

DETEKSI PELANGGARAN PENGGUNAAN HELM DENGAN METODE SSD DAN ARSITEKTUR MOBILENETV2

Ariya Purnama ¹⁾, Jamaludin Indra ²⁾, Santi Arum Puspita Lestari ³⁾, Sutan Faisal ⁴⁾

^{1, 2, 3, 4)} Fakultas Ilmu Komputer Universitas Buana Perjuangan Karawang
email : if21.ariyapurnama@mhs.ubpkarawang.ac.id ¹⁾, jamaludin.indra@ubpkarawang.ac.id ²⁾,
santi.arum@ubpkarawang.ac.id ³⁾, sutan.faisal@ubpkarawang.ac.id ⁴⁾

Abstraksi

Peningkatan jumlah kendaraan terus didominasi oleh pengendara sepeda motor. Terkait hal ini, pengawasan keselamatan lalu lintas oleh pihak berwenang perlu ditingkatkan. Namun, dengan kemajuan teknologi yang pesat, terutama di bidang visi komputer, solusi baru telah dimungkinkan. Salah satu pengembangan tersebut adalah penggunaan perangkat *Raspberry Pi* yang murah, yang dapat melakukan tugas-tugas yang mirip dengan komputer desktop. Tujuan dari penelitian ini adalah untuk mengembangkan sistem pendeteksi helm untuk pengendara sepeda motor menggunakan arsitektur *MobileNetV2* dan SSD (*Single Shot Multibox Detector*). Sebanyak 1.363 gambar digunakan, dengan 953 untuk pelatihan, 273 untuk validasi, dan 137 untuk pengujian. Tahap prapemrosesan gambar melibatkan pengubahan ukuran gambar menjadi 240 x 240 piksel sebelum dimasukkan ke dalam model. Hasil pelatihan menunjukkan akurasi maksimum sebesar 100%, sementara evaluasi model pada set pengujian mencapai akurasi deteksi 95% untuk pengendara yang mengenakan helm dan 98% untuk mereka yang tidak mengenakan helm. Selain itu, model tersebut mencapai rata-rata Average Precision (mAP) sebesar 99% pada ambang batas *IoU* 0.5 (mAP50) dan 66% pada ambang batas *IoU* 0.75 (mAP75).

Kata Kunci: Deteksi Pelanggaran Penggunaan Helm, *Raspberry Pi*, Arsitektur *MobileNetV2* dan SSD

Abstract

The increasing number of vehicles continues to be dominated by motorcycle riders. In this regard, traffic safety supervision by the authorities needs to be enhanced. However, with the rapid advancement of technology, especially in the field of computer vision, new solutions have become possible. One such development involves the use of low-cost Raspberry Pi devices, which can perform tasks similar to those of a desktop computer. The objective of this research is to develop a helmet detection system for motorcycle riders using the MobileNetV2 architecture and SSD (Single Shot Multibox Detector). A total of 1,363 images were used, with 953 for training, 273 for validation, and 137 for testing. The image preprocessing stage involved resizing the images to 240 x 240 pixels before being fed into the model. The training results showed a maximum accuracy of 100%, while model evaluation on the test set achieved a detection accuracy of 95% for riders wearing helmets and 98% for those not wearing helmets. Additionally, the model achieved a mean Average Precision (mAP) of 99% at IoU threshold 0.5 (mAP50) and 66% at IoU threshold 0.75 (mAP75).

Keywords: *Helmet Usage Violation Detection, Raspberry Pi, MobileNetV2 Architecture and SSD*

Pendahuluan

Keselamatan Berkendara merupakan tanggung jawab bersama yang harus di junjung tinggi oleh setiap pengguna jalan. Setiap orang yang berada di jalan raya, baik sebagai pengendara, penumpang, maupun pejalan kaki, memiliki peran dalam menciptakan lingkungan berlalu lintas yang aman dan teratur. Dominasi sepeda motor sebagai moda transportasi utama masyarakat Indonesia menyediakan kemudahan dan fleksibilitas berkendara. Di sisi lain, jumlah pengendara motor yang aktif berkendara akan selaras dengan kemungkinan terjadinya kecelakaan lalu lintas. Peningkatan jumlah kecelakaan ini menjadi sorotan utama bagi kepolisian yang dengan terus mengedukasi keamanan, keselamatan kepada masyarakat agar lebih mematuhi aturan keselamatan berkendara. Berdasarkan Lumba et al. [1], angka kecelakaan lalu lintas sepanjang tahun di Indonesia didominasi oleh kecelakaan sepeda motor. Menurut Nurjaman et al. [2]

masih banyak pengendara yang masih mengabaikan rambu lalu lintas dan tidak menggunakan helm sehingga perlu peningkatan kesadaran masyarakat terhadap keselamatan berkendara.

Kemajuan teknologi saat ini memberikan dampak signifikan bagi kehidupan saat ini. Salah satunya contohnya adalah computer vision yang bertujuan untuk mengembangkan sistem otomatis dan mampu mengenali objek. Deteksi objek adalah salah satu implementasi penting dari computer vision yang memungkinkan sistem untuk mengenali dan menentukan lokasi objek tertentu dalam sebuah gambar atau video. Teknologi ini telah digunakan secara luas di berbagai bidang, seperti pengawasan keamanan, kendaraan otonom, dan sistem manufaktur cerdas [3]. *Raspberry Pi* adalah sebuah perangkat mini komputer yang memiliki efisiensi sumber daya yang cukup untuk melakukan identifikasi objek secara *Realtime*. Implementasi *Objek Recognition* pada

rambu-rambu lalu lintas mendapatkan keakuratan sebesar 88,88% menggunakan *Raspberry Pi* [4]. Selain itu, sebagai perangkat komputasi berbiaya rendah. Kemampuan *Raspberry Pi* yang dapat menyelesaikan banyak tugas komputasi seperti komputer dekstop dan dimanfaatkan dalam sejumlah proyek, termasuk server media, pengendali rumah pintar dan proyek elektronik serta *Internet of Things* lainnya [5].

Single shot multibox detector (SSD) merupakan metode algoritma deteksi objek yang memiliki rasio kecepatan dan akurasi komputasi yang tinggi. Selanjutnya, dapat mendeteksi objek dengan membaca satu *Bounding Box* dari sebuah gambar atau video [6]. Salah satu fitur utama SSD adalah penggunaan *Single Multibox Detector* yang memungkinkan sistem mengenali beberapa objek secara bersamaan dalam satu *frame*. Cara kerja algoritma SSD melibatkan anotasi gambar yang memiliki kotak pembatas (*bounding box*) dengan ukuran tertentu. Kotak-kotak ini ditentukan untuk menandai lokasi objek dan menampilkan nilai skor yang menunjukkan tingkat kepercayaan sistem terhadap kategori objek yang terdeteksi [7].

MobileNetV2 adalah *library* yang dikembangkan oleh Google dirancang untuk memenuhi kebutuhan pada perangkat *mobile* dengan sumber daya terbatas. Selain itu bagian dari arsitektur *MobileNet* ini untuk mengekstraksi fitur dari sebuah gambar [8]. *MobileNet* dikembangkan sebagai bagian dari rangkaian model *TensorFlow Open Source* dan dirancang untuk menghasilkan keseimbangan antara akurasi dan keterbatasan sumber daya perangkat. Keunggulan SSD *MobileNetV2* pada umumnya seringkali digunakan untuk mendeteksi keberadaan objek secara *Realtime*. Selain itu, model *MobileNetV2* adalah versi lanjutan, memiliki ukuran ringan yang dapat menangani kendala komputasi dan mengurangi penggunaan memori [9]. Dibandingkan dengan metode lain seperti YOLO atau CNN konvensional, kombinasi SSD dan arsitektur *MobileNetV2* menawarkan keunggulan dalam hal kecepatan deteksi dan efisiensi komputasi, yang sangat cocok untuk perangkat dengan sumber daya terbatas seperti *Raspberry Pi*.

Tinjauan Pustaka

Berbagai penelitian sebelumnya telah mengembangkan sistem deteksi penggunaan helm sebagai bagian dari upaya meningkatkan keselamatan pengendara sepeda motor. Teknologi yang digunakan umumnya memanfaatkan pengolahan citra digital dan algoritma deep learning seperti YOLOv3, YOLOv4, YOLOv5, CNN, dan SSD. Setiap studi menunjukkan pendekatan dan tingkat akurasi yang bervariasi, tergantung pada metode, perangkat keras, serta kualitas data yang digunakan. Secara umum, hasil penelitian tersebut menunjukkan perkembangan teknologi deteksi secara otomatis.

Beberapa penelitian sebelumnya telah membahas deteksi pelanggaran penggunaan helm dengan

pendekatan berbasis *computer vision* dan *deep learning*. Penelitian oleh [10] menggunakan metode YOLOv4 untuk mendeteksi pelanggaran tidak menggunakan helm dalam sistem ETLE. Meskipun hasil training ditargetkan mencapai 80%, penelitian ini lebih menekankan pada implementasi awal metode deteksi tanpa menyertakan pengujian sistem secara komprehensif.

Sementara itu, penelitian oleh [11] menggunakan metode *Convolutional Neural Network* (CNN) yang diimplementasikan melalui perangkat *Raspberry Pi*. Sistem ini berhasil mendeteksi pengendara tanpa helm dengan akurasi mencapai 90% berdasarkan *confusion matrix*, meskipun masih terdapat kelemahan dalam mendeteksi objek yang blur atau tidak jelas. Penelitian ini menunjukkan bahwa akurasi tinggi dapat dicapai dengan metode CNN, namun perangkat keras yang digunakan memiliki keterbatasan dalam pemrosesan citra.

Pendekatan berbeda ditunjukkan oleh penelitian [12] yang menggunakan metode *Single Shot Multibox Detector* (SSD). Penelitian ini menekankan pengujian dengan metrik mAP dan *Average Recall*, yang masing-masing mencapai 79,2% dan 61,4%. Kelebihan dari penelitian ini terletak pada fokus evaluasi performa sistem berdasarkan partisi data, namun belum menyentuh aspek kombinasi pelanggaran atau fitur tambahan seperti jumlah penumpang.

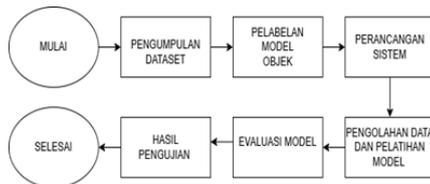
Kemudian, penelitian [13] menerapkan metode YOLOv5 dalam deteksi pelanggaran helm berdasarkan rekaman CCTV. Dengan *preprocessing* untuk menghilangkan *outlier* dan *noise*, sistem ini mampu mencapai *F1 Score* sebesar 0,87 dan mAP sebesar 0,90. Namun, penelitian ini menghadapi kendala dalam hal bias deteksi karena objek yang terlalu kecil atau jauh dari kamera, sehingga tidak terdeteksi dengan baik. Ini menunjukkan bahwa kualitas dan penempatan kamera sangat berpengaruh terhadap hasil deteksi.

Penelitian lain oleh [14] menggabungkan deteksi helm dan jumlah penumpang dengan metode YOLOv3. Sistem dirancang untuk mendeteksi lebih dari dua penumpang pada sepeda motor, kemudian dilanjutkan dengan deteksi penggunaan helm. Hasilnya, sistem berhasil mendeteksi pelanggaran tersebut dengan akurasi 84,6%. Pendekatan ini memperluas ruang lingkup deteksi pelanggaran lalu lintas, tidak hanya terbatas pada helm.

Berbeda dari penelitian-penelitian tersebut, penelitian ini mengembangkan sistem deteksi pelanggaran helm menggunakan metode yang lebih mutakhir, serta mengombinasikan fitur pelanggaran helm dengan parameter tambahan seperti jumlah penumpang secara simultan. Keunggulan dari pendekatan yang digunakan terletak pada integrasi antara akurasi tinggi dan keberhasilan deteksi multi-objek dalam kondisi nyata, yang sebelumnya belum banyak diterapkan dalam penelitian terdahulu.

Metodologi Penelitian

Metode penelitian ini dari mulai mengumpulkan dataset, serta penggunaan algoritma *Convolutional Neural Network* pada umumnya digunakan untuk melakukan teknik dari pekerjaan klasifikasi ataupun deteksi objek melalui foto, video, dan teks [15]. Dengan arsitektur *mobilenetv2* dan *SSD (Single Shot Multibox Detector)* untuk deteksi penggunaan helm. Selanjutnya pada proses gambar menggunakan perangkat *Raspberry pi* dan kamera *webcam* secara *realtime*.



Gambar 1. Metode penelitian

Pengumpulan Dataset

Dataset dikumpulkan melalui pengambilan foto gambar menggunakan kamera telpon seluler. Proses ini mengambil sejumlah gambar pengendara yang menggunakan motor, helm, dan tidak. Teknik yang dilakukan saat memotret dengan pencahayaan yang baik dan berbagai sudut. Gambar yang sudah dikumpulkan ini, selanjutnya dilakukan pembagian data untuk proses *Train*, *Valid* dan *test*. Selain itu, menggunakan format gambar png. Selanjutnya hasil dari pengumpulan gambar akan dilakukan pengolahan data menggunakan teknik *processing* dan *augmentasi* serta pelabelan model objek untuk persiapan pelatihan dan pengujian. Jumlah dataset yang digunakan dalam penelitian ini sebanyak 1.363 gambar, yang dikumpulkan dari berbagai kondisi pencahayaan dan sudut pengambilan gambar. Rincian mengenai jumlah gambar dan resolusi yang digunakan ditampilkan pada Tabel 1.

Tabel 1. Dataset Yang Dikumpulkan

Jumlah Gambar	Ukuran Gambar
1363	12240 x 16320 pixel

Pelabelan Model Objek

Tahapan ini adalah pelabelan dari dataset yang telah dikumpulkan. Proses pelabelan dilakukan dengan memberikan anotasi pada setiap gambar, untuk mengidentifikasi dan menandai kategori objek, seperti pengendara menggunakan helm dan tidak menggunakan helm. Pelabelan ini dilakukan menggunakan perangkat lunak khusus, seperti *RoboFlow*. Tujuannya adalah untuk memastikan bahwa dataset memiliki anotasi yang akurat sehingga dapat digunakan untuk melatih model deteksi objek secara optimal.

Perlu ditegaskan bahwa proses pelabelan objek menggunakan *RoboFlow* tidak dilakukan secara otomatis oleh sistem. Peneliti secara manual melakukan anotasi terhadap setiap gambar, yaitu dengan menggambar *bounding box* dan menetapkan label seperti '*Helmet*', '*NoHelmet*', dan '*Motorcycle*'

pada objek yang sesuai. *RoboFlow* hanya digunakan sebagai alat bantu untuk mempermudah proses anotasi manual, bukan sebagai sistem pendeteksi otomatis. Oleh karena itu, penelitian ini tetap diperlukan untuk membangun model deteksi yang dapat mengenali pelanggaran penggunaan helm secara mandiri setelah melalui proses pelatihan menggunakan dataset beranotasi. Contoh anotasi objek dapat dilihat pada Gambar 2.



(a)



(b)

Gambar 2. (a) objek *Helmet* (b) Objek *NoHelmet*

Perancangan sistem

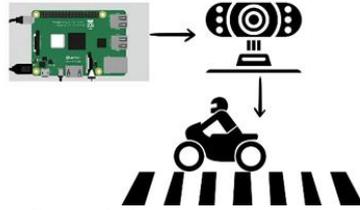
Akurasi sistem deteksi objek dipengaruhi oleh kualitas gambar yang dihasilkan oleh kamera. Oleh karena itu, pemilihan kamera menjadi langkah yang sangat penting dalam proses implementasi. Dalam perancangan alat ini, *Raspberry Pi* dipilih sebagai perangkat utama karena kemampuannya untuk menjalankan pemrosesan video *realtime*. Selain itu, Tabel 2 menjelaskan komponen utama yang digunakan dalam perancangan sistem beserta fungsinya masing-masing. Dalam penelitian ini, kamera yang digunakan adalah webcam eksternal beresolusi tinggi (HD 720p) yang dihubungkan ke *Raspberry Pi* melalui USB. Pemilihan ini dilakukan karena kamera bawaan *Raspberry Pi* (seperti *Pi Camera Module*) memiliki keterbatasan dalam menangkap detail objek dalam kondisi pencahayaan tertentu.

Tabel 2. Perancangan Sistem

Perancangan	Penggunaan
<i>Raspberry pi</i>	Pemrosesan model dari hasil video secara <i>realtime</i>
Kamera <i>Webcam</i>	Perekaman video secara <i>realtime</i>
<i>Server Localdisk Raspberry pi</i>	Penyimpanan hasil gambar deteksi objek

Penggunaan *Raspberry Pi* untuk berbagai aplikasi komputasi dengan fokus pada efisiensi sumber daya dan perangkat berbiaya yang rendah. Keunggulan *Raspberry Pi* memiliki efisiensi sumber daya yang

cukup untuk melakukan identifikasi objek secara Realtime [16]. Selain itu *Raspberry Pi* untuk deteksi objek dengan memproses data gambar dari *webcam* menggunakan pustaka *OpenCv* [17]. Gambar 3 memperlihatkan skema sistem yang dirancang.



Gambar 3. Perancangan Sistem

Pengolahan Data Dan Pelatihan Model

Pada tahap persiapan model dataset yang telah dikumpulkan dan dialokasikan dalam kategori di lakukan teknik pengolahan dataset sampai pelatihan dan pengujian model.

1. Pengolahan Dataset

Dengan mengubah ukuran gambar menjadi 240x240 pixel. Teknik tersebut dilakukan untuk mengoptimalkan proses saat pelatihan model dan mengurangi beban komputasi [18]. pada perangkat dengan sumber daya terbatas seperti *Raspberry Pi*. Dengan mengurangi resolusi gambar tersebut, konfigurasi mengurangi beban komputasi. Selanjutnya, tahapan augmentasi ini meliputi teknik *Random Crop* dengan pada *file pipeline config* sebelum pelatihan, Dengan digunakan teknik ini bertujuan untuk mempelajari pola citra gambar lebih dekat.

2. Pembagian Dataset

Pembagian Data gambar dalam persiapan model ini dibagi menjadi tiga set, yakni *train set*, *test set* dan *val set*. Pembagian data ini setelah proses augmentasi direncanakan dengan alokasi 70% untuk *train set*, 20% *validasi set*, 10% *test set*. Proses pembagian data ini memperbanyak untuk data *train* agar mempelajari pola objek gambar pada saat pelatihan, serta digunakan *validasi* cukup untuk menilai performa model sebelum diuji.

3. Pelatihan model

MobileNetV2 digunakan sebagai *backbone* dari model ini. Model ini dibangun dan dilatih menggunakan *TensorFlow Object Detection API* sebuah *framework* yang dirancang untuk membangun model deteksi objek dengan efisien. Pendekatan transfer learning diterapkan untuk memanfaatkan model pralatih (*pre-trained model*) yang telah dilatih. Beberapa parameter pelatihan disesuaikan untuk mengoptimalkan kinerja model, yaitu :

- Learning rate* yang mengatur seberapa cepat model memperbarui bobot selama pelatihan.
- Batch size* menentukan jumlah sampel data yang diproses dalam satu iterasi pelatihan
- Epoch* yang mengacu pada jumlah siklus penuh pelatihan di mana model memproses seluruh dataset.

- Pipeline config* digunakan untuk konfigurasi training arsitektur dari model.

Evaluasi Model

Tahapan ini dilakukan setelah mencapai akurasi pelatihan yang baik, selanjutnya adalah optimasi model dan konversi model dalam format *tfLite* yang bertujuan model lebih optimal dan ringan. Selain itu untuk menilai performa model SSD *MobileNetV2* dalam mendeteksi pengendara motor yang menggunakan helm dan tidak. Proses pengujian ini menggunakan dataset uji (*test set*), yaitu data yang tidak pernah digunakan selama proses pelatihan. Setelah model selesai dilatih, tahap evaluasi dilakukan untuk menilai kinerjanya dan evaluasi yang menggambarkan hasil deteksi objek dalam empat kategori. Seperti *True Positive* (TP) jumlah nilai prediksi yang terjadi sesuai nilai dengan nilai sebenarnya, *False Positive* (FP) jumlah nilai prediksi yang terjadi, namun tidak sesuai dengan nilai sebenarnya, *False Negative* (FN) jumlah nilai prediksi yang tidak terjadi dan tidak sesuai dengan nilai sebenarnya [19]. Berdasarkan, sejumlah metrik evaluasi dihitung untuk menggambarkan performa model dalam deteksi objek dari penggunaan *Mean Average Precision* (mAP) [20].

Hasil Evaluasi dilakukan untuk memastikan bahwa model dapat memberikan hasil akurasi yang baik dan dihitung berdasarkan metrik-metrik tersebut, sementara setiap kesalahan deteksi (*misclassification*) dianalisis untuk memahami keterbatasan model. Pada nilai Akurasi mengukur tingkat keakuratan model dalam mengklasifikasi objek dan Presisi menggambarkan nilai akurasi antara data yang digunakan dengan hasil prediksi. Sedangkan *Recall* merepresentasikan keberhasilannya mendeteksi objek dan *F1-Score* dirancang untuk menghitung kombinasi dari perbandingan nilai *Recall* dan Presisi. Selanjutnya perhitungan rumus deteksi objek untuk evaluasi metrik [21] adalah sebagai berikut ini.

- Akurasi (*Accuracy*): Mengukur prediksi yang benar terhadap total data yang diuji.

$$Accuracy = \frac{TP+TN}{TOTAL} \quad (1)$$

- Presisi (*Precision*): Mengukur prediksi positif yang benar dibandingkan dengan total prediksi positif.

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

- Recall* untuk mengukur prediksi positif yang benar dibandingkan dengan total data positif sebenarnya.

$$Recall = \frac{TP}{FN+TP} \quad (3)$$

- Mean Average Precision* (mAP) dengan Metode evaluasi ini menghitung rata-rata presisi di berbagai nilai *threshold Intersection over Union* (IoU) untuk setiap kelas objek. mAP menjadi indikator utama dalam menilai performa keseluruhan model dalam mendeteksi berbagai kategori objek

- e. *F1 Score* Merupakan rata-rata dari *Precision* dan *Recall*, yang digunakan untuk menggabungkan kedua metrik tersebut dalam satu nilai evaluasi.

$$F1\ Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (4)$$

Hasil dan Pembahasan

Hasil dari penelitian ini berupa model dengan arsitektur *MobileNetV2* dan algoritma SSD untuk deteksi penggunaan helm bagi pengendara sepeda motor. Pengumpulan dataset ini sebanyak 1363 gambar untuk dilakukan training dan pengujian.

Hasil Pengumpulan Dataset

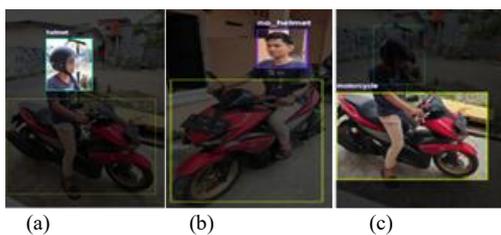
Dataset yang telah dikumpulkan, selanjutnya dilakukan teknik pembagian data. Dalam penyusunan model data gambar dibagi menjadi tiga set, yakni *train set*, *test set* dan *val set*. Pembagian data direncanakan dengan alokasi 70% untuk *train set*, 10% *test set*, 20% *val set*. Dari dataset ini akan dilakukan untuk pelabelan model objek serta pelatihan dan pengujian. Selanjutnya dataset yang telah dibagi ini dilakukan proses *processing* dan *augmentasi*. Berikut ini adalah rincian data yang telah dilakukan proses pembagian data. Rincian pembagian dataset ditunjukkan pada Tabel 3.

Tabel 3. Hasil Pengumpulan Dataset

Dataset	Jumlah Gambar	Pembagian data
pelatihan	953	70%
validasi	273	20%
uji	137	10%

Hasil Pelabelan Model Objek

Hasil dari pelabelan objek bertujuan untuk penamaan dari sebuah kategori kelas untuk objek yang akan dideteksi. Pelabelan ini menentukan batas kotak (*Bounding Box*). Gambar 4 berikut ini menyajikan hasil dari pelabelan objek gambar.



Gambar 4. Hasil Pelabelan Model Objek (a) *Helmet* (b) *No Helmet* (c) *Motorcycle*

Dengan memberikan sebuah label objek pada gambar yaitu Kategori objek terdiri tiga kelas yakni "*Helmet*", "*NoHelmet*", "*Motorcycle*". Selanjutnya penamaan label model objek digunakan untuk membaca dari sebuah gambar yang telah dideteksi oleh sebuah algoritma CNN (*Convolutional Neural Network*) dan SSD (*Single Shot Multibox Detector*). Hasil deteksi akan menampilkan akurasi berupa nilai skor dari label objek.

Hasil Penerapan Sistem

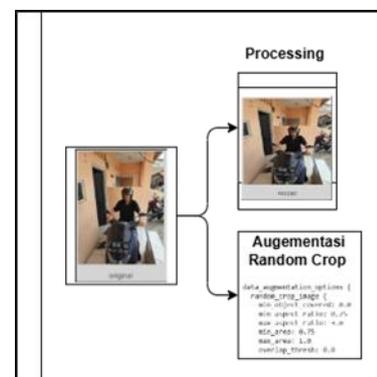
Hasil Penerapan sistem ini menggunakan perangkat *Raspberry Pi* dan pemilihan webcam dilakukan berdasarkan resolusi, *frame rate*, dan kemampuan menangkap gambar dalam kondisi cahaya rendah. *Webcam* yang memiliki resolusi tinggi dapat membantu dalam menangkap detail objek, sementara *frame rate* yang stabil memastikan sistem dapat mendeteksi objek secara *real-time*. Berikut ini adalah hasil dari penerapan sistem yang dibuat. Contoh hasil visual dari sistem yang dijalankan ditampilkan pada Gambar 5.



Gambar 5. Hasil Penerapan Sistem

Hasil Pengolahan data dan Pelatihan Model

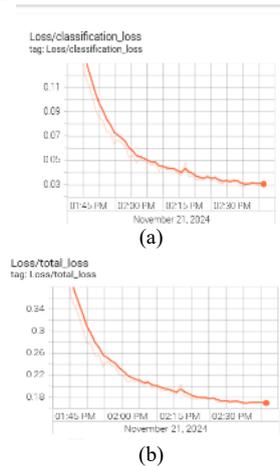
Persiapan pelatihan model ini menggunakan algoritma CNN (*Convolutional Neural Network*) dengan arsitektur *MobileNetV2* dan SSD (*Single Shot Multibox Detector*). Tahapan persiapan pelatihan model ini mengatur nilai *parameter learning rate*, *Epoch* dan *steps 1000*. Selain itu, dataset yang sudah dilakukan pengolahan data yaitu tahapan *processing* *resize* gambar ukuran 240x240 piksel dengan mengirimkan input kedalam arsitektur *mobileNetv2*. Proses ini bertujuan agar model lebih optimal saat pelatihan. Selanjutnya pada tahapan *augmentasi* yaitu menerapkan teknik *Random Crop* di *file pipeline config* sebelum pelatihan. Berikut ini adalah dari hasil *processing* dengan *Resize* gambar dan teknik *augmentasi*. Ilustrasi hasil *resize* dan *augmentasi* disajikan pada Gambar 6.



Gambar 6. Hasil Pengolahan Data

Hasil dari pelatihan ini menggunakan teknik perubahan pada nilai parameter dan melakukan perbaikan pada dataset dari hasil pelabelan model

objek. Berikut ini Hasil dari pelatihan pada Gambar 7. (a) ini menunjukan Selanjutnya, Pelatihan kedua ini dengan *epoch* sebanyak 5000, *batch size* 128 dan menggunakan *steps* 1000. *classification loss* cukup tinggi karena model mengalami kesulitan dalam membedakan kategori objek dengan nilai terendah sebesar 0.02982 Namun nilai ini menurun secara signifikan dari model yang mempelajari pola gambar. Penurunan *total loss* menunjukan pada Gambar 7. (b) sebesar 0.1683, model telah mencapai stabilitas dan memiliki kinerja yang cukup untuk mendeteksi label objek dari beberapa kategori. Berikut ini adalah hasil dari pelatihan.



Gambar 7. (a) Loss Classification (b) Total Loss

Dari hasil pelatihan menggunakan algoritma CNN (*Convolutional Neural Network*) dan SSD (*Single Shot Multibox Detector*). Selanjutnya tahap pengujian seberapa banyak data yang di *Input* menggunakan data test format *TF Record* pada Gambar 9. Berikut ini rincian data gambar hasil akurasi deteksi dalam percobaan pertama dan kedua. Gambar 8 menunjukkan hasil pengujian pertama dan kedua terhadap model.



Gambar 8. (a) Hasil Pengujian Pertama (b) Hasil Pengujian Kedua

Hasil Evaluasi Model

Hasil Evaluasi model dari algoritma CNN (*Convolutional Neural Network*) dan SSD (*Single Shot Multibox Detector*) untuk Deteksi penggunaan helm bagi pengendara sepeda motor. Menggunakan arsitektur *MobileNetv2* sebagai basis model untuk *Feature Extraction* yang masih menggunakan lapisan *pointwise* dan *depthwise*. Menggunakan bobot *pre-trained* dari *dataset*, dengan input gambar berukuran 240x240. Hasil pelatihan dan pengujian menunjukan nilai representasi yang baik. Berikut ini adalah rincian data dari hasil evaluasi model.

```

Class motorcycle (2):
  Precision: 0.99
  Recall: 0.99
  F1-Score: 0.99
  TP: 277, FP: 4, FN: 4
Class helmet (1):
  Precision: 0.95
  Recall: 0.95
  F1-Score: 0.95
  TP: 165, FP: 9, FN: 8
Class no_helmet (3):
  Precision: 0.99
  Recall: 0.99
  F1-Score: 0.99
  TP: 134, FP: 2, FN: 2
    
```

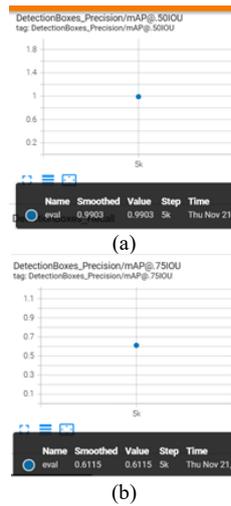
Gambar 9. Hasil Pengujian Evaluasi Model

Hasil evaluasi model menggunakan arsitektur *MobileNetv2* dan SSD (*Single Shot Multibox Detector*) Menunjukan nilai performa dalam mendeteksi tiga kelas objek. Pada label objek *Motorcycle*, model mencapai *Precision*, *Recall*, dan *F1-Score* masing-masing sebesar 0,99, dengan 277 *True Positives* (TP), 4 *False Positives* (FP), dan 4 *False Negatives* (FN). Untuk kelas *Helmet*, *Precision*, *Recall*, dan *F1-Score* tercatat sebesar 0,95, dengan 165 TP, 9 FP, dan 8 FN. Sementara itu, kelas *No_Helmet* juga menunjukkan kinerja optimal dengan nilai *Precision*, *Recall*, dan *F1-Score* sebesar 0,99, serta 134 TP, 2 FP, dan 2 FN. Secara keseluruhan, model memiliki tingkat akurasi yang tinggi dalam mendeteksi pelanggaran penggunaan helm dengan sedikit kesalahan deteksi. Tabel 4 akan menyajikan perhitungan akurasi deteksi untuk evaluasi model dari gambar 4.

Tabel 4. Evaluasi Hasil pengujian

Kategori Objek	TP	FN	FP	Precision	Recall	F1-Score
Helmet	165	8	9	94%	95%	95%
Nohelmet	134	2	2	98%	98%	98%
Motorcycle	277	4	4	98%	98%	98%

Selanjutnya menampilkan nilai *mAP* (*Mean Average Precision*) menggunakan data test dari kategori label objek, nilai 0.6 untuk *threshold* digunakan dalam prediksi objek *bounding box* dari *frame*. Berikut ini adalah Gambar 10. (a) Hasil dari *mAP50* mendapatkan 99% dengan nilai 0.9903, presisi yang tinggi dari pengenalan pola objek berbagai gambar dan pada Gambar 10. (b) *mAP75* hanya berkisar 66% dengan angka terendah 0.6115, dari ukuran anotasi objek yang kurang presisi.



Gambar 10. (a) Hasil mAP50 (b) Hasil mAP75

Hasil Pengujian

Hasil pengujian ini secara *Realtime* Dengan perangkat *Raspberry pi* yang terhubung dengan kamera *webcam*. Pada gambar 11. memperlihatkan hasil deteksi objek dari model yang telah di lakukan pelatihan dan pengujian. Hasil pelabelan model objek berpengaruh pada tingkat deteksi. Pelabelan atau anotasi objek yang kurang presisi menyebabkan penurunan dalam tingkat akurasi atau kegagalan dari sistem deteksi objek yang memakai helm dengan benar maupun tidak. Permasalahan tersebut, sistem yang telah dirancang untuk deteksi pelanggaran penggunaan helm ini akan menyimpan gambar di penyimpanan perangkat *Raspberry Pi*, jika kategori objek terdeteksi pelanggaran dari pengendara sepeda motor tidak menggunakan helm. Berikut ini adalah hasil dari pengujian langsung secara *realtime* dari sistem deteksi objek pelanggaran penggunaan helm bagi pengendara sepeda motor.



Gambar 11. Hasil pengujian deteksi (a) Tidak menggunakan helm (b) Menggunakan helm

Pada Gambar 11. (A) Pengendara sepeda motor yang terdeteksi tidak menggunakan helm, Sistem akan bekerja menampilkan hasil akurasi deteksi dengan menunjukan Jenis pelanggaran tidak menggunakan helm. Selanjutnya pada gambar (B) adalah pelanggaran dari penggunaan helm, tidak digunakan dengan benar. Pada gambar (C) menunjukan hasil dari pengendara menggunakan helm, sistem akan bekerja menampilkan hasil akurasi dan tidak pelanggaran. Berikut ini adalah tabel dari hasil akurasi deteksi

selama pengujian secara *realtime*. Tabel 5 merangkum hasil akurasi deteksi selama pengujian *realtime*.

Tabel 5. Hasil Pengujian

Kategori objek	Akurasi Deteksi <i>Realtime</i>						Jarak Deteksi	Jenis Pelanggaran
	1	2	3	4	5	6		
Pengendara Tidak menggunakan helm	75 %	71 %	88 %	87 %	91 %	90 %	<250 cm	Tidak Menggunakan Helm dan Pelanggaran Penggunaan Helm
Pengendara menggunakan helm	60 %	76 %	70 %	77 %	89 %	86 %	<250 cm	Tidak ada pelanggaran

Kesimpulan

Dari hasil *dataset* sebanyak 1363 gambar dari kategori objek *Helmet*, *Nohelmet* dan *Motorcycle* dengan algoritma *Convolutional neural network* dan kinerja *SSD (Single Shot Multibox Detector)*, arsitektur *MobileNetV2* mendapatkan hasil.

1. Hasil pelatihan menunjukkan bahwa model berhasil mencapai akurasi sebesar 100% pada data pelatihan dalam membedakan antara pengendara yang memakai helm dan yang tidak. Data hasil pelatihan ini mendapat nilai akurasi tertinggi dari 3 kategori objek *helmet* 95%, *Nohelmet* 98% dan *Motorcycle* 98%.
2. Hasil pengujian untuk evaluasi model menggunakan mAP dengan thresold 0.6 dapat memprediksi objek dari 3 kelas objek. Data menunjukan Map 50 mendapatkan akurasi tertinggi yaitu 99%, namun untuk mAP75 hanya mendapatkan 66%. Nilai akurasi mAP75 secara tingkat akurasi masih banyak data ukuran dari teknik anotasi *Bounding Box* kurang presisi, sehingga model mengalami kegagalan dalam deteksi mencapai lebih dari 75%
3. Hasil Pengujian secara *Realtime* mendapatkan akurasi tertinggi yaitu sebesar 91 % untuk jenis pelanggaran tidak menggunakan helm, penggunaan helm dan 89% untuk pengendara yang menggunakan helm.

Daftar Pustaka

[1] P. Lumba, A. Ariyanto, A. Alfirahmi, and R. Rismalinda, "Dampak Peningkatan Pengendara Sepeda Motor Dibawah Umur terhadap Jumlah Kecelakaan di Indonesia," *Aptek*, vol. 14, no. 2, pp. 94-102, 2022.

[2] D. A. Nurjaman, I. D. Erianti, B. A. Salsabilla, C. C. Sihombing, S. A. Prihartiwi, and D. P. Novita, "Penegakan Hukum Terhadap Pelanggaran Lalu Lintas Di Karawang," *Cendekia Ilmiah*, pp. 540-545, 2024, doi: 10.56799/jceki.v4i1.6292.

[3] P. R. Aningtiyas, A. Sumin, and S. Wirawan, "Pembuatan Aplikasi Deteksi Objek Menggunakan Tensorflow Object Detection Api Dengan Memanfaatkan Ssd Mobilenet V2 Sebagai Model

- Pra-Terlatih,” *Ilmiah Komputasi*, pp. 421-430, 2020, doi: 10.32409/jkistik.19.3.68.
- [4] A. Nugroho and M. R. Cahyono, “Implementasi Object Recognition Pada Rambu-Rambu Dan Lampu Lalu Lintas Dengan Raspberry Pi Dengan Algoritma Yolo V5,” *Sebatik*, pp. 549-556, 2022, doi: 10.46984/sebatik.v26i2.2047.
- [5] T. Mulyadi, M. Rizal, A. Amiruddin, T. Informatika, and S. Akba Makassar, “Penerapan Teknologi Augmented Reality Sebagai Sarana Edukasi Perkenalan Alat Musik dengan Metode Single Marker,” *J. Inf. Syst. Manag.*, vol. 1, no. 2, pp. 18–21, Jan. 2020, doi: 10.24076/JOISM.2020V1I2.26.
- [6] M. N. Baay, A. N. Irfansyah, and M. Attamimi, “Sistem Otomatis Pendeteksi Wajah Bermasker Menggunakan Deep Learning,” *Teknik Its*, pp. 64-70, 2021
- [7] A. Prima, “Rancang Bangun Sistem Pendeteksi Aneka Ragam Buah Menggunakan Mobilenetv2,” *Jsisfotek (Jurnal Sistim Informasi Dan Teknologi)*, pp. 208-215, 2023, doi: 10.60083/jsisfotek.v5i2.217.
- [8] A. Miranto, “Real Time Object Detection Menggunakan Mobilenet-Ssd Pada Sistem Keamanan Ruangan Dengan Bot Telegram Sebagai Notifikasi User,” *Elektronik Ilmu Komputer Udayana*, pp. 211-216, 2024, doi: 10.29408/edumatic.v9i1.29004.
- [9] M. A. Aziz, A. S. Rachman, and I. M. Sukmadana, “Pengujian Deteksi Objek Manusia Menggunakan Jetson Nano Dengan Model SSD Mobilenetv2,” *Informatika Teknologi Dan Sains*, vol. 6, no. 2, 830-840, 2024, doi: 10.51401/jinteks.v6i4.4899.
- [10] A. W. Suryanto, and A. R. Kardian, “Deteksi Pelanggaran Lalu Lintas Tidak Menggunakan Helm Dengan YOLO V4 Pada Sistem ETLE,” *Jurnal Teknik Komputer*, vol. 9, no. 2, pp. 129-134, 2023, doi: 10.31294/jtk.v9i2.14798.
- [11] I. R. Ilham and F. Utaminingrum, “Deteksi Helm untuk Keamanan Pengendara Sepeda Motor dengan Metode CNN (Convolutional Neural Network) menggunakan Raspberry Pi,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 5, no. 11, pp. 4734-4739, 2021
- [12] F. Fuadi, C. Setianingsih, and M. W. Paryasto, “Sistem Deteksi Pengendara Sepeda Motor Tanpa Helm Menggunakan Algoritma SSD,” *eProceedings of Engineering*, vol. 10, no. 1, 2023
- [13] M. A. Meidyan and W. Yustanti, “Implementasi Metode You Only Look Once (YOLOV5) Dalam Deteksi Pelanggaran Helm,” *Journal of Emerging Information System and Business Intelligence (JEISBI)*, vol. 5, no. 3, pp. 214-222, 2024, doi: 10.26740/jeisbi.v5i3.60517.
- [14] S. B. Setyawan, W. Pribadi, H. Arrosida, and E. P. Nugroho, “Sistem Deteksi Pengendara Sepeda Motor Tanpa Helm dan Kelebihan Penumpang pada Dengan Menggunakan YOLO V3,” In *Prosiding Seminar Nasional Terapan Riset Inovatif (SENTRINOV)*, vol. 7, no. 1, pp. 430-438, 2021, November
- [15] M. Y. Wibowo, H. Hikmayanti, and A. F. Masruriyah, “Deteksi Penggunaan Masker Pada Tempat Umum menggunakan Algoritma Convolutional Neural Network,” *Scientific Student Journal For Information, Technology And Science*, vol. 5, no. 2, pp. 131-136, 2024
- [16] A. Israk, R. Satra, and F. Fattah, “Perancangan Sistem Pendeteksi Pelanggaran Lampu Lalu Lintas Menggunakan Raspberry Pi 3 Berbasis Internet Of Things,” *Buletin Sistem Informasi Dan Teknologi Islam*, pp. 275-283, 2021, doi: 10.33096/busiti.v2i4.1008.
- [17] Sutarti, Siswanto, & A. P. Jutika, “Implementasi Face Recognition Berbasis Haar-Cascade Classifier Pada Sistem Keamanan Rumah Menggunakan Dual-Camera,” *Infotech*, pp. 106-115, 2022, doi: 10.31949/infotech.v8i2.3610.
- [18] S. S. Asmoro, M. F. Amrulloh, M. A. Toybah, and M. A. Saputra, “Rancang Bangun Aplikasi Mobile Untuk Klasifikasi Jenis Ikan Koi Menggunakan Algoritma Convolutional Neural Network,” *Prosiding Seminar Nasional Teknologi Dan Sains*, pp. 270-277, 2024, doi: 10.29407/stains.v3i1.4312
- [19] M. Iqbal, D. M. Midyanti, and S. Bahri, “Deteksi Objek Manusia Pada Citra Menggunakan Single Shot Detector (Ssd) Berbasis Edge Computing,” *Teknologi Informasi Dan Ilmu Komputer*, pp. 547-556, 2024, doi: 10.25126/jtiik.938446.
- [20] M. D. Pratama, B. Priyatna, S. S. Hilabi, and A. L. Hananto, “Deteksi Objek Kecelakaan Pada Kendaraan Roda Empat Menggunakan Algoritma Yolov5,” *Ilmiah Sistem Informasi*, vol. 12, no. 2, pp. 15-26, 2022, doi: 10.26594/teknologi.v12i2.3260.
- [21] O. Bouazizi, C. Azroumahli, A. E. Mourabit, and M. Oussouadi, “Road Object Detection Using SSD-MobileNet Algorithm Case Study For Rea-Time ADAS Applications,” *Journal Of Robotics And Control*, pp. 551-560, 2024, doi: 10.18196/jrc.v5i2.21145.