

Tersedia online di www.journal.unipdu.ac.id
UnipduHalaman jurnal di www.journal.unipdu.ac.id/index.php/teknologi**Research article****Deteksi Objek Kecelakaan Pada Kendaraan Roda Empat Menggunakan Algoritma YOLOv5**Muhamad Dio Riza Pratama ^{a,*}, Bayu Priyatna ^b, Shofa Shofiah Hilabi ^c, April Lia Hananto ^d^{a,b,c,d} Program Studi Sistem Informasi, Universitas Buana Perjuangan Karawang, Indonesiaemail: ^{a,*} si19.muhamadpratama@mhs.ubpkarawang.ac.id

*Korespondensi

Dikirim 05 Desember 2022; Direvisi 10 Desember 2022; Diterima 17 Desember 2022; Diterbitkan 20 Desember 2022

Abstrak

Kecelakaan lalu lintas khususnya kendaraan roda empat merupakan insiden yang sering terjadi dan mengakibatkan banyak kerugian bagi siapa saja yang mengalaminya. CCTV adalah alat yang digunakan untuk memantau volume kendaraan tetapi tidak bisa untuk mendeteksi kecelakaan. Oleh sebab itu tujuan pada penelitian ini adalah membangun model untuk mendeteksi kecelakaan ataupun dampak kerusakan kendaraan roda empat melalui data *angle* insiden dari CCTV serta pendekatan *computer vision* dengan *you only look once* (YOLO) yang dikenal sebagai algoritma deteksi objek yang memiliki akurasi cukup tinggi jika dibandingkan dengan beberapa algoritma yang ada. Data yang diambil dan digunakan pada penelitian ini memiliki jumlah data latih sebanyak 1146 gambar serta data uji sebanyak 109 gambar diperoleh akurasi model dengan mAP 90,2% dan dilakukan uji data dengan input video diperoleh mAP 84% lalu pada pengujian data acak diperoleh akurasi mAP 51,5%.

Kata Kunci: kecelakaan lalu lintas, cctv, computer vision, you only look once (YOLO), deteksi objek**Car Vehicle Accident Object Detection Using YOLOv5 Algorithm****Abstract**

Traffic accidents, especially four-wheeled vehicles, are incidents that often occur and result in many losses for anyone who experiences them. CCTV is a tool used to monitor vehicle volume but cannot detect accidents. Therefore the aim of this study is to build a model to detect accidents or the impact of damage to four-wheeled vehicles through incident angle data from CCTV and a computer vision approach with you only look once (YOLO) known as the object detection algorithm which has quite high accuracy when compared with some existing algorithms. The data taken and used in this study has a total of 1146 training data images and 109 test data obtained model accuracy with 90.2% mAP and data testing with video input obtained 84% mAP then on random data testing obtained 51.5% mAP accuracy.

Keywords: traffic accident, cctv, computer vision, you only look once (YOLO), object detection**Untuk mengutip artikel ini dengan APA Style:**Pratama, M.D.R., Priyatna, B., Hilabi, S.S., Hananto, A.L. (2022). Deteksi Objek Kecelakaan Pada Kendaraan Roda Empat Menggunakan Algoritma YOLOv5. TEKNOLOGI: Jurnal Ilmiah Sistem Informasi, v(n), 15-26. <https://doi.org/10.26594/teknologi.v12i2.3260>© 2022 Penulis. Diterbitkan oleh Program Studi Sistem Informasi, Universitas Pesantren Tinggi Darul Ulum. Ini adalah artikel open access di bawah lisensi CC BY-NC-NA (<https://creativecommons.org/licenses/by-nc-sa/4.0/>).**1. Pendahuluan**

Kecelakaan lalu lintas adalah sebuah insiden yang disebabkan pada secara sengaja atau tidak sengaja dan tidak bisa diprediksi kapan datangnya serta melibatkan beberapa hal misalnya kendaraan lain, kondisi jalan, cuaca dll (Ardelia et al., 2018). Faktor penyebab kecelakaan lalu lintas dibagi menjadi tiga bagian yaitu, akibat faktor manusia, faktor kendaraan, dan faktor cuaca atau lingkungan (Oktarinda et al., 2022). Badan Pusat Statistik (BPS) menunjukkan bahwa pada periode 2013-2017, total kecelakaan lalu lintas tetap stabil di kisaran 90-100 ribu, dengan menduduki posisi ketiga sebagai penyebab kematian di Indonesia. Hal yang harus digaris bawahi adalah bahwa korban kecelakaan tidak hanya korban yang meninggal pada saat kejadian, yang paling utama adalah korban dengan luka berat dan luka ringan akibat kecelakaan lalu lintas, yang bila tidak segera mendapat pertolongan medis dan keselamatan dengan segera akan mengakibatkan kematian atau cacat seumur hidup. Terjadinya kecelakaan roda empat di jalan tol yang terbilang sebagai jalan bebas hambatan juga terbilang cukup besar. Jasa Marga menyebutkan terdapat 887 kecelakaan di jalan tol sepanjang 2018, dengan faktor *human error* menjadi faktor utama setelah di evaluasi melalui pemantauan CCTV (Afif et al., 2020).

Penggunaan CCTV sebagai alat pemantau operasi jalan tol juga memiliki peranan yang besar dalam kelancaran operasional di jalan tol dan sebagai sarana penyedia layanan pengiriman informasi. Contohnya adalah terjadinya kecelakaan dan terpantau oleh CCTV, maka petugas pemantau CCTV akan memberikan laporan bahwa terjadi kecelakaan. Untuk mempercepat peringatan terjadinya kejadian, maka pemecahan yang diberikan pada penelitian ini adalah dengan memberikan teknologi komputerisasi melalui deteksi objek (Amit et al., 2021) dengan *computer vision* (Turtiainen et al., 2020). *Computer vision* dibangun dengan jaringan algoritma *Convolution neural network* (CNN) (Punjab et al., n.d., 2018) yang bekerja dengan konsep dimana komputer berusaha melihat apa yang manusia lihat, kemudian belajar untuk mengenali objek apa saja yang ada didalamnya (Gour, 2019). Kemajuan teknologi *computer vision* yang berkembang dengan cepat memudahkan semua orang untuk menguji teknologi ini. Ada banyak algoritma yang bisa digunakan untuk mendeteksi objek, mulai dari R-CNN, Mediapipe dan YOLO (Aini et al., 2021; Ji et al., 2022; F. Zhang et al., 2020). Semua algoritma ini bisa digunakan dan dibuat dengan *opensource*.

Oleh sebab itu dibuat percobaan pendeteksian kecelakaan lalu lintas menggunakan YOLO versi kelima (YOLOv5) (Do Thuan, 2021) serta diharapkan dapat disambungkan dengan kamera atau CCTV dan bisa mendeteksi mulai dari kecelakaan tunggal ataupun tidak tunggal. Terlebih lagi teknologi ini sangat membantu apabila terjadi kecelakaan lalu lintas pada lokasi yang sepi dan jauh dari lingkungan masyarakat. Diharapkan bisa membantu disaat terjadinya kecelakaan oleh pihak-pihak yang terkait.

2. State of the Art

Penelitian yang terkait dengan pengembangan deteksi objek kecelakaan lalu lintas telah dilakukan oleh peneliti sebelumnya. Ijjina, E.P., (2019) melakukan penelitian deteksi objek menggunakan R-CNN (Lokanath et al., 2017) dengan metode pengambilan dataset yang sama, yaitu melalui CCTV (Ijjina et al., 2019). *Mask Region-based Convolutional Neural Networks* (Mask R-CNN) (Q. Zhang et al., 2020) dipilih sebagai algoritma pada penelitian ini dikarenakan peformanya pada saat itu terbilang yang terbaik karena telah diuji banding dengan berbagai algoritma serupa dan memiliki mAP rata – rata di 89,9%. Penelitian ini menghasilkan akurasi deteksi objek sebesar 71% dan bisa mendeteksi objek kecelakaan lalu lintas dengan baik.

2.1. Computer Vision

Computer vision sendiri merupakan cabang dari kecerdasan buatan yang membuat komputer terlihat seperti manusia. *Computer vision* pada dasarnya mencoba meniru cara kerja penglihatan manusia (*human vision*) (V., 2019). Penglihatan manusia sebenarnya cukup kompleks. Manusia mempersepsikan objek dengan penglihatan (mata), dan objek gambar diteruskan ke otak untuk interpretasi. Hasil interpretasi ini dapat digunakan untuk pengambilan keputusan (Voulodimos et al., 2018).

Cara kerja *computer vision* berdasarkan fungsinya secara garis besar dibagi menjadi tiga bagian:

1. *Preprocessing* gambar dimana proses memperoleh memanipulasi data gambar dari data mentah menuju data yang siap diproses kedalam proses komputasi.
2. Melakukan teknik komputasi untuk memproses atau memodifikasi data gambar berdasarkan piksel demi piksel.
3. Menganalisis dan menginterpretasikan gambar menggunakan hasil pemrosesan untuk tujuan tertentu seperti: deteksi objek, pengontrol di manufaktur, dll (Pambudi et al., 2012).

2.2. Convolution Neural Network (CNN)

Convolution Neural Network (CNN) merupakan salah satu jenis dari jaringan syaraf tiruan yang digunakan dalam mengolah data gambar. CNN bekerja dengan mengubah gambar kedalam array melalui nilai setiap piksel lalu memberikan perhitungan matriks yang disebut dengan konvolusi (Li et al., 2020). Pada perkembangannya penggunaan CNN semakin dipermudah dengan teknik *transfer learning* dimana kita hanya perlu memakai algoritma yang sudah tersedia untuk dimasukkan input data sesuai dengan kebutuhan. Algoritma CNN ada berbagai macam dan diperuntukkan untuk kebutuhan yang berbeda – beda mulai dari deteksi objek, pengenalan objek, analisis dokumen, klasifikasi gambar, klasifikasi video, dll (Wang et al., 2019).

2.3. Metode Deteksi Objek

Metode deteksi objek adalah salah satu cabang dari *computer vision* yang digunakan untuk menemukan objek dalam gambar menggunakan *bounding box* dan mengklasifikasikan objek ke dalam kelas tertentu (Dvornik et al., 2018). Metrik yang paling relevan dan umum digunakan untuk mengukur performa algoritma pendeteksian objek adalah *mean average precision* (mAP) (Diwan et al., 2022). Deteksi objek mengambil algoritma dari *convolution*

neural network dan yang paling populer saat ini adalah *You Only Look Once (YOLO)* dengan versi terbarunya YOLOv5 dan algoritma ini yang akan digunakan pada penelitian ini

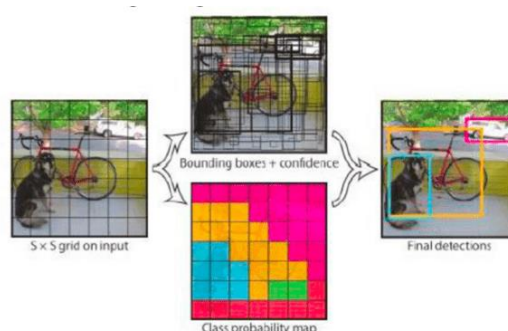
2.4. *You Only Look Once (YOLO)*

You Only Look Once (YOLO) adalah metode pendeteksian objek yang dikembangkan oleh Joseph Redmon yang menggunakan algoritma CNN untuk mendeteksi objek (Plastiras et al., 2018). Redmon membuat arsitektur model yang terinspirasi dari model arsitektur GoogleNet (Kim et al., 2019). Dengan itu dia bisa membuat model algoritma deteksi objek yang memiliki kecepatan training yang melebihi algoritma sebelumnya.

Ilustrasi YOLO (Redmon et al., 2015) dapat dilihat pada Gambar 1. Konsepnya adalah dengan membagi dua gambar data input kedalam $S \times S$ grid cell. Setiap cell akan memprediksikan nilai *confidence* dan juga memprediksi banyak *bounding box*. Jika tidak ada objek didalam cell tersebut, maka nilai *confidence* akan menjadi nol. Setelah nilai *confidence* pada setiap cell didapatkan maka nilainya dibandingkan dengan nilai *intersection over union (IoU)* untuk mendapatkan *bounding box* prediksi disetiap kelas yang ada dengan perhitungan (Liu et al., 2020).

$$\text{Confidence} = \text{Pr}(\text{Object}) \times \text{IoU}(\text{GT}, \text{Pred})$$

Dimana Pr = Probability, IoU = Intersection over Union, GT = Ground Truth



Gambar 1. Ilustrasi You Only Look Once (Redmon et al., 2015)


Algoritma 1. Pseudocode You Only Look Once (YOLO)

Input: Gambar dataset

Output: pred sebagai prediksi dari bounding box

1. **for** I in gambar **Do**:
2. Pisahkan gambar menjadi bagian $S \times S$, $B(5)$, C **Do**:
3. $B^*5 \leftarrow \text{confidence} = \text{Pr}(\text{object} \times \text{IoU}(\text{GT}, \text{Pred}))$
4. $C \leftarrow \text{class probabilities} \in [0,1]$
5. **return** pred

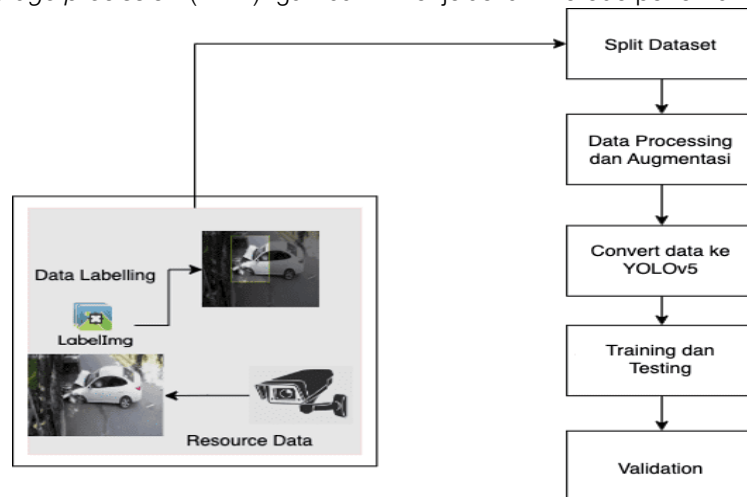
Pada penelitian ini versi YOLO yang digunakan adalah original model YOLOv5 (Jung et al., 2022). Versi ini merupakan YOLO generasi ke-5 yang diterbitkan pada Mei 2020. Alasan dipilihnya versi kelima adalah kemudahan dalam konfigurasinya dan bisa terhubung langsung dengan Roboflow untuk keperluan *data processing* dan *data augmentation* (Lin et al., 2022).



Gambar 2. Perbandingan Peforma YOLOv5 (Lin et al., 2022)

3. Metode Penelitian

Pada penelitian ini digunakan data latih sebanyak 1310 gambar dimana nantinya data tersebut akan di *split* menjadi *data training*, *data testing* dan *data validation*. Metode yang digunakan adalah objek deteksi yang berdasarkan konsep kecerdasan buatan dimana komputer diberi pelatihan agar bisa melihat seperti yang manusia lihat atau disebut dengan *computer vision*. Dibangun dengan algoritma *Convolutional Neural Network* (CNN), model algoritma yang digunakan adalah YOLOv5 untuk objek deteksi. metrik yang digunakan pada proses deteksi objek adalah *mean average precission* (mAP). gambar 1 menjelaskan metode penelitian yang dimaksud:



Gambar 1. Gambaran umum metode penelitian yang diusulkan

3.1. Pembuatan dataset

Pembuatan dataset dilakukan dengan memilih data kecelakaan melalui video CCTV. Video yang dipilih akan diubah menjadi *frame by frame* dan setelah itu maka dilakukan proses pembuatan label *bounding box* pada setiap data gambar menggunakan *tools* LabelImg dari setiap gambar yang diberi label akan disematkan kelas *accident* sebagai tanda bahwa proses deteksi dilakukan maka label bertuliskan *accident* akan muncul. Diperoleh data latih sebanyak 1146 gambar serta data uji sebanyak 109 gambar dan untuk validasi menggunakan data gambar sebanyak 55.



Gambar 3. Dataset yang telah diberikan label

3.2. Data Preprocessing dan Augmentation

Pada setiap gambar data yang dimiliki masih memiliki ukuran *size* yang acak, oleh sebab itu dilakukan proses preprocessing dengan mengubah ukurannya menjadi 416x416 dan ditambah *grayscale* fitur yang bertujuan untuk mengoptimalkan waktu *training* dan meningkatkan performa dengan mentransformasi seluruh gambar. Proses Augmentation berfungsi untuk membuat dan memperkaya gambar yang dimiliki dan dibuat ulang dengan versi terbaru dari setiap gambar. Gambar yang di augmentasi pada dataset ini adalah dengan menambahkan *90° Rotate*, *Brightness*, *BlurUp to 0.75px* dan *NoiseUp to 5% of pixels*.



Gambar 4. Penambahan dan perubahan data setelah proses *preprocessing* dan *augmentation*

3.3. Konversi data ke YOLOv5

Proses konversi data ke YOLOv5 menggunakan layanan bernama Roboflow. Roboflow adalah *framework* pengembang *computer vision* untuk pengumpulan data yang lebih baik ke prapemrosesan, dan teknik pelatihan model. Roboflow memiliki kumpulan data publik yang tersedia bagi pengguna dan juga memiliki akses bagi pengguna untuk mengunggah data khusus mereka sendiri. Roboflow juga memiliki fitur untuk menkonversi data yang sudah diberi label untuk diproses kedalam YOLOv5.

3.4. Training dan Testing

Proses *training data* atau pelatihan data dilakukan melalui kernel Google Collaboratory dengan menginstall beberapa *dependencies* utama yaitu YOLOv5 dan framework PyTorch serta proses pelatihan data dilakukan dengan *hardware GPU accelerator*. Proses awal YOLOv5 memerlukan format khusus untuk custom dataset berupa file yaml. Proses training data menggunakan parameter *learning rate* = 0.01 dan *momentum* = 0.9 serta dilakukan *callback* untuk menghentikan proses training apabila nilai loss meningkat selama prosesnya. Pseudocode pada *training* dan *testing* bisa dilihat dibawah ini.

Algoritma 2. Pseudocode training dan testing	
Input:	N sebagai Image dataset
	T sebagai Testing dataset
Output:	Pr sebagai Target prediction
	mAP sebagai metric of prediction
1.	install dependencies dan requirements pada google collaboratory
2.	dari dataset yang telah dimiliki import kedalam roboflow
3.	merubah format kedalam YOLOv5
4.	mengatur parameter learning rate = 0.01, momentum = 0.9, batch = 16, epochs = 500
5.	for i to N do :
6.	menghitung nilai confidence setiap boxes
7.	menghitung nilai error boxes menggunakan IoU, treshold = 0.5
8.	menghitung confidence error pada setiap boxes
9.	membandingkan confidence error pada model (X, Y) dengan $T(X_1, Y_1)$
10.	menghitung error model training dengan mencari <i>recall</i> dan <i>precision</i>
11.	find AP berdasarkan recall dan precision
12.	$AP \leftarrow \sum_{k=0}^{k=n-1} [recall(k) - recall(k+1)] * precision(k)$
13.	didapatkan nilai mAP pada Pr
14.	$Pr \leftarrow 1/n \sum_{k=1}^{k=n} [AP]_k$
15.	mengatur training model sampai target mAP setinggi mungkin dan loss kecil
16.	memasukkan loss function kedalam model training
17.	if loss function terus menurun Then
18.	lanjutkan training
19.	if loss function terus meningkat = 5 iterasi Then
20.	break

Setelah melakukan proses *training data*, maka selanjutnya adalah melakukan *data validation* atau validasi data. Tahapan ini dilakukan untuk mengetahui bagaimana hasil dari proses *training* yang dilakukan dengan data yang nyata. Proses validasi data diawali dengan *splitting dataset* kedalam tiga folder yang berbeda. Dari dataset diambil sekitar 7% data kedalam data validasi dan ditempatkan kedalam folder data yang terpisah antara data *training*, *testing* dan *validation*. Untuk proses *data testing* ini akan dipersiapkan sejumlah gambar, di mana pada tahap ini akan disiapkan 55 gambar uji diluar data latih dan data validasi. Dan diperoleh akurasi mAP sebesar 86% dalam mendeteksi objek kecelakaan lalu lintas.



Gambar 5. Akurasi yang didapatkan pada data testing

3.5. Metrik Evaluasi

Tahapan pengujian akurasi diperlukan sebuah metrik untuk menilai kualitas dari model yang telah dibangun. Metrik evaluasi juga digunakan untuk mendapatkan nilai akurasi dari data yang telah di training sebelumnya dan dicocokkan dengan data baru. Adapaun metrik evaluasi utama yang digunakan adalah *Mean Average Precision* (mAP) (Henderson et al., 2017). Metrik ini adalah yang populer digunakan dalam menghitung akurasi suatu objek deteksi. Nilai mAP didapatkan melalui *average precision*, dimana *Average Precision* (AP) (Oksuz et al., 2018) didapatkan dari persamaan sebagai berikut:

$$precision = \frac{TP}{TP + FP} \quad recall = \frac{TP}{TP + FN}$$

$$AP = \sum_{k=0}^{k=n-1} [recall(k) - recall(k+1)] * precision(k)$$

Keterangannya adalah:

TP = True Positive, adalah ketika model prediksi menilai data sebagai benar, dan aktualnya adalah benar.

TN = True Negative, adalah ketika model prediksi menilai data sebagai salah, dan aktualnya adalah salah.

FP = False Positive, adalah ketika model prediksi menilai data sebagai benar, dan aktualnya adalah salah.

FN = False Negative, adalah ketika model prediksi menilai data sebagai salah dan aktualnya adalah benar.

Cara untuk mendapatkan nilai TP, TN, FP dan FN pada deteksi objek adalah dengan menghitung *Intersection of Union* (IoU) (Rezatofighi et al., 2019). Perhitungannya diperoleh dengan mengukur irisan antara *bounding box* asli dengan *bounding box* hasil prediksi. Jika nilai IoU > 0.5 maka bernilai *True Positive* sedangkan jika nilai IoU < 0.5 maka bernilai *False Positive*. Ilustrasinya dapat dilihat pada gambar 6.

$$IoU = \frac{\text{area of overlap}}{\text{area of union}} = \frac{\text{area of intersection}}{\text{area of union}}$$

Gambar 6. Ilustrasi perhitungan Intersection of Union (IoU)

Setelah diperoleh nilai *Average Precision (AP)* maka untuk mendapatkan *Mean Average Precision (mAP)* adalah dengan membagi nilai AP dari setiap jumlah kelas pada data dan dihitung melalui nilai threshold. Berikut adalah cara menghitung mAP.


$$mAP = \frac{1}{n} \sum_{k=1}^{k=n} AP_k$$

4. Hasil dan Pembahasan

Penelitian ini dilaksanakan dengan menggunakan dataset *angle footage* dari CCTV dengan pendekatan *Convolutional Neural Network (CNN)* melalui *computer vision* dan model algoritma yang digunakan adalah *You Only Look Once (YOLO)* versi ke lima. YOLOv5 digunakan pada penelitian ini berhasil dijalankan untuk mendeteksi kecelakaan kendaraan roda empat. Dalam proses *training model*, *hyperparameter* yang digunakan adalah *learning rate* 0.01 dan *momentum* 0.9 serta iterasi maksimal 500 dengan *callback* apabila *mean average precision (mAP)* sudah tidak bisa naik selama 5 iterasi, maka proses *training* selesai.


4.1. Hasil Training

Proses *training* dapat dilihat melalui peningkatan akurasi *mean average precision* serta penurunan nilai *loss*. Semakin kecil nilai *loss* pada proses *training* maka semakin baik model dalam mendeteksi objek. Pada prosesnya, *training* berhenti pada iterasi ke 500 dan menghabiskan waktu *training* selama 4,5 jam. Grafik proses penurunan *loss* dapat dilihat pada gambar 7.



Gambar 7. Penurunan *loss* sampai iterasi ke-500

Peningkatan mAP juga terjadi pada setiap iterasi *training* dijalankan, pada prosesnya peningkatan mAP penurunan *loss* terjadi secara signifikan dan bersamaan sampai iterasi ke 500. Hal ini menunjukkan bahwa proses *training* berjalan dengan baik dalam melatih model deteksi objek.

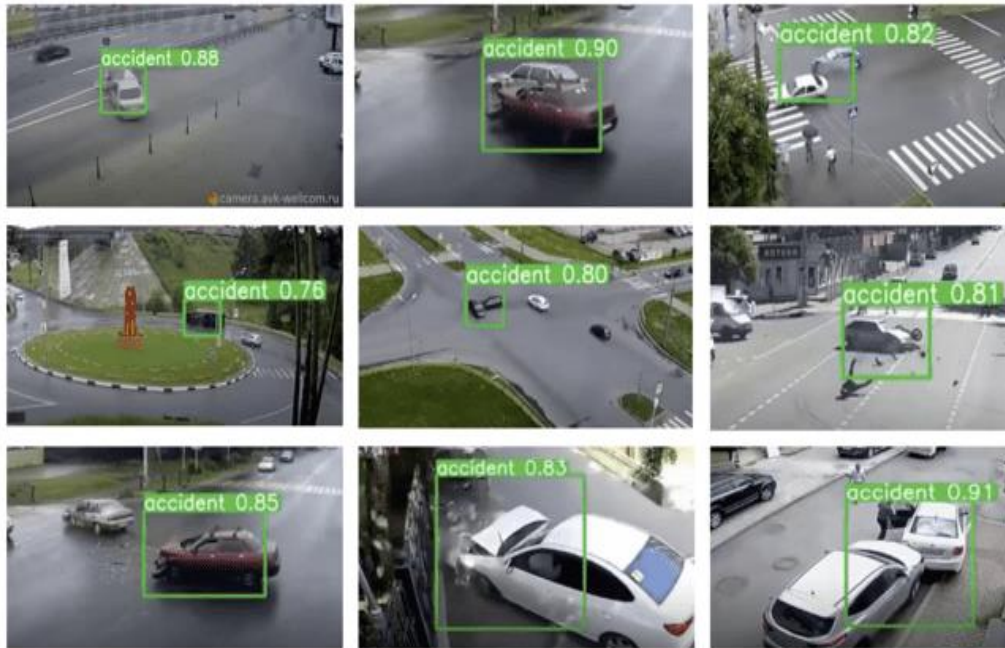


Gambar 8. Peningkatan akurasi sampai iterasi ke-500

4.2. Hasil Pengujian

Pengujian pada model dilakukan untuk mengetahui performa deteksi objek secara langsung dengan data yang nyata. Pengujian model atau biasa disebut dengan *model validation* adalah proses pengukuran model dengan

memberikan perhitungan terhadap segala bentuk kesalahan pada prediksi model. Pada saat proses *training* dilakukan juga teknik validasi yaitu *split validation* dengan membagi dataset secara acak dan memisahkan data menjadi 70% *data training*, 22% *data testing* dan 7% *data validation*. Selain melalui proses *training*, proses pengujian juga dilakukan dengan dua metode. Pertama adalah mengujinya langsung dengan input video CCTV dan menghasilkan output video yang sudah berisi prediksi deteksi kecelakaan kendaraan roda empat. Pengujian yang kedua adalah mengujinya dengan data acak dengan data yang bersumber dari internet. Hasil awal pada proses pengujian melalui proses *training* didapatkan nilai mAP 90,2%. Proses pengujian selanjutnya adalah dengan memberikan input video CCTV yang berisi kecelakaan kendaraan roda empat. Dan hasilnya adalah bisa dilihat pada gambar 9.



Gambar 9. Hasil deteksi pada pengujian input data video CCTV

Selanjutnya untuk proses pengujian menggunakan data acak dilakukan dengan memberikan input gambar kecelakaan yang berasal dari google images dan melihat hasil prediksi yang dilakukan oleh model deteksi objek. Hasil pengujian dapat dilihat pada gambar 10.



Gambar 10. Hasil deteksi pada pengujian data acak

Dari hasil tiga pengujian yang dilakukan didapatkan beragam hasil akurasi yang berbeda – beda. Akan tetapi, model objek deteksi bisa dikatakan bisa memprediksi kecelakaan walaupun akurasi yang diperoleh masih harus dikembangkan lagi. Hasil pengujian dapat dilihat pada Tabel 1.

Tabel 1. Hasil rata-rata mAP pada setiap pengujian

Pengujian	\bar{x} mAP
Split validation	0.902
Input video training	0.84
Data acak	0.515

5. Kesimpulan

Setelah dilakukan seluruh tahapan dari penelitian ini, mulai dari tahapan perancangan data, pelatihan data, validasi data dan juga analisa, dapat diambil kesimpulan bahwa mendeteksi objek pada kecelakaan lalu lintas melalui algoritma YOLOv5 dengan jumlah dataset 1146 gambar data training, data uji 109 gambar dan data validasi 55 gambar. Diperoleh mAP 90,2% serta dalam proses pengujian model yang dilakukan diperoleh hasil mAP 84% untuk pengujian yang dilakukan secara input video terhadap model objek deteksi dan diperoleh mAP 51,5% untuk pengujian yang dilakukan dengan cara memberikan input data acak. Dengan demikian, bisa dikatakan YOLOv5 dapat memberikan akurasi dan performa dengan baik untuk mendeteksi objek kecelakaan kendaraan roda empat. Diharapkan pada penelitian selanjutnya mampu mengembangkan metode dan kekurangan yang ada pada penelitian ini serta diharapkan mampu untuk mengimplementasikan sistem yang sudah dibuat kedalam bentuk berbagai macam *device* dengan tujuan dapat digunakan secara efektif dan membantu kemajuan ilmu teknologi *computer vision*.

6. Referensi

- Afif, M. M. S., & Rahman, A. (2020). Prediksi Keandalan Pengendara Mobil Terkait Drowsiness (Studi Kasus Pengendara Mobil di Jalan Tol Surabaya-Surakarta). *Jurnal Teknik ITS*, 8(2). doi: 10.12962/j23373539.v8i2.45249
- Aini, Q., Lutfiani, N., Kusumah, H., & Zahran, M. S. (2021). Deteksi dan Pengenalan Objek Dengan Model Machine Learning: Model Yolo. *CESS (Journal of Computer Engineering, System and Science)*, 6(2), 192. doi: 10.24114/cess.v6i2.25840
- Amit, Y., Felzenszwalb, P., & Girshick, R. (2021). Object Detection. *Computer Vision, January 2020*, 875–883. doi: 10.1007/978-3-030-63416-2_660
- Diwan, T., Anirudh, G., & Tembhurne, J. V. (2022). Object detection using YOLO: challenges, architectural successors, datasets and applications. *Multimedia Tools and Applications*. doi: 10.1007/s11042-022-13644-y
- Dvornik, N., Mairal, J., & Schmid, C. (2018). Modeling visual context is key to augmenting object detection datasets. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11216 LNCS, 375–391. doi: 10.1007/978-3-030-01258-8_23
- EVOLUTION OF YOLO ALGORITHM AND YOLOV5: THE STATE-OF-THE-ART OBJECT DETECTION ALGORITHM. (n.d.).
- Gour, D. (2019). *Optimized-YOLO : Algorithm for CPU to Detect Road Traffic Accident and Alert System*. 8(09), 160–163.
- Henderson, P., & Ferrari, V. (2017). End-to-end training of object class detectors for mean average precision. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 10115 LNCS, 198–213. doi: 10.1007/978-3-319-54193-8_13
- Ijjina, E. P., Chand, D., Gupta, S., & Goutham, K. (2019). Computer Vision-based Accident Detection in Traffic Surveillance. *2019 10th International Conference on Computing, Communication and Networking Technologies, ICCCNT 2019*. doi: 10.1109/ICCCNT45670.2019.8944469
- Ji, W., Pan, Y., Xu, B., & Wang, J. (2022). A Real-Time Apple Targets Detection Method for Picking Robot Based on ShufflenetV2-YOLOX. *Agriculture (Switzerland)*, 12(6), 1–23. doi: 10.3390/agriculture12060856
- Jung, H. K., & Choi, G. S. (2022). Improved YOLOv5: Efficient Object Detection Using Drone Images under Various Conditions. *Applied Sciences (Switzerland)*, 12(14). doi: 10.3390/app12147255
- Kim, J. H., Seo, S. Y., Song, C. G., & Kim, K. S. (2019). Assessment of Electrocardiogram Rhythms by GoogLeNet Deep Neural Network Architecture. *Journal of Healthcare Engineering*, 2019. doi: 10.1155/2019/2826901
- Li, Z., Yang, W., Peng, S., & Liu, F. (2020). *CNN survey*.
- Lin, Q., Ye, G., Wang, J., & Liu, H. (2022). RoboFlow: a Data-centric Workflow Management System for Developing AI-enhanced Robots. *Proceedings of the 5th Conference on Robot Learning*, 164(CoRL), 1789–1794.
- LINTAS, T. (2018). *Studi Peraturan Kapolri No 15 Tahun 2013 Tentang Penanganan Kecelakaan Lalu Lintas Di Kantor Kepolisian Resor Balikpapan*. 6(15), 411–424. Retrieved from https://ejournal.ip.fisip-unmul.ac.id/site/wp-content/uploads/2018/02/Ardelia_02-02-18-09-23-27.pdf
- Liu, G., Nouaze, J. C., Mbouembe, P. L. T., & Kim, J. H. (2020). YOLO-tomato: A robust algorithm for tomato detection based on YOLOv3. *Sensors (Switzerland)*, 20(7), 1–20. doi: 10.3390/s20072145
- Lokanath, M., Kumar, K. S., & Keerthi, E. S. (2017). Accurate object classification and detection by faster-RCNN. *IOP Conference Series: Materials Science and Engineering*, 263(5). doi: 10.1088/1757-899X/263/5/052028

- National Institute of Technology (Punjab, I., National Institute of Technology (Punjab, I. D. of C. S. & E., Institute of Electrical and Electronics Engineers. Delhi Section, & Institute of Electrical and Electronics Engineers. (n.d.). *ICSCCC 2018 : International Conference on Secure Cyber Computing and Communication : December 15-17, 2018*.
- Oksuz, K., Cam, B. C., Akbas, E., & Kalkan, S. (2018). Localization recall precision (LRP): A new performance metric for object detection. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11211 LNCS, 521–537. doi: 10.1007/978-3-030-01234-2_31
- Oktarinda, E., Prihutomo, N. B., & Maulani, E. O. (2022). Analisis Pengaruh Kendaraan Odol Terhadap Tingkat Kecelakaan Di Jalan Tol. *Construction and Material Journal*, 4(1), 49–57. doi: 10.32722/cmj.v4i1.4151
- Pambudi, W. S., & Tomponu, A. N. (2012). Aplikasi Sensor Vision untuk Deteksi MultiFace dan Menghitung Jumlah Orang. *Seminar Nasional Teknologi Informasi & Komunikasi Terapan 2012 (Semantik 2012)*, 2012(Semantik), 26–33.
- Plastiras, G., Kyrkou, C., & Theocharides, T. (2018). Efficient convnet-based object detection for unmanned aerial vehicles by selective tile processing. *ACM International Conference Proceeding Series*. doi: 10.1145/3243394.3243692
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2015). *You Only Look Once: Unified, Real-Time Object Detection*. Retrieved from <http://arxiv.org/abs/1506.02640>
- Rezatofighi, H., Tsoi, N., Gwak, J., Sadeghian, A., Reid, I., & Savarese, S. (2019). Generalized intersection over union: A metric and a loss for bounding box regression. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2019-June*, 658–666. doi: 10.1109/CVPR.2019.00075
- Turtiainen, H., Costin, A., Lahtinen, T., Sintonen, L., & Hamalainen, T. (2020). *Towards large-scale, automated, accurate detection of CCTV camera objects using computer vision. Applications and implications for privacy, safety, and cybersecurity. (Preprint)*.
- V., Dr. S. (2019). Computer Vision for Human-Machine Interaction-Review. *Journal of Trends in Computer Science and Smart Technology*, 2019(02), 131–139. doi: 10.36548/jtcsst.2019.2.006
- Voulodimos, A., Doulamis, N., Doulamis, A., & Protopapadakis, E. (2018). Deep Learning for Computer Vision: A Brief Review. *Computational Intelligence and Neuroscience*, 2018. doi: 10.1155/2018/7068349
- Wang, W., & Yang, Y. (2019). Development of convolutional neural network and its application in image classification: a survey. *Optical Engineering*, 58(04), 1. doi: 10.1117/1.oe.58.4.040901
- Zhang, F., Bazarevsky, V., Vakunov, A., Tkachenka, A., Sung, G., Chang, C.-L., & Grundmann, M. (2020). *MediaPipe Hands: On-device Real-time Hand Tracking*.
- Zhang, Q., Chang, X., & Bian, S. B. (2020). Vehicle-Damage-Detection Segmentation Algorithm Based on Improved Mask RCNN. *IEEE Access*, 8, 6997–7004. doi: 10.1109/ACCESS.2020.2964055