

SIMONKIDI : SISTEM MONITORING FOKUS PENGEMUDI PADA SUPIR BUS BERBASIS ALGORITMA YOLO (*YOU ONLY LOOK ONCE*)

Muh Irhas Rafiqi

Politeknik Keselamatan
Transportasi Jalan

Jl. Perintis Kemerdekaan No.17,
Slerok, Kec. Tegal Timur, Kota Tegal,
Jawa Tengah (52125)

Email:

21021047@taruna.pktj.ac.id

Humam Eka Saputra

Politeknik Keselamatan
Transportasi Jalan

Jl. Perintis Kemerdekaan No.17,
Slerok, Kec. Tegal Timur, Kota
Tegal, Jawa Tengah (52125)

Email:

21021043@taruna.pktj.ac.id

Helmi Wibowo

Politeknik Keselamatan
Transportasi Jalan

Jl. Perintis Kemerdekaan No.17,
Slerok, Kec. Tegal Timur, Kota
Tegal, Jawa Tengah (52125)

Email:

helmi.wibowo@pktj.ac.id

Abstract

The significant growth in the number of vehicles is directly proportional to the increase in traffic accidents, especially in Indonesia. One of the leading causes of accidents is human factors, including risky driving behaviors such as drowsiness, drinking, using a phone, and not wearing a seatbelt. This study developed a Driver Focus Monitoring System based on YOLOv8 (SIMONKIDI) to detect such risky behaviors in real-time. The dataset used consists of 1,109 images, divided into 800 images for training data, 187 images for validation data, and 163 images for testing data. The training process was conducted over 100 epochs, detecting four classes of risky behavior. The Confusion Matrix values range from 0.800 to 0.960, with an accuracy score 0.865, Precision 0.916, Recall 0.920, and an F1 score 0.870. These findings indicate that the YOLOv8-based SIMONKIDI system demonstrates efficient and accurate performance in detecting risky driving behaviors. Therefore, this system is expected to contribute to reducing traffic accident rates and enhancing road safety.

Keywords: Traffic Accidents, Risky Driving, Driver Behavior, Monitoring System, YOLOv8

Abstrak

Pertumbuhan jumlah kendaraan yang signifikan berbanding lurus dengan peningkatan tingkat kecelakaan lalu lintas, terutama di Indonesia. Salah satu penyebab kecelakaan karena faktor manusia diantaranya perilaku mengemudi berisiko seperti mengantuk, minum, menelpon, dan tidak menggunakan sabuk pengaman. Penelitian ini mengembangkan Sistem Monitoring Fokus Pengemudi berbasis YOLOv8 (SIMONKIDI) untuk mendeteksi perilaku berisiko tersebut secara *real-time*. Dataset yang digunakan terdiri dari 1109 gambar yang terbagi menjadi 800 gambar untuk data pelatihan, 187 gambar untuk data validasi, dan 163 gambar untuk data pengujian. Proses pelatihan dilakukan selama 100 *epochs* dengan empat kelas perilaku yang dideteksi. Rentang nilai *Confusion Matrix* berkisar 0,80 hingga 0,96, dengan nilai *Accuracy* 0,865, *Precision* 0,916, *Recall* 0,92, dan *F1 score* sebesar 0,87. Temuan ini mengindikasikan bahwa SIMONKIDI berbasis YOLOv8 memiliki kinerja yang efisien dan akurat dalam mendeteksi perilaku mengemudi berisiko. Dengan demikian, sistem ini diharapkan dapat berkontribusi dalam mengurangi tingkat kecelakaan lalu lintas dan meningkatkan keselamatan berkendara.

Kata Kunci: Kecelakaan Lalu Lintas, Mengemudi Berisiko, Perilaku Pengemudi, Sistem Monitoring, YOLOv8

PENDAHULUAN

Pertumbuhan jumlah kendaraan berbanding lurus dengan tingkat kecelakaan. Kecelakaan

lalu lintas menjadi tantangan utama dalam sistem transportasi di berbagai negara, termasuk Indonesia, yang mengalami peningkatan kejadian yang mengkhawatirkan. Hal tersebut didukung oleh data Korlantas Polri yang menyatakan bahwa pada tahun 2023 jumlah kecelakaan meningkat sebesar 0,06% dibandingkan tahun sebelumnya. Oleh karena itu, Pemerintah Indonesia memerlukan strategi dalam rangka mencegah terjadinya peningkatan jumlah kecelakaan yang signifikan (KEMENHUB, 2023).

Data kepolisian menunjukkan bahwa sebagian besar kecelakaan disebabkan oleh sejumlah faktor yaitu 61% dari kecelakaan disebabkan oleh faktor manusia, 9% disebabkan oleh kendaraan, dan 30% disebabkan oleh infrastruktur (KEMENHUB, 2017). Faktor manusia dipengaruhi oleh perilaku pengemudi dalam berkendara. Perilaku mengemudi berisiko adalah perilaku pengemudi yang dapat berisiko terjadi kecelakaan saat mengemudi, keterlibatan dalam perilaku seperti mengemudi sambil melakukan aktivitas tambahan, seperti minum, atau menelpon saat mengemudi (Ulleberg & Rundmo, 2003). Selain itu, kelelahan dan mengantuk juga menjadi penyebab utama kecelakaan lalu lintas (Zuraida, 2015). Seseorang dikatakan mengantuk apabila kurangnya konsentrasi dan kewaspadaan, menguap dan meningkatnya frekuensi kedipan mata (Nurdjanah & Puspitasari, 2017).

Melihat dampak negatif dan risiko yang ditimbulkan oleh perilaku berisiko pengemudi, pengembangan sistem yang mampu mendeteksi perilaku ini dengan cepat dan memberikan peringatan menjadi krusial. Sistem-sistem yang ada saat ini, seperti sensor kecepatan standar dan minimnya peringatan penggunaan sabuk pengaman, belum selalu efektif dalam mencegah perilaku berisiko saat mengemudi. Oleh karena itu, pengembangan sistem yang lebih komprehensif, yang juga dapat mengidentifikasi perilaku seperti mengantuk, dan mengemudi tanpa sabuk, penggunaan *handphone* dalam berkendara menjadi kebutuhan yang mendesak (Rahayu et al., 2024).

Sistem deteksi perilaku pengemudi khususnya telah diteliti oleh beberapa peneliti sebelumnya. Seperti penelitian menerapkan deteksi kantuk dengan memanfaatkan algoritma *Haar Cascade*. Kedipan mata dihitung berdasarkan *Eye Aspect Ratio* (EAR). Dalam penelitian tersebut menunjukkan bahwa sistem dapat mendeteksi kantuk dengan tingkat *accuracy* 92,5%, *precision* 89,71%, dan *recall* 96% (Ramadana Lubis et al., 2023).

Salah satu inovasi yang diusulkan dalam upaya meningkatkan keselamatan berkendara adalah mengembangkan sistem deteksi perilaku pengemudi berbasis *computer vision*. Sistem dirancang dengan memanfaatkan algoritma *YOLOv8* (*You Only Look Once*) dengan perangkat lunak yaitu *Google Collaboratory* dan *Roboflow*. Peneliti berharap penelitian ini dapat mengembangkan model deteksi perilaku pengemudi secara *real time* yang mampu mendeteksi perilaku pengemudi dengan efektif dan akurat berdasarkan data gambar dan video.

METODE PENELITIAN

Metode *You Only Look Once* (YOLO) digunakan untuk mendeteksi objek dalam penelitian ini. YOLO sangat efisien dalam mendeteksi objek karena hanya memerlukan satu kali pemrosesan gambar untuk mendeteksi semua objek yang ada di dalamnya (Nafis Alfarizi et

al., 2023). Implementasi dari metode ini tersedia pada platform *open source neural network* bernama *Darknet*. Cara kerja *YOLO* adalah dengan menganalisis seluruh gambar dalam satu kali pandangan, kemudian meneruskannya melalui jaringan saraf untuk mendeteksi objek-objek yang ada. Karena hanya memerlukan satu kali pemrosesan gambar, metode ini dinamakan *You Only Look Once (YOLO)* (Redmon et al., 2016). Dalam penelitian ini pengujian model deteksi menggunakan metode *You Only Look Once (YOLO)* dilakukan untuk menganalisis performa model deteksi secara langsung dengan spesifikasi perangkat keras sesuai pada tabel 1.

Tabel 1. Perangkat Keras yang Digunakan


No	Perangkat Keras	Spesifikasi
1	Jenis Laptop	Lenovo Ideapad Slim 5
2	<i>Processor</i>	AMD RYZEN 5 4000 Series
3	<i>Random Access Memory (RAM)</i>	8 GB
4	<i>Hardisk SSD</i>	556 GB

Selain perangkat keras pada tabel 1, diperlukan juga perangkat lunak sesuai pada tabel 2. Sebagai media untuk memproses model deteksi agar dapat diimplementasikan pada perangkat keras yang digunakan.

Tabel 2. Perangkat Lunak yang Digunakan

No	Perangkat Lunak	Kegunaan
1.	<i>Roboflow</i>	Anotasi dataset dan <i>preprocessing</i> model
2.	<i>Google Collaboratory</i>	Melatih dataset yang telah di proses <i>roboflow</i>

Untuk menyusun suatu model deteksi menggunakan *YOLOv8*, peneliti mengikuti alur penelitian yang ditunjukkan pada gambar 1.




Gambar 1. Diagram Alir Penelitian

1. Pengumpulan data gambar untuk setiap kelas dilakukan dengan mengambil dataset dari *Kaggle* dan dokumentasi secara langsung dari tindakan yang mengarah pada perilaku berisiko saat berkendara. Bentuk perilaku berisiko saat berkendara dirangkum sesuai pada tabel 3.

Tabel 3. Bentuk Perilaku Berisiko


No	Deskripsi Perilaku Pengemudi	Gambar
1	Pengemudi dalam keadaan mengantuk	
2	Tidak menggunakan <i>seatbelt</i>	
3	Mengemudi sambil memegang botol minum	
4	Mengemudi sambil menelpon	

Jumlah dataset yang digunakan sebanyak 1109 gambar, kemudian diupload pada laman *Roboflow* sebagai pengolah dataset sebelum dilakukan pelatihan pada *Google Collab*.



Gambar 2. Anotasi Dataset

2. Melakukan *preprocessing* dengan melakukan anotasi gambar seperti gambar 2. Anotasi gambar dilakukan dengan memberikan label pada objek yang termasuk dalam kelas deteksi seperti wajah mengantuk, *seatbelt*, botol minum, dan telepon genggam.



Gambar 3. Klasifikasi Dataset

Klasifikasi dataset menjadi data untuk pelatihan (*train*), data validasi (*valid*) dan data untuk pengujian performa model deteksi (*test*) seperti yang ditunjukkan pada gambar 3. Pada bagian *preprocessing* lakukan *resize* menjadi ukuran 640 x 640 dan auto orient. Dimana terdapat 1109 dataset dengan 759 untuk data *train*, 187 untuk data *valid* dan 163 untuk data *test*. Tampilan hasil *preprocessing* dapat dilihat pada gambar 3.

3. Memasukkan *Snippet Code* pada *Google Collaboratory* untuk memanggil dataset dari *Roboflow*. Salin *snippet code* kemudian pilih *notebook YOLOV8* untuk melakukan pelatihan model deteksi objek. Proses pelatihan memiliki beberapa langkah, seperti memilih *hyperparameter*, menentukan dataset pelatihan dan validasi serta melakukan pelatihan pada model yang ditunjukkan pada gambar 4. Dengan menggunakan model *YOLOv8s*, jumlah *epoch* 100 dan *image size* 800.

```
[6] !mkdir (HOME)/datasets
    !cd (HOME)/datasets

    !pip install roboflow

    from roboflow import Roboflow
    rf = Roboflow(api_key="e6PC4HcNF28F8Gnu3ug")
    project = rf.workspace("simonkidi").project("simonkidi")
    version = project.version(2)
    dataset = version.download("yolov8")
```

Gambar 4. Menempelkan *Snippet Code* di *Google Colab*

4. Evaluasi Model : Parameter pengukuran untuk mengevaluasi akurasi model dan tingkat kepercayaan dalam mengklasifikasikan data baru. Matriks evaluasi yang digunakan meliputi *Confusion Matrix*, *Mean Average Precision*, *Results*, *Precision*, *Recall*, dan *F1-Score* (Putra & Mulyana, 2024).
 - a. *Confusion Matrix*
Confusion Matrix adalah tabel untuk menilai kinerja model deteksi dimana hasil prediksi model deteksi di setiap kelas dibandingkan dengan nilai yang sebenarnya (Rofii et al., 2021).

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Gambar 5. Tabel Confusion Matrix

b. *Accuracy*

Accuracy adalah rasio prediksi benar (positif atau negatif) dengan jumlah data keseluruhan. Nilai dari *accuracy* dapat di hitung dengan persamaan (1).

$$\frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

c. *Precision*

Precision dapat didefinisikan sebagai rasio prediksi benar positif dibandingkan dengan keseluruhan hasil yang prediksi positif. Pada persamaan (2) dapat digunakan untuk menentukan nilai dari *precision*.

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

d. *Recall*

Recall merupakan rasio prediksi benar positif dengan keseluruhan data yang benar positif. Nilai dari *recall* dapat di hitung dengan persamaan (3).

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

e. *F1 -Score*

F1 -Score menunjukkan perbandingan presisi dan recall rata rata yang dibobotkan. Nilai dari *F1-Score* dapat di hitung dengan persamaan (4).

$$\frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4)$$

Setelah selesai melakukan pelatihan model, selanjutnya simulasi dengan mencoba melakukan pendeteksian melalui gambar, video maupun secara *real time* dengan menggunakan *device* laptop.


HASIL DAN PEMBAHASAN

Pada sub bab ini dipaparkan hasil evaluasi model deteksi perilaku mengemudi yang dikembangkan menggunakan algoritma *YOLOv8* dengan sebaran dataset pada tabel 4 terdiri dari dataset *Train*, *Valid* dan *Test*. Evaluasi dilakukan untuk mengukur kinerja dari model

deteksi dalam mendeteksi perilaku mengemudi melalui beberapa parameter kunci yaitu *Confusion Matrix Normalized*, *Accuracy*, *Precision*, *Recall* dan *F1 score*.

Tabel 4. Sebaran Jumlah Anotasi Dataset

No	Kelas	Train	Valid	Test	Total
1	Menelpon	169	61	34	264
2	Mengantuk	152	38	16	206
3	Minum	258	45	89	392
4	Seatbelt	180	43	24	247




Gambar 6. *Confusion Matrix Normalized*


Pada gambar 6. Didapat bahwa model deteksi yang dilatih memiliki nilai *confusion matrix* antara 0,80 – 0,96 dengan kelas minum memiliki nilai tertinggi dan kelas mengantuk memiliki nilai terendah. Dari data tersebut berarti besar kecilnya nilai *confusion matrix* sebanding dengan jumlah dataset yang dilatih disetiap kelas, dimana dataset terbanyak yaitu 433 gambar untuk kelas minum, sedangkan pada kelas mengantuk memiliki dataset paling sedikit yaitu dengan 206 gambar. Dari nilai *Confusion Matrix* pada gambar 6 juga dapat diperoleh nilai akurasi dari model deteksi sebagai berikut:

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} = \frac{0,81 + 0,80 + 0,96 + 0,94}{0,81 + 0,15 + 0,20 + 0,80 + 0,05 + 0,96 + 0,15 + 0,94} \times 100 = 86,5\%$$


Dari perhitungan akurasi dengan menggunakan persamaan (1), diperoleh nilai akurasi 86,5%, nilai tersebut menandakan sistem deteksi penggunaan *seatbelt*, mengantuk, menelpon dan memegang minuman benar dari seluruh percobaan deteksi menggunakan algoritma *YOLOv8*. Untuk memastikan performa hasil deteksi secara keseluruhan diperlukan evaluasi nilai *precision*, *recall*, dan *F1-score*. Kemudian untuk nilai *precision*, *recall*, dan *F1-score* pada gambar 7, 8 dan 9.

Gambar 7. *Precision Curve*

Precision menunjukkan akurasi dari prediksi positif yang dilakukan oleh model deteksi. Nilai *precision* yang tinggi berarti model deteksi memiliki tingkat kesalahan yang rendah dalam prediksi positif (Gupta, R., Sharma, A., Alam, 2024). Gambar 7 menunjukkan rata-rata *precision* semua kelas pada model deteksi perilaku mengemudi berbasis *YOLOv8* berada di angka 0,916.

Gambar 8. *Recall Curve*

Recall menunjukkan kemampuan model dalam menemukan semua kasus positif. Nilai *recall* yang tinggi menandakan model deteksi dapat mendeteksi sebagian besar kasus positif yang ada (Alfina et al., 2024). Pada gambar 8 menunjukkan nilai *recall* dari semua kelas model deteksi perilaku mengemudi berbasis *YOLOv8* sebesar 0,920.

Gambar 9. *F1 Curve*

F1 Score adalah metrik yang mengkombinasikan *precision* dan *recall* menjadi satu nilai tunggal yang diambil dari rata-rata harmonik keduanya. *F1 score* memberikan gambaran keseimbangan antara *precision* dan *recall* (Natasha Sharma, 2023). Nilai *F1* yang tinggi menunjukkan model deteksi memiliki keseimbangan yang baik antara kemampuan mendeteksi kasus positif dan menghindari kesalahan dalam memprediksi kasus positif. Pada gambar 9. Hasil *F1 score* di semua kelas pada model deteksi perilaku mengemudi berbasis *YOLOv8* sebesar 0,870.



Gambar 10. Data Test Model Deteksi

Algoritma *YOLO* (*You Only Look Once*) dapat mendeteksi perilaku pengemudi pada citra gambar dan video dengan akurasi yang cukup tinggi seperti yang ditunjukkan pada gambar 10. Dengan demikian, algoritma ini mampu menghindari kesalahan identifikasi yang dapat berdampak pada keselamatan manusia dan lingkungan saat berkendara.

KESIMPULAN

Penelitian ini menyajikan Sistem Monitoring Fokus Pengemudi berbasis *YOLOv8* (SIMONKIDI). Dataset yang digunakan terdiri dari 1109 gambar, yang terbagi menjadi 825 gambar untuk data pelatihan, 146 gambar untuk data validasi, dan 138 gambar untuk data pengujian. Proses pelatihan dilakukan selama 100 *epochs* dengan empat kelas perilaku yang dideteksi, yaitu mengantuk, minum, menelpon, dan menggunakan *seatbelt*. Hasil evaluasi menunjukkan nilai *confusion matrix* yang berada dalam rentang 0,800 hingga 0,960, yang mengindikasikan tingkat ketepatan yang tinggi dalam klasifikasi setiap kelas perilaku. *Precision* yang diperoleh sebesar 0,916 menunjukkan model memiliki tingkat ketepatan yang tinggi dalam mendeteksi perilaku yang benar tanpa banyak *false positives*. Sementara itu, nilai *recall* sebesar 0,920 mengindikasikan kemampuan model yang baik dalam mendeteksi semua kejadian dari perilaku yang benar. Nilai *F1 score* sebesar 0,870 menunjukkan keseimbangan yang baik antara *precision* dan *recall*. Hasil penelitian ini menunjukkan bahwa model SIMONKIDI berbasis *YOLOv8* mampu memberikan kinerja yang efisien dan akurat dalam memonitor perilaku pengemudi, yang dapat berkontribusi dalam meningkatkan keselamatan berkendara.

DAFTAR PUSTAKA

- Alfina, I., Azzahra, A., Setiawan, A., Kudus, U. M., Alfina, I., & Azzahra, A. (2024). Inovasi teknologi ai dalam deteksi dini tuberkulosis dengan kecerdasan buatan. *Jurnal Multilingual*, 4(2), 281–297.
- Gupta, R., Sharma, A., Alam, T. (2024). Building Predictive Models with Machine Learning. *Springer Singapore*, 145. https://doi.org/https://doi.org/10.1007/978-981-97-0448-4_3
- KEMENHUB. (2017). *Rata-rata Tiga Orang Meninggal Setiap Jam Akibat Kecelakaan Jalan*. Kominfo.Go.Id.
- KEMENHUB. (2023). *Tekan Angka Kecelakaan Lalu Lintas, Kemenhub Ajak Masyarakat Beralih ke Transportasi Umum dan Utamakan Keselamatan Berkendara*. <https://dephub.go.id/post/read/tekan-angka-kecelakaan-lalu-lintas,-kemenhub-ajak-masyarakat-beralih-ke-transportasi-umum-dan-utamakan-keselamatan-berkendara>
- Nafis Alfarizi, D., Agung Pangestu, R., Aditya, D., Adi Setiawan, M., & Rosyani, P. (2023). Penggunaan Metode YOLO Pada Deteksi Objek: Sebuah Tinjauan Literatur Sistematis. *Jurnal Artificial Intelligent Dan Sistem Penunjang Keputusan*, 1(1), 54–63.
- Natasha Sharma. (2023). *Understanding and Applying F1 Score: AI Evaluation Essentials with Hands-On Coding Example*. Arize.Com.
- Nurdjanah, N., & Puspitasari, R. (2017). Factors Affecting the Concentration of Driver. *Warta Penelitian Perhubungan*, 1(5), 57–141.
- Putra, R. F., & Mulyana, D. I. (2024). Optimasi Deteksi Objek Dengan Segmentasi dan Data Augmentasi Pada Hewan Siput Beracun Menggunakan Algoritma You Only Look Once (YOLO). *Jurnal JTik (Jurnal Teknologi Informasi Dan Komunikasi)*, 8(1), 93–103. <https://doi.org/10.35870/jtik.v8i1.1391>
- Rahayu, W. D., Pambudi, E. A., Wicaksono, A. P., & Wibowo, F. (2024). 1852-4596-1-Pb. *Jurnal Ilmiah Teknik Informatika Dan Sistem Informasi*, 13, 439–450.
- Ramadana Lubis, A. A., Purnama, S. I., & Afandi, M. A. (2023). Sistem Pendeteksi Kantuk Berbasis Metode Haar Cascade Untuk Aplikasi Computer Vision. *Techno.Com*, 22(3), 589–598. <https://doi.org/10.33633/tc.v22i3.8464>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 779–788. <https://doi.org/10.1109/CVPR.2016.91>
- Rofii, F., Priyandoko, G., Fanani, M. I., & Suraji, A. (2021). Vehicle Counting Accuracy Improvement By Identity Sequences Detection Based on Yolov4 Deep Neural Networks. *Teknik*, 42(2), 169–177. <https://doi.org/10.14710/teknik.v42i2.37019>
- Ulleberg, P., & Rundmo, T. (2003). Personality, attitudes and risk perception as predictors of risky driving behaviour among young drivers. *Safety Science*, 41(5), 427–443. [https://doi.org/10.1016/S0925-7535\(01\)00077-7](https://doi.org/10.1016/S0925-7535(01)00077-7)
- Zuraida, R. (2015). Fatigue Risk of Long-Distance Driver as the Impact of the Duration of Work. *ComTech: Computer, Mathematics and Engineering Applications*, 6(3), 319. <https://doi.org/10.21512/comtech.v6i3.2207>