataset* pelatihan, yang sebagian besar hanya mencakup citra individu yang terpisah dari objek lain. Terdapat 23 dari 45 citra mengalami kesalahan deteksi dalam kasus ini.

C. Model Mendeteksi Selain Korban



GAMBAR 8

Kesalahan deteksi menganggap objek lain sebagai korban.

Gambar 8 menunjukkan bahwa model melakukan kesalahan dengan mendeteksi objek selain pengendara yang mengalami kecelakaan sebagai korban. Kesalahan ini menunjukkan bahwa model tidak dapat membedakan dengan tepat antara korban kecelakaan dan objek lain yang tidak relevan. Terdapat 6 dari 45 citra yang mengalami kesalahan deteksi pada kasus ini.

D. Data Uji dengan Jarak Tertentu



GAMBAR 9

Model kesulitan dalam mendeteksi korban jarak terlalu jauh atau dekat.

Gambar 9 menunjukkan kesalahan deteksi yang terjadi ketika posisi korban terlalu jauh atau terlalu dekat dengan kamera. Model mengalami kesulitan dalam mendeteksi pengendara yang terlibat kecelakaan ketika korban berada di posisi yang sangat dekat atau sangat jauh dari kamera. Kesulitan ini kemungkinan disebabkan oleh keterbatasan variasi dalam *dataset* pelatihan, yang sebagian besar hanya mencakup citra dengan posisi korban yang berada pada jarak menengah. Dalam kategori ini, terdapat 10 dari 45 citra yang mengalami kesalahan deteksi.

E. Nilai Confidence Kecil



GAMBAR 10

Model memberikan nilai confidence rendah tetapi IoU tinggi.

Meskipun model YOLOv9 menunjukkan performa yang baik dalam hal lokalisasi objek, namun terdapat masalah dalam melakukan identifikasi yang memengaruhi tingkat keakuratan deteksi. Salah satu penyebab utama kesalahan ini adalah nilai *confidence* yang kecil pada deteksi korban kecelakaan. Ketika nilai *confidence* terlalu rendah, model sering kali gagal untuk mengidentifikasi objek sebagai korban kecelakaan, meskipun objek tersebut telah berhasil terlokalisasi dengan benar. Hal ini dapat terjadi karena banyaknya variasi seperti pose dan bentuk dari korban pada saat terjadi kecelakaan.

Gambar 10 menunjukkan bahwa meskipun model memberikan nilai *confidence* yang rendah, nilai IoU yang diperoleh tetap sangat tinggi. Hal ini menunjukkan bahwa

meskipun model mampu melakukan lokalisasi objek dengan tepat, masalah dalam melakukan deteksi masih menghambat kemampuan deteksi secara keseluruhan. Selain itu, penulis juga mengidentifikasi bahwa terdapat 39 dari 45 citra yang memiliki nilai *confidence* di bawah ambang batas minimum

## V. KESIMPULAN

Penelitian ini berhasil menyelesaikan permasalahan dalam deteksi kecelakaan pengendara sepeda motor menggunakan metode YOLOv9 versi e dengan variasi *learning rate* 0,001, 0,003, dan 0,0005, serta *batch size* 4 dan 8. Hasil terbaik diperoleh dengan *learning rate* 0,0005 dan *batch size* 8, menghasilkan AP@50 sebesar 0,72, *precision* 0,75, *recall* 0,61, *average confidence* 0,63, dan IoU 0,73, yang mencerminkan performa yang cukup baik. Meskipun model ini menunjukkan hasil yang positif, masih terdapat beberapa kekurangan dalam proses deteksi, seperti ketidakmampuan model untuk mendeteksi posisi pengendara yang mengalami kecelakaan secara menyeluruh, kurangnya variasi jarak antara CCTV dan korban, serta adanya kesalahan deteksi yang mengidentifikasi objek lain sebagai manusia.

Untuk penelitian selanjutnya, disarankan untuk memperbanyak jumlah *dataset* agar model dapat mendeteksi pengendara yang terlibat dalam kecelakaan dengan berbagai kondisi dan posisi. Hal ini dikarenakan penelitian ini hanya menggunakan 815 citra, yang masih terbilang terbatas. Selain itu, perluasan ruang lingkup sistem deteksi juga disarankan, seperti penambahan kemampuan untuk mendeteksi kecelakaan yang melibatkan kendaraan roda empat dan tiga. Dengan demikian, sistem ini tidak hanya mampu mendeteksi kecelakaan pada sepeda motor, tetapi juga pada mobil dan sepeda motor roda tiga. Penelitian ke depan juga dapat difokuskan pada upaya untuk meningkatkan nilai *confidence* dalam mendeteksi korban, sehingga model dapat lebih akurat dalam mengidentifikasi objek yang terdeteksi sebagai korban atau bukan.

## REFERENSI

- [1] World Health organization, "Road traffic injuries." [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries>
- [2] Badan Pusat Statistik, "Jumlah Kecelakaan, Korban Mati, Luka Berat, Luka Ringan, dan Kerugian Materi, 2022."
- [3] D. Setiawan and M. Asima, "PEMETAAN RISIKO KECELAKAAN LALU LINTAS DI RUAS JALAN TOL CIPULARANG," Nov. 2019.
- [4] Polisi Republik Indonesia, "Jurnal data pusiknas bareskrim polri tahun 2023 edisi 2024," Jun. 2024, [Online]. Available: [https://pusiknas.polri.go.id/jurnal\\_detail/jurnal\\_data\\_pusiknas\\_bareskrim\\_polri\\_tahun\\_2023\\_edisi\\_2024](https://pusiknas.polri.go.id/jurnal_detail/jurnal_data_pusiknas_bareskrim_polri_tahun_2023_edisi_2024)
- [5] Ismurrizal, "Analisis Faktor Penyebab Kematian Pada Kecelakaan Lalu Lintas," p. 4, Oct. 2020, [Online]. Available: <https://ejournal.delihusada.ac.id/index.php/JK2M/articledownload/403/299>
- [6] A. P. Melani, V. S. A. Nawangsih, N. U. K. Devi, F. Laseda, Moch. S. Rizal, and A. Hoirullah, "Analisis Keterlambatan Penanganan Korban Kecelakaan Tanpa Identitas di RSUD Waluyo Jati Kraksaan," *Jurnal Publik*, vol. 18, no. 02, pp. 119–128, Dec. 2024, doi: 10.52434/jp.v18i02.416.
- [7] Kementerian Kesehatan, "Sistem Penanggulangan Gawat Darurat Terpadu (SPGDT)," Oct. 2024. Accessed: Feb. 07, 2025. [Online]. Available: [https://pusatkrisis.kemkes.go.id/\\_pub/files935881\\_Final\\_Buku\\_Pedoman\\_Teknis\\_SPGDT.pdf](https://pusatkrisis.kemkes.go.id/_pub/files935881_Final_Buku_Pedoman_Teknis_SPGDT.pdf)
- [8] J. T. Valente and M. A. Perez, "Emergency response to vehicle collisions: Feedback from emergency medical service providers," *Safety*, vol. 6, no. 4, 2020, doi: 10.3390/safety6040048.
- [9] K. S. S. Wiwekananda, R. P. Hamukti, K. S. S. Yogananda, K. E. Calisto, and P. S. Utomo, "Understanding factors of ambulance delay and crash to enhance ambulance efficiency: an integrative literature review," *Journal of Community Empowerment for Health*, vol. 3, no. 3, p. 213, Dec. 2020, doi: 10.22146/jcoemph.57338.
- [10] K. Adi, A. Subagio, S. A. Widyanto, and A. B. Putranto, "Motor vehicle condition monitoring and recording system using arduino mega," *International Review of Electrical Engineering*, vol. 16, no. 3, pp. 286–294, 2021, doi: 10.15866/iree.v16i3.18344.
- [11] Prabakar S, *AN ENHANCED ACCIDENT DETECTION AND VICTIM STATUS INDICATING SYSTEM: PROTOTYPE*. IEEE, 2012.
- [12] K. A. V. Prof. S. R. J. Bankar Sanket Anil, *Intelligent System for Vehicular Accident Detection and Notification*. IEEE, 2014.
- [13] A. Lupinska-Dubicka *et al.*, "In-Car eCall Device for Automatic Accident Detection, Passengers Counting and Alarming," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 11960 LNCS, Springer, 2020, pp. 36–57. doi: 10.1007/978-3-662-61092-3\_3.
- [14] M. I. Basheer Ahmed *et al.*, "A Real-Time Computer Vision Based Approach to Detection and Classification of Traffic Incidents," *Big Data and Cognitive Computing*, vol. 7, no. 1, Mar. 2023, doi: 10.3390/bdcc7010022.
- [15] Y. Xiao *et al.*, "A review of object detection based on deep learning," *Multimed Tools Appl*, vol. 79, no. 33–34, pp. 23729–23791, Sep. 2020, doi: 10.1007/s11042-020-08976-6.
- [16] T.-Hang. Meen, *Knowledge Innovation and Invention: 1st IEEE International Conference on Knowledge Innovation and Invention (IEEE ICKII 2018): Jeju Island, South Korea, July 23-27, 2018*. International Institute of Knowledge Innovation and Invention (IIKII), 2018.
- [17] W. Y. Hsu and W. Y. Lin, "Ratio-and-Scale-Aware YOLO for Pedestrian Detection," *IEEE Transactions on Image Processing*, vol. 30, pp. 934–947, 2021, doi: 10.1109/TIP.2020.3039574.
- [18] Y. Li, J. Wang, J. Huang, and Y. Li, "Research on Deep Learning Automatic Vehicle Recognition Algorithm Based on RES-YOLO Model," *Sensors*, vol. 22, no. 10, May 2022, doi: 10.3390/s22103783.
- [19] Z. Zou, K. Chen, Z. Shi, Y. Guo, and J. Ye, "Object Detection in 20 Years: A Survey," May 2019, [Online]. Available: <http://arxiv.org/abs/1905.05055>

- [20] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," 2016.
- [21] P. and T. R. Hidayatullah, "YOLOv9 Architecture Explained," 2024.
- [22] C.-Y. Wang, I.-H. Yeh, and H.-Y. M. Liao, "YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information," Feb. 2024, [Online]. Available: <http://arxiv.org/abs/2402.13616>
- [23] M. Yaseen, "What is YOLOv9: An In-Depth Explorantion of the Internal Features of the Next-Generation Object Detector," Sep. 2024, [Online]. Available: <http://arxiv.org/abs/2409.07813>
- [24] U.S. Department of Transportation, "Estimating Effectiveness of Lane Keeping Assist Systems in Fatal Road Departure Crashes," Dec. 2024.
- [25] "accident Computer Vision Project." [Online]. Available: <https://universe.roboflow.com/gabriel-xdfe6/accident-vcudo-506cz>

