

Perbandingan Performa Model SSD Mobilenet V2 dan FPNLite dalam Deteksi Helm Pengendara Sepeda Motor

Dionisius Reinaldo A.S¹, Yosefina Finsensia Riti^{2*}, Nathanael Christian P.T³

^{1,2,3}Program Studi Ilmu Informatika, Fakultas Teknik, Universitas Katolik Darma Cendika
Jl. Dr. Ir. H. Soekarno No.201, Surabaya, Indonesia 60117

*email: yosefina.riti@ukdc.ac.id

(Naskah masuk: 6 Juli 2023; diterima untuk diterbitkan: 23 Oktober 2023)

ABSTRAK – Helm merupakan alat keselamatan dalam berkendara sepeda motor. Helm digunakan untuk melindungi kepala dari benturan akibat kecelakaan. Saat ini kesadaran masyarakat mengenai pentingnya penggunaan helm masih kurang sehingga kecelakaan lalu lintas pengguna sepeda motor yang tidak memakai helm menjadi masalah yang serius dan sering terjadi di Indonesia. Tujuan dari penelitian ini adalah mengembangkan sistem deteksi otomatis untuk mengidentifikasi penggunaan helm menggunakan model deep learning dengan framework tensorflow API yang menyediakan model pralatih SSD Mobilenet V2 dan Mobilenet V2 FPNLite. Dataset terdiri dari gambar pengendara yang menggunakan helm dan tidak menggunakan helm, dan 604 gambar tersebut dibagi menjadi data pelatihan, validasi, dan pengujian. Setelah pelatihan dengan 28.000 iterasi, Mobilenet V2 mencapai akurasi rata-rata 80,12% dan Mobilenet V2 FPNLite mencapai 71,59%. Hasil evaluasi menunjukkan Mobilenet V2 FPNLite mempunyai akurasi yang baik dengan tingkat kepercayaan 99%. Penelitian ini akan memberikan kontribusi penting dalam meningkatkan keselamatan berkendara sepeda motor melalui teknologi pendeteksi objek yang canggih.

Kata Kunci – Deteksi Objek, Helm, Tensorflow, SSD, Citra

Performance Comparison of SSD Mobilenet V2 and FPNLite in Motorcycle Rider Helmet Detection

ABSTRACT – Helm is a safety tool for riding motorcycles. Helmets are used to protect the head from impact in the event of an accident. Currently, public awareness regarding the importance of helmet usage is still lacking, resulting in a serious and frequent occurrence of traffic accidents involving motorcyclists not wearing helmets in Indonesia. The aim of this research is to develop an automatic detection system to identify helmet usage using deep learning models with the TensorFlow API framework, providing pre-trained models such as SSD Mobilenet V2 and Mobilenet V2 FPNLite. The dataset consists of images of riders wearing helmets and not wearing helmets, divided into training, validation, and testing data totaling 604 images. After training with 28,000 iterations, Mobilenet V2 achieved an average accuracy of 80.12%, while Mobilenet V2 FPNLite reached 71.59%. Evaluation results show that Mobilenet V2 FPNLite has good accuracy with a confidence level of 99%. This research will provide a significant contribution to improving motorcycle riding safety through advanced object detection technology.

Keywords – Object Detection, Helmet, Tensorflow, SSD, Imagery

1. PENDAHULUAN

Helm merupakan hal yang sangat penting digunakan dalam mengendarai motor, karena helm digunakan untuk melindungi kepala dari cedera

yang serius akibat kecelakaan lalu lintas [1]. Saat ini kesadaran masyarakat mengenai pentingnya menggunakan helm untuk keselamatan berkendara motor masih kurang sehingga dalam kehidupan sehari-hari sering ditemui pengendara motor yang

tidak memakai helm [2]. Di Indonesia kecelakaan berkendaraan akibat tidak memakai helm setiap tahunnya meningkat [3]. Menurut data POLRI pada tahun 2019 terjadi kecelakaan sebanyak 107.500 kecelakaan lalu lintas, angka tersebut merupakan peningkatan dari tahun sebelumnya yakni sebanyak 103.672 kecelakaan lalu lintas [4]. Menurut Dinas Lalu Lintas, pada tahun 2020 terjadi 109.951 kecelakaan lalu lintas, dimana 22.793 orang meninggal dunia dan 143.578 orang luka-luka [5].

Tingginya kasus kecelakaan akibat tidak menggunakan helm mendorong aparat keamanan lalu lintas atau polisi untuk melakukan aksi tindakan pencegahan [6] berupa tilang. Tindakan penilangan terhadap pengendara motor yang tidak menggunakan helm mampu menurunkan pelanggaran akibat tidak memakai helm. Tindakan tilang yang mampu menurunkan tingkat pelanggaran [7] akibat tidak memakai helm saat berkendara akan berkontribusi terhadap penurunan tingkat kecelakaan bermotor akibat tidak memakai helm. Namun dalam implementasinya proses tilang masih menggunakan tilang konvensional menggunakan kertas yang dinilai masih kurang dalam implementasinya dan membutuhkan banyak tenaga kerja untuk mengawasi banyak titik di jalanan dan pihak kepolisian tidak dapat mengawasi selama 24 jam penuh [8], dengan demikian diperlukan sebuah alat atau teknologi yang dapat melakukan hal tersebut, semua pelanggaran akan dicatat oleh sistem sehingga tidak ada data yang terlewatkan satupun [9].

Di era perkembangan teknologi yang begitu cepat, deteksi objek merupakan teknologi yang dapat membedakan objek yang terlihat dalam sebuah gambar atau video [4],[10]. Teknologi ini dapat diimplementasikan ke dalam berbagai bidang termasuk dalam mengurangi tingkat kecelakaan bermotor akibat tidak memakai helm. Dengan bantuan deteksi objek dapat membantu pihak kepolisian untuk mendeteksi pelanggaran lalu lintas seperti mendeteksi apakah seorang pengendara menggunakan helm atau tidak, hal ini bertujuan untuk meningkatkan keselamatan pengendara bermotor di jalan raya.

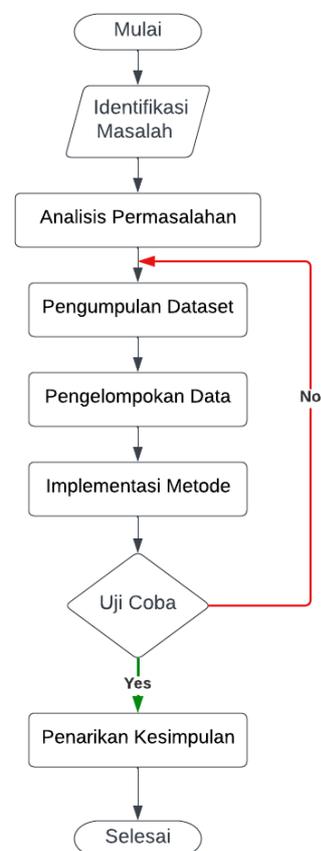
Algoritma deteksi objek yang banyak diimplementasikan saat ini menggunakan algoritma Deep Learning. Berdasarkan metode deteksi objek Deep Learning terdapat berbagai macam algoritma diantaranya; You Only Look Once (YOLO), Single Shot Detector (SSD), RetinaFace, dan (Faster Recurrent Convolutional Neural Network) Faster R-CNN [11]. Seiring dengan berjalannya waktu diciptakan framework yang dapat digunakan untuk membuat model untuk mendeteksi objek.

Penelitian terdahulu digunakan sebagai landasan teori dalam penelitian ini, Contohnya adalah studi

tahun 2020 oleh Prisky Ratna Aningtiyas, Agus Sumin, dan Setia Wirawan berjudul "Pembuatan Aplikasi Deteksi Objek Menggunakan TensorFlow Object Detection API dengan Memanfaatkan SSD Mobilenet V2 Sebagai Model Pra-Terlatih" Studi ini menjelaskan cara menggunakan SSD MobileNet V2 untuk mendeteksi objek: sebagai metode pra-pelatihan, yang kemudian digunakan untuk membangun aplikasi yang dapat menggunakan input gambar untuk mendeteksi dan mengukur akurasi objek. Penelitian ini menggunakan Framework Tensorflow API, Tensorflow menyediakan model pra-pelatihan yang dapat digunakan untuk deteksi objek menggunakan API deteksi Tensorflow [12]. Model pra-pelatihan SSD Mobilenet V2 dan Mobilenet V2 FPNLite digunakan dalam penelitian ini. Kedua model tersebut akan mendeteksi objek dengan memberikan hasil yang akurat dan mendeteksi rentang objek dalam setiap kategori kelas tertentu [13]. Hasil dari pelatihan akan diuji pada data test untuk mengetahui akurasi yang dihasilkan oleh model tersebut.

2. METODE DAN BAHAN

Dalam jurnal ini penelitian dilakukan langkah demi langkah sesuai dengan urutan tahapannya. Berikut adalah gambaran dari langkah-langkah yang diberikan.



Gambar 1. Diagram Penelitian

Identifikasi Masalah

Permasalahan utama dari penelitian ini adalah kecerobohan pengendara motor yang tidak memakai helm saat berkendara di jalan raya yang menyebabkan banyaknya kecelakaan sepeda motor. Maka dari itu diberlakukan tindakan pencegahan berupa tilang yang terbukti mampu menurunkan tingkat kecelakaan akibat tidak memakai helm [14]. Sehingga dibutuhkan pendeteksian otomatis untuk membantu polisi untuk mendeteksi pelanggaran pengendara motor tidak menggunakan helm.

Analisis Permasalahan

Dalam penelitian ini menggunakan model SSD Mobilenet V2 dan Mobilenet V2 FPNLite untuk pendeteksian objek. Analisis permasalahan diperoleh untuk membandingkan dua algoritma tersebut dalam pendeteksian pelanggaran pengendara motor tidak menggunakan helm. Dataset merupakan hal yang penting dalam penelitian ini. Google Colaboratory atau Jupyter-lab digunakan untuk menjalankan program python supaya mendapatkan informasi yang diinginkan [15].

Pengumpulan Dataset

Dataset yang digunakan pada penelitian ini diambil dari berbagai sumber seperti kaggle dan roboflow. Dataset berisi 604 gambar pengendara dengan helm dan atau tidak menggunakan helm. Selain itu dataset juga berisi 604 anotasi yang berfungsi sebagai label atau penanda mengenai objek yang dideteksi sekaligus melatih model dalam mendeteksi suatu objek [16].

Pengelompokan Data

Pada langkah ini, dataset dari 604 citra dikelompokkan menjadi dua tipe data, yaitu 483 gambar untuk data latih dan 60 gambar untuk data validasi dan 61 gambar untuk data testing .

Implementasi Metode

Arsitektur Mobilenet V2 dan Mobilenet V2 FPNLite merupakan jaringan tiruan yang digunakan untuk tugas pemrosesan gambar khususnya klasifikasi dan deteksi objek. Pada dasarnya kedua arsitektur tersebut dibuat berdasarkan Mobilenet V2 yang dirancang untuk komputasi yang lebih ringan dan efisien. Perbedaan utama dari kedua arsitektur tersebut terletak pada FPN atau *Feature Pyramid Network* yang merupakan mekanisme untuk memahami objek dengan berbagai skala [17] sehingga Mobilenet V2 FPNLite lebih cocok untuk melakukan tugas deteksi objek. Selain itu, Mobilenet V2 FPNLite memerlukan lapisan tambahan sehingga komputasinya menjadi lebih kompleks.

Sebaliknya Mobilenet V2 lebih cocok untuk melakukan tugas klasifikasi objek.

Tahap ini merupakan proses pengolahan data yang telah diolah sebelumnya. Implementasi model Mobilenet V2 dan Mobilenet V2 FPNLite dengan dataset yang telah diproses diperlukan untuk melatih model deteksi untuk mengenali objek manusia menggunakan helm atau tidak. Dalam proses implementasi model Mobilenet V2 dan Mobilenet V2 FPNLite memiliki proses pelatihan dan proses testing. Proses pelatihan meliputi proses pemanggilan dataset dan melatih model untuk mendeteksi berdasarkan gambar pada dataset. Sedangkan untuk proses testing meliputi proses pemanggilan hasil latih dataset pada sebuah objek dengan tujuan untuk melakukan pengujian apakah model dapat mengenali objek diluar dataset yang diberikan.

Uji Coba

Pada tahap ini dilakukan percobaan untuk mengetahui tingkat keberhasilan dari model yang digunakan. keberhasilan metode dinilai berdasarkan tingkat akurasi, presisi dan sensitivitas [16].

Pada penelitian ini akan menggunakan *Intersection over Union (IoU)* adalah sebuah metode yang digunakan untuk menilai kinerja model klasifikasi [18] dengan cara membandingkan *ground-truth bounding box* dan *predicted bounding box*. Seperti pada persamaan berikut [19].

$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}} \quad (1)$$

Selain itu diperoleh *mean average precision* yang merupakan nilai rata-rata dari IoU. Pada penelitian ini mAP menggunakan nilai *threshold* 0,5 sehingga apabila citra menghasilkan nilai IoU diatas 0,5 maka akan diklasifikasikan sebagai *True Positive*, sebaliknya jika citra menghasilkan nilai IoU dibawah 0,5 maka akan diklasifikasikan sebagai *False Positive*. Jika objek tidak menggunakan helm dan model tidak dapat mendeteksi objek tersebut maka akan diklasifikasikan sebagai *False Positive*, sebaliknya jika model mendeteksi objek tidak memakai helm dan model mendeteksi dengan benar maka akan diklasifikasikan sebagai *True Negative*.

Dari nilai tersebut dapat digunakan untuk menghitung *precision*

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

Hasil perhitungan *precision* dievaluasi dan menghasilkan kurva yang dikenal sebagai "kurva presisi-recall." Nilai Rata-rata Presisi (AP) diperoleh dengan menghitung area di bawah kurva untuk setiap kelas yang diidentifikasi oleh sistem. Kemudian, nilai *Mean Average Precision* (mAP) dihitung dengan cara merata-ratakan nilai AP dari semua kelas yang berhasil terdeteksi.

Penarikan Kesimpulan

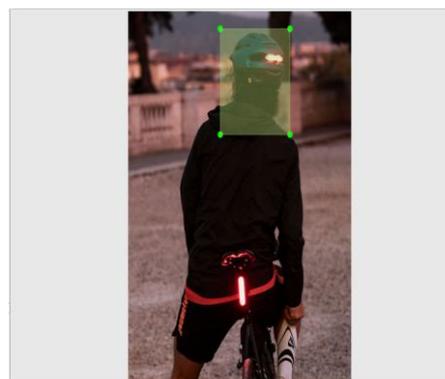
Pada fase ini, peneliti menarik kesimpulan untuk metode yang diuji, terlepas dari apakah dapat dikembangkan untuk deteksi objek atau tidak [20]. Dan pada tahap ini juga ditentukan nilai akurasi yang dibuat oleh model Mobilenet V2 dan Mobilenet V2 FPNLite.

3. HASIL DAN PEMBAHASAN

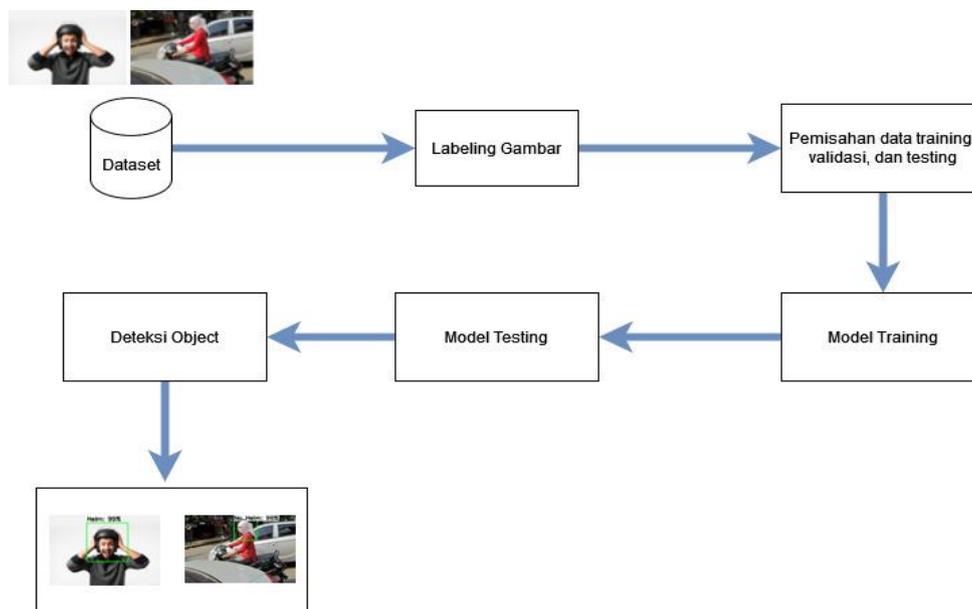
Pengolahan Data

Pada penelitian ini berfokus pada penggunaan helm. Alur pengolahan data dapat dilihat pada

gambar 2. Pada setiap data uji dibagi menjadi dua kelas yaitu Helm dan No_Helm. Kedua kelas ini dibedakan berdasarkan dengan penggunaan helm pada pengendara motor dan pengendara motor yang tidak memakai helm. Dataset dikumpulkan dari beberapa sumber seperti kaggle dan roboflow kemudian dilakukan proses anotasi gambar menggunakan LabelImg untuk memberi label untuk melatih model untuk mendeteksi objek helm dan tidak menggunakan helm [19],[21]. Seperti yang ditunjukkan pada gambar 3.



Gambar 2. LabelImg



Gambar 3. Alur Pengolahan Data

Setelah dataset gambar dianotasi dengan menggunakan LabelImg data tersebut kemudian didistribusikan seperti pada tabel 1.

Training

Saat melakukan proses pelatihan data dengan tensorflow dengan model SSD Mobilenet V2 dan Mobilenet V2 FPNLite, untuk mencapai akurasi yang diinginkan, parameter juga harus diuji dan

ditentukan.

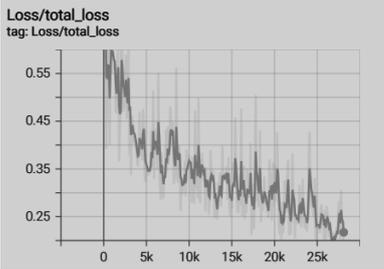
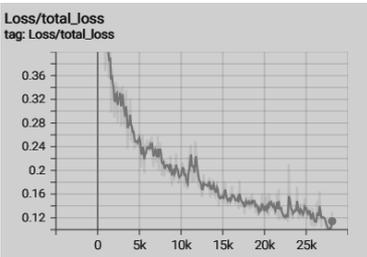
Tabel 1. Distribusi Dataset

Objek Citra	Dataset	Data Training dan Validasi	Data Testing
Helm dan No_Helm	604	543	61

Parameter yang dipakai yaitu jumlah epoch yang akan digunakan. Jumlah epoch ditentukan untuk menentukan seberapa sering metode pembelajaran dijalankan untuk mengolah semua data yang

tersimpan dalam log file. Pada penelitian ini, menggunakan epoch 28.000 kali pengulangan untuk mendapatkan hasil yang maksimal [22].

Tabel 2. Grafik Total_loss

Epoch	Model	Total Loss	Durasi Pelatihan
28.000	Mobilenet V2		3 jam
28.000	Mobilenet V2 FPNLite		2,5 jam

Berdasarkan hasil pelatihan pada table 2 dengan 28.000 kali pengulangan menggunakan data input yang berasal dari data train menghasilkan visualisasi grafik total loss yang menurun seiring dengan bertambahnya iterasi dalam proses pelatihan berdasarkan hasil pelatihan didapatkan bahwa model Mobilenet V2 membutuhkan waktu pelatihan yang lebih lama yaitu 3 jam dibanding dengan Mobilenet V2 FPNLite yang membutuhkan

waktu 2,5 jam. *Total_Loss* menggambarkan sejauh mana hasil prediksi model arsitektur dengan nilai yang sebenarnya. Nilai *Total_loss* didapatkan dari perhitungan jumlah nilai *classification loss*, *localization loss*, dan *regularization loss*, seperti pada tabel 3.

Selain itu model Mobilenet V2 FPNLite mempunyai nilai total_loss yang lebih kecil dibanding dengan model Mobilenet V2 sehingga jika dibandingkan maka Mobilenet V2 FPNLite akan memiliki tingkat keakuratan yang lebih tinggi.

Tabel 3. Nilai Loss Model SSD

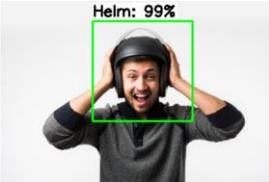
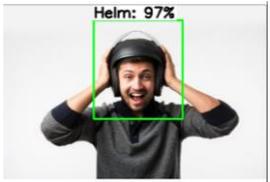
Model	<i>Total_Loss</i>	<i>classification loss</i>	<i>localization loss</i>	<i>regularization loss</i>
Mobilenet V2 FPNLite	0.11317559	0.035103787	0.014878778	0.06319303
Mobilenet V2	0.21640201	0.066804275	0.04656244	0.10303529

Testing

Setelah melakukan proses training, kemudian dilakukan pengujian pada model SSD Mobilenet V2 dan Mobilenet V2 FPNLite untuk mengevaluasi keakuratan dari model setelah dilakukannya proses

training. Uji coba dilakukan dengan dataset gambar untuk testing dan menghasilkan tingkat keakuratan dengan threshold 0.5 pada masing-masing model seperti dalam tabel 4.

Tabel 4. Hasil Test Model

No.	Gambar	Hasil SSD FPNLite	Mobilenet V2	Hasil SSD Mobilenet V2
1.				
2.				
3.				
4.				

Evaluasi Model

Berdasarkan hasil yang didapatkan dari testing model SSD Mobilenet V2 dan Mobilenet V2 FPNLite mendapatkan nilai presisi seperti dalam tabel 5 dan tabel 6. Hasil evaluasi mAP (*mean average precision*) dari model dengan diberikan data test ditunjukkan pada tabel 5 dan table 6. Pada hasil dengan threshold 0.5 model dapat menemukan nilai True Positive lebih banyak sehingga memiliki nilai akurasi yang tinggi pada model Mobilenet V2 FPNLite mendapat mAP 71,95% sedangkan pada Mobilenet V2 mendapat nilai mAP yang lebih tinggi yaitu sebesar 80,12%, namun ketika diberikan nilai threshold yang lebih tinggi kedua model yang di uji mengalami penurunan nilai akurasi pada hal ini menunjukkan penurunan nilai lokalisasi yang

mengacu pada hasil prediksi bounding box pada deteksi objek dengan kecocokannya pada nilai threshold yang sebenarnya [23],[24]

Tabel 5. mAP model *Mobilenet V2*

Model	Jenis	mAP 0,5	mAP 0,6	mAP 0,75	mAP 0,5;0,9 5
<i>Mobilenet V2</i>	Helm	79,92 %	78,43 %	50,14 %	48,67 %
	No_Helm	80,32 %	73,65 %	26,11 %	38,52 %
	Rata-Rata	80,12 %	76,04 %	38,13 %	43,60 %

Tabel 6. mAP model *Mobilenet V2 FPNLite*

Model	Jenis	mAP 0,5	mAP 0,6	mAP 0,75	mAP 0,5;0,95
<i>Mobilenet V2 FPNLite</i>	Helm	69,12%	69,12%	49,22%	43,13%
	No_Helm	74,78%	57,65%	28,22%	33,92%
	Rata-Rata	71,95%	63,69%	38.73%	38.53%

DAFTAR PUSTAKA

- [1] O. Ni Putu Sri Widiasih, "Tinjauan Yuridis Terhadap Perilaku Pengguna Helm di Universitas Haluoleo," *Jurnal Hukum Volkgeist*, vol. 2, no. 2, 2018.
- [2] H. Budiardjo and S. Martono, "Desain Bagasi Helm Sepeda Motor sebagai Alternatif Penyimpanan Helm," *Sebatik*, vol. 26, no. 1, pp. 73–80, Jun. 2022, doi: 10.46984/sebatik.v26i1.1871.
- [3] F. Fadhlur Rachman, H. Bethaningtyas, and R. Fauzi Iskandar, "Deteksi Penggunaan Alat Pelindung Diri (APD) untuk Keselamatan dan Kesehatan Kerja Menggunakan Metode Mask Region Convolutional Neural Network (Mask R-CNN)," *e-Proceeding of Engineering*, vol. 8, pp. 327–332, 2021.
- [4] D. Ariyoga, R. Rahmadi, and R. A. Rajagede, "Penelitian Terkini Tentang Sistem Pendeteksi Pelanggaran Lalu Lintas Berbasis Deep Learning: Sebuah Kajian Pustaka," *Automata*, vol. 2, 2021.
- [5] S. Shofiah *et al.*, "Road Safety Go to School sebagai Upaya Peningkatan Kesadaran Berlalu Lintas," *Community Dev J*, vol. 4, no. 2, pp. 2136–2140, 2023.
- [6] R. Aditama, "Upaya Polisi Lalu Lintas Polres Tanjung Jabung Barat dalam Restorasi Fungsi Helm," *Wajah Hukum*, vol. 6, no. 2, p. 327, Oct. 2022, doi: 10.33087/wjh.v6i2.1086.
- [7] Bambang. Widodo, Hendrawan. Armanto, and E. Setyati, "Deteksi Pemakaian Helm Proyek Dengan Metode Convolutional Neural Network," *JOURNAL OF INTELLIGENT SYSTEMS AND COMPUTATION*.
- [8] U. Sabadina, "Penerapan E-Tilang dalam Penyelesaian Tindak Pidana Pelanggaran Lalu Lintas," *Indonesian Journal of Criminal Law and Criminology (IJCLC)*, vol. 1, no. 1, pp. 60–71, Jul. 2020, doi: 10.18196/ijclc.v1i1.9157.
- [9] A. S. Wulandari, "Inovasi Penerapan Sistem E-Tilang di Indonesia," *Jurnal Studi Islam dan Sosial*, vol. 14, no. 1, 2020.
- [10] D. A. Prabowo, D. Abdullah, and A. Manik, "Deteksi dan Perhitungan Objek Berdasarkan Warna Menggunakan Color Object Tracking," *Jurnal Pseudocode*, vol. V, no. 2, 2018, [Online]. Available: www.ejournal.unib.ac.id/index.php/pseudocode
- [11] R. Gelar Guntara, "Pemanfaatan Google Colab Untuk Aplikasi Pendeteksian Masker Wajah Menggunakan Algoritma Deep Learning YOLOv7," *Jurnal Teknologi Dan Sistem Informasi Bisnis*, vol. 5, no. 1, pp. 55–60, Feb. 2023, doi: 10.47233/jteksis.v5i1.750.
- [12] W. Swastika, A. W. Nur, and O. H. Kelana, "Monitoring Ruangan Untuk Deteksi Manusia Berbasis CNN Dengan Fitur Push Notification," *Teknika*, vol. 8, no. 2, pp. 92–96, Oct. 2019, doi: 10.34148/teknika.v8i2.166.
- [13] P. Ratna Aningtyas, A. Sumin, and S. Wirawan, "Pembuatan Aplikasi Deteksi Objek Menggunakan TensorFlow Object Detection API dengan Memanfaatkan SSD MobileNet V2 Sebagai Model Pra - Terlatih," *Jurnal Ilmiah Komputasi*, vol. 19, no. 3, Mar. 2020, doi: 10.32409/jikstik.19.3.68.
- [14] R. Yuli Endra, A. Cucus, F. Nur Affandi, and M. Bintang Syahputra, "Deteksi Objek Menggunakan Histogram of Oriented Gradient (HOG) untuk Model Smart Room," *Explore - Jurnal Sistem Informasi dan Telematika*, vol. 9, 2018.
- [15] W. Setiawan, N. Hafidz Farhan, and U. Sangga Buana YPKP Bandung Fakultas Teknik Informatika, "Deteksi Objek Plat Nomor Kendaraan Dengan Metode CNN,"

- Jurnal Computech & Bisnis*, vol. 16, no. 1, pp. 46-50, 2022.
- [16] R. M. Mailoa and L. W. Santoso, "Deteksi Rompi dan Helm Keselamatan Menggunakan Metode YOLO dan CNN," *Jurnal Infra*, 2022.
- [17] Y.-C. Chiu, C.-Y. Tsai, D. Ruan, G.-Y. Shen, and T.-T. Lee, "Mobilenet-SSDv2: An Improved Object Detection Model for Embedded Systems," 2020.
- [18] K. A. Shianto, K. Gunadi, and E. Setyati, "Deteksi Jenis Mobil Menggunakan Metode YOLO Dan Faster R-CNN," *Jurnal Infra*, vol. 7, 2019.
- [19] K. Eko, M. Yuniarno, and A. Zaini, "Pembuatan Modul Deteksi Objek Manusia Menggunakan Metode YOLO untuk Mobile Robot," *JURNAL TEKNIK ITS*, vol. 10, pp. A50-A55, 2022.
- [20] J. Jumadi and D. Sartika, "Pengolahan Citra Digital untuk Identifikasi Objek Menggunakan Metode Hierarchical Agglomerative Clustering," *Jurnal Sains dan Teknologi*, vol. 10, no. 2, 2021.
- [21] I. Inayatul Arifah, F. Nur Fajri, and G. Qorik Oktagalu Pratamasunu, "Deteksi Tangan Otomatis Pada Video Percakapan Bahasa Isyarat Indonesia Menggunakan Metode YOLO Dan CNN," 2022. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAI> C
- [22] Q. Aini, N. Lutfiani, H. Kusumah, and M. S. Zahran, "Deteksi dan Pengenalan Objek dengan Model Machine Learning: Model YOLO," *Journal Of Computer Engineering System and Science*, vol. 6, no. 2, pp. 2502-714, 2021.
- [23] S. Jupiyandi, F. R. Saniputra, Y. Pratama, M. R. Dharmawan, and I. Cholissodin, "Pengembangan Deteksi Citra Mobil untuk Mengetahui Jumlah Tempat Parkir Menggunakan CUDA dan Modified YOLO," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 6, no. 4, pp. 413-419, 2019, doi: 10.25126/jtiik.201961275.
- [24] A. Ubaidillah MS, A. Fiqhi Ibadillah, and M. Mukhlis Febriansyah, "Deteksi Jumlah Pengunjung Dan Penggunaan Masker Dengan Menggunakan Metode YOLO Dan Haar Cascade Classifier," *Zetroem* , vol. 05, 2023.