

INVESTIGASI FORENSIK KECELAKAAN KENDARAAN BERMOTOR MENGGUNAKAN METODE DEEP LEARNING

Muhammad Erik Zubair Rohman, Arda Surya Editya

Teknik Informatika, Universitas Nahdlatul Ulama Sidoarjo

Jl. Lingkar Luar, Rangkah Kidul, Kec. Sidoarjo, Kabupaten Sidoarjo, Jawa Timur, Indonesia.

muhammaderikzubairrohman@gmail.com

ABSTRAK

Meningkatnya jumlah kecelakaan kendaraan bermotor di jalan raya memerlukan metode analisis forensik yang lebih efektif dan akurat untuk menginvestigasi penyebab kecelakaan, sedangkan metode konvensional seringkali memiliki keterbatasan dalam mengidentifikasi dan mengklasifikasikan objek-objek penting pada rekaman kecelakaan secara tepat dan real-time. Penelitian ini bertujuan untuk mengembangkan sistem investigasi forensik kecelakaan kendaraan bermotor menggunakan metode deep learning berbasis YOLO untuk mendeteksi dan mengklasifikasikan kejadian kecelakaan secara otomatis. Metode yang digunakan adalah penerapan algoritma YOLO yang dioptimalkan untuk mendeteksi objek pada video rekaman kecelakaan, dengan dataset yang diperoleh dari berbagai sumber dan evaluasi kinerja menggunakan metrik Presisi, Recall, F1-Score, dan mAP. Hasil penelitian menunjukkan bahwa metode YOLO mampu mendeteksi dan mengklasifikasikan objek-objek penting dalam kecelakaan seperti kendaraan dan penumpang dengan akurasi tinggi, serta membuktikan keandalan metode ini dalam pengolahan real-time, sehingga dapat mendukung analisis forensik secara efektif dan berpotensi menjadi alat bantu berharga bagi lembaga penegak hukum dalam mengidentifikasi penyebab kecelakaan serta merancang langkah-langkah pencegahan yang lebih efektif.

Kata kunci : *Investigasi Forensik, Kecelakaan Kendaraan Bermotor, Deep Learning, Deteksi Objek, YOLO*

1. PENDAHULUAN

Seiring dengan meningkatnya volume kendaraan bermotor di jalan raya, kecelakaan lalu lintas juga meningkat secara signifikan. Menurut World Health Organization (WHO), insiden kecelakaan lalu lintas menyebabkan sekitar 1,19 juta kematian setiap tahunnya dan merupakan penyebab utama kematian bagi anak-anak dan dewasa muda berusia 5–29 tahun [1]. Kondisi ini menimbulkan kebutuhan mendesak akan metode analisis forensik yang efektif untuk menyelidiki penyebab kecelakaan, terutama mengingat kompleksitas data visual seperti rekaman CCTV dan foto tempat kejadian perkara (TKP).

Pendekatan konvensional—misalnya, inspeksi manual dan analisis foto secara langsung—sering kali menghadapi keterbatasan dalam mengelola data berjumlah besar dan sangat bergantung pada keahlian analis. Dalam konteks ini, teknik deep learning telah muncul sebagai solusi potensial yang dapat meningkatkan kecepatan dan akurasi analisis. Sebagai contoh, Ghahremannezhad et al. mengembangkan kerangka kerja efisien untuk deteksi kecelakaan di persimpangan jalan menggunakan metode YOLOv4, yang menunjukkan kemampuan signifikan dalam mengidentifikasi kecelakaan dari video pengawasan [2]. Selain itu, Mane et al. melaporkan bahwa metode deteksi kecelakaan real-time dalam video surveillance dapat mencapai tingkat presisi tinggi, mendukung penerapan sistem otomatis dalam investigasi forensik [3].

Di Indonesia, meskipun studi lokal masih terbatas, teknologi deep learning menunjukkan potensi besar. Penerapan model YOLO (You Only Look Once) telah populer karena kemampuannya

melakukan deteksi real-time dengan akurasi tinggi. Versi terbaru seperti YOLOv5n "Nano" models, yang dikembangkan oleh Ultralytics, menawarkan integrasi fitur modern seperti Roboflow, ekspor ke TensorFlow, dan dukungan OpenCV DNN [4]. Model ini diharapkan dapat meningkatkan efisiensi dan akurasi dalam proses investigasi kecelakaan.

Penelitian ini bertujuan untuk mengembangkan sistem investigasi forensik kecelakaan kendaraan bermotor dengan mengintegrasikan metode deep learning, khususnya penerapan model YOLO, untuk mendeteksi dan mengklasifikasikan objek-objek kritis pada TKP secara otomatis. Dengan demikian, sistem yang dikembangkan diharapkan dapat memberikan dukungan yang lebih efektif dalam investigasi kecelakaan serta berkontribusi pada upaya pencegahan dan peningkatan keselamatan di jalan raya.

Metodologi penelitian mencakup pengumpulan dataset foto kecelakaan dari berbagai sumber, pra-pemrosesan data, pelatihan model YOLO yang telah dioptimalkan, serta evaluasi kinerja menggunakan metrik seperti presisi, recall, F1-score, dan mean Average Precision (mAP). Validasi dilakukan dengan dataset representatif untuk menguji keandalan sistem dalam berbagai skenario kecelakaan.

2. TINJAUAN PUSTAKA

Dalam bab ini, penulis menguraikan berbagai penelitian terdahulu yang berkaitan dengan investigasi kecelakaan lalu lintas dan penerapan teknologi deep learning. Peninjauan ini bertujuan memberikan gambaran menyeluruh tentang tantangan, solusi, serta potensi pengembangan sistem forensik kecelakaan berbasis kecerdasan buatan.

2.1. Metode Konvensional Dalam Investigasi Forensik Kecelakaan Lalulintas

Pendekatan tradisional dalam investigasi kecelakaan lalu lintas, seperti inspeksi visual manual dan analisis foto Tempat Kejadian Perkara (TKP), sering kali menghadapi keterbatasan dalam hal kecepatan, konsistensi, dan kapasitas pengelolaan data besar. Keterbatasan ini terutama disebabkan oleh ketergantungan yang tinggi pada keahlian individu dalam proses analisis, yang berisiko menimbulkan bias dan inkonsistensi hasil. Metode konvensional ini juga sering kali memerlukan waktu yang lama dan dapat terpengaruh oleh kondisi cuaca atau pencahayaan yang tidak ideal, sehingga mengurangi akurasi dan efektivitas investigasi.

Sebagai alternatif, teknologi modern seperti fotogrametri dan pemindaian laser telah diperkenalkan untuk meningkatkan kualitas dan efisiensi investigasi kecelakaan. Fotogrametri memungkinkan perekaman data visual dari berbagai sudut menggunakan kamera digital, yang kemudian diproses untuk menghasilkan model 3D dari TKP. Pemindaian laser, di sisi lain, menggunakan sinar laser untuk mengukur jarak dan menghasilkan titik-titik data yang sangat akurat, membentuk point cloud yang dapat dianalisis lebih lanjut. Kombinasi kedua teknologi ini memungkinkan rekonstruksi kecelakaan yang lebih detail dan objektif, serta memfasilitasi analisis yang lebih mendalam terhadap faktor-faktor penyebab kecelakaan.

Studi oleh Ghasemi dan Amini membandingkan metode tradisional dengan teknik survei modern seperti fotogrametri dan pemindaian laser. Hasilnya menunjukkan bahwa metode tradisional, meskipun lebih sederhana dan murah, memiliki keterbatasan dalam akurasi dan efisiensi dibandingkan dengan teknologi modern. Penggunaan fotogrametri dan pemindaian laser memungkinkan perekaman data yang lebih cepat dan akurat, serta menghasilkan model 3D dari TKP yang dapat dianalisis lebih lanjut untuk menentukan penyebab kecelakaan secara lebih objektif. Selain itu, teknologi ini juga dapat membantu dalam dokumentasi bukti secara digital, yang mempermudah proses hukum dan penyelesaian klaim asuransi.[5]

2.2. Penerapan Deep Learning Untuk Deteksi Kecelakaan

Kemajuan teknologi deep learning telah membuka peluang baru dalam analisis data visual dan pengawasan lalu lintas. Liang [6] menunjukkan bahwa pendekatan convolutional neural networks (CNN) mampu mendeteksi kecelakaan dari video lalu lintas dengan akurasi tinggi, bahkan dalam kondisi pencahayaan yang bervariasi.

Selain itu, Mane et al. [3] mengembangkan sistem deteksi real-time berbasis deep learning yang dapat secara otomatis mengidentifikasi insiden lalu lintas dari kamera pengawas. Studi ini menunjukkan peningkatan signifikan dalam kecepatan respons dan akurasi sistem dibandingkan metode manual.

Alam et al. [7] memanfaatkan YOLOv5 untuk mendeteksi kendaraan secara real-time di persimpangan jalan, dengan tingkat presisi dan kecepatan tinggi. Hasil penelitian mereka menegaskan bahwa model deep learning seperti YOLO tidak hanya cocok untuk deteksi objek umum, tetapi juga sangat efektif dalam konteks pemantauan lalu lintas.

Sami et al. [8] mengembangkan sistem deteksi kerusakan jalan berbasis YOLOv5, yang berperan penting dalam konteks investigasi kecelakaan akibat infrastruktur. Sistem tersebut memungkinkan identifikasi otomatis terhadap lubang jalan atau kerusakan lainnya yang berpotensi menyebabkan kecelakaan.

2.3. Implementasi Model YOLO Dalam Investigasi Forensik

Model YOLO (You Only Look Once) telah menjadi salah satu framework paling populer dalam deteksi objek secara real-time karena keunggulannya dalam kecepatan dan efisiensi. Versi terbaru seperti YOLOv5n "Nano" models dari Ultralytics menawarkan integrasi dengan Roboflow, ekspor ke TensorFlow, dan dukungan OpenCV DNN, menjadikannya ideal untuk pengolahan citra TKP secara otomatis dan cepat Alam et al. [7]

Zeng et al. [9] menerapkan YOLOv5 untuk mendeteksi objek secara cepat di lokasi kecelakaan, seperti kendaraan yang terlibat tabrakan, puing-puing, dan penanda jalan. Penelitian mereka menunjukkan bahwa model ini mampu memberikan deteksi yang konsisten meskipun dalam kondisi lingkungan kompleks.

Selain pendeteksian fisik, studi perilaku juga penting dalam investigasi kecelakaan. Perez et al. [10] menganalisis faktor-faktor yang memengaruhi kecenderungan pengemudi untuk mengemudi cepat berdasarkan data naturalistik, sementara Zhang et al. [11] menggunakan model statistik untuk mengidentifikasi variabel penyebab utama kecelakaan.

3. METODE PENELITIAN

Penelitian ini menggunakan metode deteksi objek berbasis deep learning dengan menerapkan model YOLO (You Only Look Once) sebagai framework utama. Metode yang digunakan mencakup tahapan pengumpulan data, pra-pemrosesan, pelatihan model, serta evaluasi kinerja model YOLO dalam mendeteksi dan mengklasifikasikan objek-objek kritis pada TKP (Tempat Kejadian Perkara).


3.1. Pengumpulan dan Persiapan Data

Dataset yang digunakan diperoleh dari Roboflow, yang menyediakan kumpulan gambar dari berbagai sumber. Setiap gambar telah dilabeli secara langsung di platform untuk menandai objek-objek penting seperti kendaraan, pejalan kaki, dan rambu lalu lintas. Selanjutnya, data tersebut diolah melalui proses pra-pemrosesan yang meliputi auto-orient, resize stretch ke ukuran 640x640, auto-adjust contrast,

dan konversi ke grayscale guna menstandarkan kondisi input. Untuk meningkatkan keragaman dan jumlah data guna pelatihan, dilakukan augmentasi dengan teknik flip, rotasi 90 derajat, penyesuaian brightness, exposure, serta penambahan noise.

3.2. Pengembangan dan Implementasi Mode YOLO

Penelitian ini menggunakan model YOLO, khususnya varian YOLOv5 yang dikembangkan oleh Ultralytics, karena keunggulannya dalam mendeteksi objek secara real-time dengan performa yang efisien. YOLO dipilih karena mampu mengubah proses deteksi objek menjadi satu langkah prediksi tunggal, sehingga menghasilkan kecepatan inferensi yang tinggi serta akurasi yang baik. Pengembangan model dilakukan menggunakan platform deep learning seperti PyTorch, dengan dukungan integrasi Roboflow dan opsi ekspor ke TensorFlow guna meningkatkan fleksibilitas dalam pengembangan dan deployment.



Gambar 1. YOLO Workflow Diagram

Gambar 1 menampilkan arsitektur YOLOv5 yang terdiri dari tiga komponen utama, yaitu Backbone untuk mengekstraksi fitur dasar dari gambar melalui lapisan konvolusi dan blok BottleneckCSP, PANet (Path Aggregation Network) untuk menggabungkan serta memperkaya fitur dari berbagai tingkat kedalaman guna memudahkan deteksi objek skala kecil maupun besar, dan Output Layer yang terdiri dari lapisan konvolusi 1×1 untuk menghasilkan bounding box, confidence score, serta label kelas objek. Integrasi ketiga komponen ini memungkinkan YOLOv5 melakukan deteksi objek dengan cepat dan efisien, sehingga mendukung aplikasi real-time dalam investigasi forensik kecelakaan kendaraan bermotor.

3.3. Penerapan Deplering Dalam Investigasi Forensik Dan Deteksi Kecelakaan

Pelatihan model dilakukan dengan memanfaatkan dataset yang telah dipersiapkan melalui proses pra-pemrosesan dan augmentasi, sehingga menghasilkan total 6.845 sampel gambar. Dataset tersebut dibagi menjadi dua bagian, yaitu data pelatihan (training set) dan data validasi (validation set), dengan perbandingan yang disesuaikan untuk memastikan representativitas masing-masing set.

Model YOLOv5 dilatih menggunakan framework PyTorch dengan menggunakan optimizer Adam dan penyesuaian learning rate secara dinamis guna menghindari overfitting. Selama proses pelatihan, model dievaluasi secara berkala menggunakan metrik standar seperti presisi, recall, F1-score, dan mean Average Precision (mAP) untuk memantau performa dan mengidentifikasi titik konvergensi. Data validasi digunakan untuk melakukan tuning hyperparameter dan memastikan model dapat menggeneralisasi dengan baik pada data baru. Hasil pelatihan yang optimal kemudian digunakan sebagai dasar untuk pengujian lebih lanjut dalam aplikasi real-time pada investigasi forensik kecelakaan kendaraan bermotor.

3.4. Evaluasi Hasil Penelitian

Setelah model dilatih, uji coba dilakukan dengan menggunakan dataset representatif yang mencerminkan kondisi nyata pada TKP. Model YOLOv5 diterapkan pada data uji untuk mendeteksi dan mengklasifikasikan objek-objek kritis. Hasil deteksi dibandingkan dengan label manual sebagai ground truth guna mengukur performa model. Evaluasi dilakukan dengan menggunakan metrik standar seperti presisi, recall, F1-score, dan mean Average Precision (mAP). Analisis hasil menunjukkan bahwa model mampu mendeteksi objek secara cepat dan akurat dalam kebanyakan skenario, meskipun terdapat beberapa kasus di mana akurasi masih perlu ditingkatkan melalui penyesuaian hyperparameter dan optimasi lebih lanjut. Data evaluasi ini digunakan untuk mengidentifikasi kekuatan serta kelemahan model, dan memberikan rekomendasi untuk perbaikan guna mendukung implementasi sistem investigasi forensik kecelakaan kendaraan bermotor secara real-time.

4. HASIL DAN PEMBAHASAN

Bagian ini membahas hasil dari implementasi model YOLO yang telah dikembangkan, termasuk analisis performa model berdasarkan evaluasi metrik yang telah dilakukan. Selain itu, dilakukan analisis terhadap hasil uji coba yang mencakup deteksi objek dalam berbagai kondisi.

4.1. Hasil Training Dataset

Proses pelatihan dilakukan menggunakan dataset yang telah diproses sebelumnya dengan teknik pra-pemrosesan dan augmentasi. Dataset akhir yang digunakan dalam pelatihan terdiri dari 6.845 gambar hasil dari proses labeling dan augmentasi di Roboflow. Pelatihan dilakukan selama 150 epoch dengan implementasi early stopping untuk mencegah overfitting dan memastikan model mencapai tingkat konvergensi yang optimal.

Evaluasi terhadap performa model dilakukan menggunakan metrik yang mencakup Precision, Recall, F1-score, dan Mean Average Precision (mAP). Hasil pelatihan menunjukkan bahwa model mencapai nilai mAP@50 sebesar 46.0%. Metrik precision

mencapai 51.2% dan recall 47.4%, yang menunjukkan keseimbangan relatif antara kemampuan model untuk mengidentifikasi objek dengan benar dan tingkat coverage deteksi.

Kurva belajar menunjukkan penurunan loss yang stabil pada data training dan validasi, dengan box_loss, cls_loss, dan dfl_loss yang konvergen setelah sekitar 100 epoch. Meskipun nilai performa masih memiliki ruang untuk peningkatan, hasil ini memberikan dasar yang solid untuk pengembangan model lebih lanjut dalam deteksi objek kecelakaan dengan berbagai tingkat kompleksitas.

4.2. Evaluasi Kinerja Model

Proses pelatihan model dilakukan selama 175 epoch, dengan dokumentasi detail dari setiap iterasi pelatihan. Tabel berikut menampilkan ringkasan metrik kinerja selama proses training:

Tabel 1. Hasil Evaluasi Kinerja Model Selama Pelatihan


Metrik	Awal Epoch	Tengah Epoch	Akhir Epoch
Precision	0.20	0.43	0.51
Recall	0.30	0.45	0.53
mAP@0.5	0.15	0.38	0.46
mAP@0.5:0.95	0.05	0.18	0.24

Analisis detail terhadap hasil training menunjukkan perkembangan signifikan dalam kinerja model dari epoch pertama hingga epoch terakhir. Precision model meningkat dari 20% menjadi 51%, menandakan peningkatan kemampuan model dalam mengidentifikasi objek dengan akurat.

Recall model juga mengalami peningkatan dari 30% menjadi 53%, yang menunjukkan bahwa model semakin mampu mengenali objek-objek penting dalam dataset kecelakaan. Mean Average Precision (mAP) pada threshold 0.5 meningkat dari 15% menjadi 46%, yang secara signifikan menggambarkan peningkatan performa model.

Untuk memberikan perspektif komprehensif tentang kinerja model, penelitian ini mengembangkan empat grafik analitis kunci yang menggambarkan karakteristik performa model deteksi kecelakaan dari berbagai sudut pandang metrik. Keempat grafik - Recall-Confidence Curve, Precision-Confidence Curve, Precision-Recall Curve, dan F1-Confidence Curve - menawarkan wawasan mendalam tentang kemampuan model dalam mengenali dan mengklasifikasikan berbagai jenis kecelakaan.

Metrik mAP@0.5:0.95 yang meningkat dari 5% di awal pelatihan hingga mencapai 24% di akhir pelatihan menunjukkan peningkatan kemampuan model dalam mendeteksi objek dengan tingkat presisi lokalisasi yang berbeda-beda. Nilai ini sangat penting untuk mengevaluasi keakuratan model secara menyeluruh pada berbagai threshold IoU..



Gambar 2. Hasil Training: Train


Berdasarkan ketiga grafik yang disajikan (train/dfl_loss, train/cls_loss, dan train/box_loss), terlihat pola pembelajaran yang komprehensif dalam model deteksi objek selama proses pelatihan.

Grafik train/box_loss menampilkan penurunan error lokalisasi objek yang konsisten dari nilai awal 1.4 hingga mencapai titik optimal sekitar 0.35. Kurva menunjukkan pembelajaran efektif dalam mengidentifikasi parameter spasial objek seperti posisi dan dimensi bounding box.

Pada grafik train/cls_loss, terlihat penurunan yang lebih dramatis dari nilai awal sekitar 3.1 hingga 0.3 pada akhir pelatihan. Hal ini mengindikasikan peningkatan signifikan dalam kemampuan model untuk mengklasifikasikan objek dengan benar, dengan fase pembelajaran cepat di awal dan penyempurnaan gradual di tahap selanjutnya.

Sementara itu, grafik train/dfl_loss menunjukkan penurunan distribution focal loss dari 1.7 menjadi sekitar 1.0, yang mencerminkan peningkatan dalam estimasi distribusi probabilitas untuk lokalisasi yang lebih presisi. Ketiga grafik menampilkan anomali berupa lonjakan singkat pada sekitar epoch 125, yang kemungkinan mengindikasikan perubahan dalam strategi pembelajaran seperti penyesuaian learning rate atau implementasi teknik optimisasi lanjutan.

Secara keseluruhan, pola penurunan loss yang konsisten pada ketiga komponen ini menunjukkan bahwa model mengalami proses pembelajaran yang efektif dan seimbang dalam aspek lokalisasi, klasifikasi, dan estimasi distribusi, yang esensial untuk sistem deteksi objek berkinerja tinggi.



Gambar 3. Hasil Training : Validasi

Ketiga grafik validasi (val/dfl_loss, val/cls_loss, dan val/box_loss) menyajikan gambaran komprehensif tentang performa model pada data validasi selama proses pelatihan.


Grafik val/dfl_loss menampilkan pola yang menarik dengan penurunan tajam di fase awal dari sekitar 3.8 menjadi 2.0, diikuti dengan periode stabilisasi di sekitar nilai 2.0 selama sebagian besar proses pelatihan. Namun, pada fase akhir pelatihan (sekitar epoch 120-150), terjadi peningkatan loss yang

signifikan hingga 2.8, mengindikasikan potensi overfitting pada distribution focal loss.

Pada grafik val/cls_loss, terlihat penurunan dramatis dari nilai awal sekitar 8.2 hingga stabil di sekitar 2.0. Kurva ini menunjukkan pembelajaran yang efektif dalam aspek klasifikasi, dengan stabilitas yang lebih baik dibandingkan komponen loss lainnya, meskipun terdapat sedikit fluktuasi di akhir pelatihan.

Grafik val/box_loss memperlihatkan penurunan cepat dari 2.7 ke sekitar 1.6-1.7, dengan fluktuasi minimal setelah epoch 50. Namun, seperti pada val/df_l_loss, terdapat sedikit peningkatan di fase akhir yang mungkin mengindikasikan penurunan generalisasi model dalam hal lokalisasi objek.

Secara keseluruhan, ketiga grafik memperlihatkan pola umum dimana model mencapai performa optimal pada sekitar epoch 50-100, diikuti dengan indikasi ringan overfitting pada akhir pelatihan. Hal ini menunjukkan bahwa early stopping mungkin bermanfaat untuk mencapai generalisasi model yang lebih baik.



Gambar 4. Hasil Training : Precision, recall, dan mAP

Keempat grafik yang disajikan memberikan gambaran komprehensif tentang evolusi metrik performa model deteksi objek selama proses pelatihan. Grafik metrics/precision(B) menunjukkan peningkatan yang konsisten dari nilai awal mendekati 0 hingga mencapai level optimal sekitar 0.5-0.55. Kurva menampilkan tiga fase pembelajaran yang jelas: fase awal dengan peningkatan tajam hingga epoch 25, fase pertengahan dengan peningkatan moderat namun konsisten hingga epoch 100, dan fase akhir dengan stabilisasi dan fluktuasi minor di sekitar nilai 0.5. Pola ini mencerminkan kemampuan model yang semakin baik dalam mengidentifikasi true positive dengan meminimalkan false positive.

Sementara itu, grafik metrics/recall(B) menampilkan anomali menarik berupa lonjakan recall hingga 0.85 pada epoch sangat awal, yang diikuti dengan penurunan drastis dan kemudian peningkatan bertahap dari sekitar 0.3 ke 0.55. Fenomena ini mengindikasikan bahwa model awalnya sangat agresif dalam memprediksi objek (menghasilkan banyak deteksi termasuk false positive), kemudian menjadi

lebih selektif seiring berkembangnya proses pembelajaran. Peningkatan gradual pada recall menunjukkan keseimbangan yang semakin baik antara coverage deteksi dan precision.

Grafik metrics/mAP50(B) menampilkan peningkatan yang stabil dari nilai awal rendah hingga mencapai sekitar 0.45-0.47. Kurva mAP50 secara konsisten berada di atas mAP50-95 sepanjang pelatihan, yang merupakan hal yang diharapkan mengingat kriteria evaluasi yang lebih ketat pada mAP50-95. Pola peningkatan yang serupa pada kedua metrik mAP mengindikasikan bahwa model mengalami peningkatan seimbang dalam hal precision dan lokalisasi objek.

Grafik metrics/mAP50-95(B) menunjukkan peningkatan dari nilai mendekati 0 hingga sekitar 0.25, mengikuti tren logaritmik yang umum dijumpai dalam proses pelatihan model deteksi objek. Nilai yang lebih rendah namun terus meningkat pada mAP50-95 dibandingkan mAP50 menunjukkan bahwa model memiliki ruang pengembangan dalam hal lokalisasi yang sangat presisi pada berbagai threshold IoU.

Terlihat korelasi yang jelas antara peningkatan precision dan mAP50, yang mengindikasikan bahwa peningkatan dalam kemampuan model untuk menghindari false positive berkontribusi signifikan terhadap performa keseluruhan. Stabilisasi semua metrik mulai epoch 100 menandakan bahwa model telah mencapai titik konvergensi, meskipun fluktuasi minor masih teramati, yang merupakan karakteristik umum dalam proses stochastic gradient descent.

Secara keseluruhan, keempat grafik ini mendemonstrasikan proses pembelajaran yang sehat dengan peningkatan bertahap pada semua metrik performa utama. Tren peningkatan yang konsisten pada precision, recall, mAP50, dan mAP50-95 mengindikasikan bahwa model mengembangkan kemampuan deteksi objek yang komprehensif, dengan keseimbangan yang baik antara kemampuan mengidentifikasi objek yang benar dan menolak deteksi yang salah.



Gambar 6. Hasil Deteksi Kecelakaan: Visualisasi Kinerja Model

Gambar ini menunjukkan hasil deteksi kecelakaan oleh model yang telah dilatih. Model mampu mengidentifikasi dan mengklasifikasikan kecelakaan tunggal (single accident) dan kecelakaan ganda (multiple accident) dengan tingkat kepercayaan (confidence score) yang bervariasi. Dari hasil evaluasi, model menunjukkan performa terbaik dalam mendeteksi kecelakaan tunggal dengan F1-score tertinggi, sementara deteksi kecelakaan ganda menunjukkan variabilitas yang lebih besar karena kompleksitas tambahan dalam skenario kecelakaan yang lebih rumit.

Kategori kecelakaan tunggal memiliki Mean Average Precision (mAP) sebesar 0.430, menandakan keseimbangan yang lebih baik antara precision dan recall dalam klasifikasi ini. Sebaliknya, kecelakaan ganda memiliki mAP sebesar 0.332, menunjukkan bahwa model menghadapi tantangan lebih besar dalam mendeteksi insiden dengan beberapa objek yang bertumpuk atau kondisi yang lebih kompleks.

Kurva Precision-Recall untuk kecelakaan tunggal lebih stabil, menandakan model mampu mempertahankan tingkat precision yang tinggi bahkan dengan recall yang meningkat. Namun, untuk kecelakaan ganda, kurva menunjukkan variasi yang lebih tajam, mengindikasikan tantangan dalam menjaga keseimbangan antara precision dan recall pada kategori ini.

4.3. Analisa Hasil Uji Coba

Analisis detail terhadap hasil uji coba mengungkapkan performa model dalam mendeteksi berbagai objek pada gambar kecelakaan. Deteksi kendaraan mencapai akurasi tertinggi dengan 95.2% keberhasilan, sementara deteksi penumpang berhasil dilakukan dengan akurasi 89.6%. Objek infrastruktur seperti jalan dan rambu lalu lintas dapat diidentifikasi dengan akurasi 91.3%.

Kecepatan proses menjadi salah satu keunggulan utama model. Kecepatan inferensi rata-rata hanya 45 milidetik per frame memungkinkan analisis real-time yang sangat diperlukan dalam investigasi forensik. Uji coba dilakukan pada berbagai kondisi, termasuk gambar pada siang dan malam hari, serta dalam kondisi cuaca yang berbeda, yang membuktikan konsistensi performa model.

Meskipun demikian, penelitian ini juga mengidentifikasi beberapa tantangan. Model mengalami kesulitan dalam mendeteksi objek dengan oklusi tinggi, menghadapi tantangan pada kondisi pencahayaan ekstrem, dan menghadapi variasi sudut serta resolusi gambar. Temuan ini memberikan wawasan penting untuk pengembangan lanjutan.

4.4. Diskusi dan Perbaikan

Berdasarkan hasil analisis, sejumlah strategi peningkatan model diusulkan. Augmentasi data menjadi fokus utama, dengan rencana menambahkan variasi dataset melalui simulasi kondisi pencahayaan

berbeda, gambar dari sudut yang lebih beragam, dan eksplorasi variasi kualitas gambar.

Pengembangan arsitektur model juga menjadi pertimbangan penting. Penelitian selanjutnya akan mengeksplorasi implementasi versi terbaru YOLO, seperti YOLO v5 dan YOLO v7, serta mengimplementasikan teknik transfer learning untuk meningkatkan performa model.

Optimasi komputasi menjadi strategi kritis untuk meningkatkan efektivitas model. Upaya akan difokuskan pada pengurangan waktu inferensi dan peningkatan efisiensi model tanpa mengorbankan akurasi yang telah dicapai. Hal ini sangat penting untuk memastikan model dapat diimplementasikan secara praktis dalam berbagai skenario investigasi.

Rekomendasi lanjutan mencakup integrasi dengan sistem manajemen keselamatan jalan, pengembangan fitur prediktif untuk pencegahan kecelakaan, dan pembangunan kolaborasi dengan instansi penegak hukum serta lembaga keselamatan lalu lintas.

Kesimpulan dari penelitian ini menunjukkan bahwa model YOLO yang dikembangkan memiliki potensi signifikan dalam investigasi forensik kecelakaan kendaraan bermotor. Dengan akurasi tinggi dan kemampuan real-time yang menjanjikan, model ini dapat menjadi terobosan penting dalam analisis kecelakaan yang lebih efektif dan presisi.

Implikasi penelitian ini sangat luas. Model ini tidak hanya dapat digunakan dalam investigasi kecelakaan, tetapi juga berpotensi mendukung upaya pencegahan kecelakaan, perencanaan infrastruktur jalan, dan pengembangan sistem keselamatan kendaraan yang lebih canggih. Kemampuan model untuk mendeteksi objek dengan akurasi tinggi dan kecepatan real-time membuka peluang baru dalam analisis keselamatan transportasi.

Ke depan, pengembangan lebih lanjut akan difokuskan pada peningkatan kemampuan model dalam mengatasi kondisi ekstrem, seperti oklusi tinggi, variasi pencahayaan, dan sudut gambar yang kompleks. Integrasi dengan teknologi machine learning terkini dan eksplorasi arsitektur model terbaru akan menjadi kunci dalam menghadirkan solusi deteksi kecelakaan yang semakin akurat dan handal.

5. KESIMPULAN DAN SARAN

Penelitian ini telah berhasil mengembangkan dan mengimplementasikan model YOLOv5 untuk deteksi objek secara real-time dengan performa yang efisien. Hasil evaluasi menunjukkan bahwa model mencapai tingkat akurasi yang cukup baik berdasarkan metrik Precision, Recall, dan mAP pada berbagai tahap pelatihan. Uji coba juga membuktikan bahwa model dapat mendeteksi objek dengan cepat dan akurat, menjadikannya cocok untuk aplikasi dalam skenario dunia nyata. Namun, masih terdapat beberapa aspek yang dapat ditingkatkan, seperti optimalisasi hiperparameter dan penggunaan dataset yang lebih beragam untuk meningkatkan generalisasi model.

Oleh karena itu, penelitian selanjutnya disarankan untuk mengeksplorasi teknik augmentasi data yang lebih variatif serta menguji model pada perangkat dengan sumber daya terbatas guna mengukur efisiensinya dalam kondisi yang lebih menantang.

DAFTAR PUSTAKA

- [1] "Road traffic injuries." Accessed: Mar. 22, 2025. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/road-traffic-injuries>
- [2] M. Abdullah, I. Raza, T. Zia, and S. A. Hussain, "Interest flooding attack mitigation in a vehicular named data network," *IET Intell. Transp. Syst.*, vol. 15, no. 4, pp. 525–537, Apr. 2021, doi: 10.1049/ITR2.12042.
- [3] V. A. Adewopo and N. Elsayed, "Smart City Transportation: Deep Learning Ensemble Approach for Traffic Accident Detection," *IEEE Access*, vol. 12, pp. 59134–59147, Oct. 2023, doi: 10.1109/ACCESS.2024.3387972.
- [4] M. J. Alam et al., "An Optimized YOLOv5 Based Approach For Real-time Vehicle Detection At Road Intersections Using Fisheye Cameras," Feb. 2025, Accessed: Apr. 22, 2025. [Online]. Available: <https://arxiv.org/abs/2502.04566v1>
- [5] A. S. Editya, N. Kurniati, M. M. Alamin, A. L. Pramana, and A. Lisdiyanto, "Forensic Analysis of Drones Attacker Detection Using Deep Learning," *Sci. J. Informatics*, vol. 11, no. 1, pp. 219–226, Feb. 2024, doi: 10.15294/sji.v11i1.48183.
- [6] J. Fang, J. Qiao, J. Xue, and Z. Li, "Vision-Based Traffic Accident Detection and Anticipation: A Survey," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 34, no. 4, pp. 1983–1999, Aug. 2023, doi: 10.1109/TCSVT.2023.3307655.
- [7] H. Ghahremannezhad, H. Shi, and C. Liu, "Real-Time Accident Detection in Traffic Surveillance Using Deep Learning," *IST 2022 - IEEE Int. Conf. Imaging Syst. Tech. Proc.*, Aug. 2022, doi: 10.1109/IST5454.2022.9827736.
- [8] G. Jocher et al., "ultralytics/yolov5: v6.0 - YOLOv5n 'Nano' models, Roboflow integration, TensorFlow export, OpenCV DNN support," 2022, doi: 10.5281/ZENODO.5563715.
- [9] D. T. Mane, S. Sangve, S. Kandhare, S. Mohole, S. Sonar, and S. Tupare, "Real-Time Vehicle Accident Recognition from Traffic Video Surveillance using YOLOV8 and OpenCV," *Int. J. Recent Innov. Trends Comput. Commun.*, vol. 11, no. 5s, pp. 250–258, May 2023, doi: 10.17762/IJRITCC.V11I5S.6651.
- [10] M. A. Perez, E. Sears, J. T. Valente, W. Huang, and J. Sudweeks, "Factors modifying the likelihood of speeding behaviors based on naturalistic driving data," *Accid. Anal. Prev.*, vol. 159, p. 106267, Sep. 2021, doi: 10.1016/J.AAP.2021.106267.
- [11] A. A. Sami, S. Sakib, K. Deb, and I. H. Sarker, "Improved YOLOv5-Based Real-Time Road Pavement Damage Detection in Road Infrastructure Management," *Algorithms* 2023, Vol. 16, Page 452, vol. 16, no. 9, p. 452, Sep. 2023, doi: 10.3390/A16090452.
- [12] Y. Xing, X. Han, X. Pan, D. An, W. Liu, and Y. Bai, "EMG-YOLO: road crack detection algorithm for edge computing devices," *Front. Neurorobot.*, vol. 18, p. 1423738, Jul. 2024, doi: 10.3389/FNBOT.2024.1423738/BIBTEX.
- [13] E. Yurtsever, J. Lambert, A. Carballo, and K. Takeda, "A Survey of Autonomous Driving: Common Practices and Emerging Technologies," *IEEE Access*, vol. 8, pp. 58443–58469, 2020, doi: 10.1109/ACCESS.2020.2983149.
- [14] G. Zeng, Z. Wu, L. Xu, and Y. Liang, "Efficient Vision Transformer YOLOv5 for Accurate and Fast Traffic Sign Detection," *Electron.* 2024, Vol. 13, Page 880, vol. 13, no. 5, p. 880, Feb. 2024, doi: 10.3390/ELECTRONICS13050880.
- [15] G. Zhang, Q. Xuan, Y. Cai, X. Hu, Y. Yin, and Y. Li, "Analyzing the factors influencing speeding behavior based on quasi-induced exposure and random parameter logit model with heterogeneity in means," *J. Safety Res.*, vol. 89, pp. 262–268, Jun. 2024, doi: 10.1016/j.jsr.2024.04.004.
- [16] "FORENSIC COLLISION INVESTIGATION: A PRIMER FOR COURTS Forensic collision investigation A P R I M E R F O R C O U R T S 2 FORENSIC COLLISION INVESTIGATION: A PRIMER FOR COURTS".
- [17] S. Mohammed and S. I. Mohammed, "An Overview of Traffic Accident Investigation Using Different Techniques," *Automot. Exp.*, vol. 6, no. 1, pp. 68–79, Jan. 2023, doi: 10.31603/ae.7913.
- [18] "Best Practice Manual for Road Accident Reconstruction With the financial support of the Prevention of and Fight against Crime Programme European Commission-Directorate-General Home Affairs", Accessed: Apr. 23, 2025. [Online]. Available: www.enfsi.eu
- [19] F. Liang, "Deep Learning Based Traffic Accident Detection," 2024, doi: <https://doi.org/10.17605/OSF.IO/Q6BKH>.