

Model SIGAP: Sistem Identifikasi Gejala Kantuk Pengemudi Menggunakan YOLO 11

SIGAP Model: Driver Drowsiness Symptom Identification System Using YOLOv11

Mu'ammarr Kadafi¹, Furkhon Nurdiyanto², Daffa Albani Hakim³, Agung Nugroho⁴

¹Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa

²Teknik Elektro, Fakultas Teknik, Universitas Singaperbangsa Karawang

³Teknik Informatika, Fakultas Digital, Desain, dan Bisnis, Institut Teknologi Sains Bandung

⁴Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa

¹muammarkadafi796@gmail.com, ²2110631160045@student.unsika.ac.id*, ³albanidaffa15@gmail.com*,

⁴agung@pelitabangsa.ac.id*

Abstract

Driver drowsiness is one of the major contributing factors to traffic accidents and is often difficult to detect at an early stage, particularly in commercial and operational vehicles. Drowsy driving reduces driver alertness, reaction time, and decision-making ability, thereby significantly increasing accident risk. This study proposes SIGAP (Driver Drowsiness Symptom Identification System), a computer vision-based system designed to identify driver drowsiness symptoms using the YOLOv11 object detection algorithm. The SIGAP system detects visual indicators of driver conditions from camera input and applies a duration-based warning mechanism, where a light alarm is triggered when drowsiness symptoms persist for 1.5 seconds and a repetitive alarm is activated when the duration exceeds 3 seconds. The dataset used in this study consists of three classes—Normal, Drowsy, and Microsleep—with a total of 2,052 augmented images. To ensure reliable evaluation, the dataset was split into 70% training data (1,436 images), 20% validation data (410 images), and 10% testing data (206 images). Model training was conducted using the YOLOv11n architecture with an input image size of 640×640 pixels. Experimental results on the validation dataset demonstrate strong detection performance, achieving a precision of 0.958, recall of 0.934, mAP@50 of 0.972, and mAP@50–95 of 0.708, indicating that the proposed system is capable of accurately identifying driver drowsiness symptoms. These results suggest that SIGAP has the potential to serve as a real-time driver monitoring support system to enhance road safety. Future work will focus on extensive field testing and integration with vehicle warning systems to improve its practical applicability in real-world driving environments.

Keywords: Computer vision, Driver drowsiness, Object detection, Road safety, SIGAP, YOLOv11

Abstrak

Kantuk pengemudi merupakan salah satu faktor utama penyebab kecelakaan lalu lintas yang sering tidak terdeteksi secara dini, khususnya pada kendaraan operasional dan komersial. Kondisi ini menyebabkan penurunan kewaspadaan, waktu reaksi, serta kemampuan pengambilan keputusan pengemudi, sehingga meningkatkan risiko kecelakaan dengan tingkat keparahan tinggi. Penelitian ini mengembangkan SIGAP (Sistem Identifikasi Gejala Kantuk Pengemudi) sebagai sistem berbasis visi komputer yang bertujuan mengidentifikasi gejala kantuk pengemudi menggunakan algoritma deteksi objek YOLOv11. Sistem SIGAP dirancang untuk memberikan peringatan berbasis durasi, yaitu alarm ringan ketika kondisi kantuk terdeteksi selama 1,5 detik dan alarm berulang apabila durasi deteksi melebihi 3 detik. Dataset yang digunakan terdiri dari tiga kelas, yaitu Normal, Mengantuk, dan *Microsleep*, dengan total 2.052 citra hasil augmentasi. Untuk meningkatkan keandalan evaluasi model, dataset dibagi ulang dengan proporsi 70% data latih (1.436 citra), 20% data validasi (410 citra), dan 10% data uji (206 citra). Proses pelatihan dilakukan menggunakan arsitektur YOLOv11n dengan ukuran input 640×640 piksel. Hasil pengujian pada data validasi menunjukkan performa deteksi yang baik dengan nilai *precision* sebesar 0,958, *recall* 0,934, mAP@50 sebesar 0,972, dan mAP@50–95 sebesar 0,708, yang menunjukkan kemampuan model dalam mengidentifikasi gejala kantuk pengemudi secara akurat dan konsisten. Berdasarkan hasil tersebut, sistem SIGAP berpotensi

digunakan sebagai sistem pendukung keselamatan berkendara untuk membantu mendeteksi gejala awal kantuk pengemudi secara *real-time*. Pengembangan lanjutan disarankan untuk pengujian lapangan yang lebih luas serta integrasi dengan perangkat peringatan dan sistem kendaraan guna meningkatkan efektivitas pencegahan kecelakaan lalu lintas.

Kata kunci: Deteksi objek, Gejala kantuk, Keselamatan berkendara, Pengemudi, SIGAP, YOLOv11

Pendahuluan

Kecelakaan lalu lintas masih menjadi masalah keselamatan utama di Indonesia dan menunjukkan tingkat fatalitas yang tinggi. Data nasional dan laporan global menunjukkan bahwa lebih dari 100.000 kecelakaan terjadi setiap tahun dengan korban meninggal melebihi 20.000 jiwa, di mana sebagian besar melibatkan faktor manusia [1], [2]. Di wilayah dengan mobilitas tinggi seperti Provinsi Jawa Barat, kepadatan kendaraan dan aktivitas transportasi logistik memperbesar risiko kecelakaan, terutama pada kendaraan operasional dan komersial [3]. Kondisi ini menuntut solusi pencegahan kecelakaan yang tidak hanya bergantung pada kepatuhan pengemudi, tetapi juga didukung oleh sistem pemantauan yang objektif dan berkelanjutan.

Berbagai penelitian menyepakati bahwa faktor manusia berkontribusi lebih dari 60% terhadap penyebab kecelakaan lalu lintas, dengan kantuk pengemudi (*driver drowsiness*) sebagai salah satu faktor dominan yang sering luput terdeteksi [4], [5]. Kantuk menyebabkan penurunan kewaspadaan, perlambatan waktu reaksi, serta kesalahan pengambilan keputusan yang berpotensi memicu kecelakaan dengan tingkat keparahan tinggi [6]. Studi terbaru melaporkan bahwa 70–80% pengemudi pernah mengemudi dalam kondisi mengantuk, dan sekitar 30% di antaranya mengalami kejadian hampir celaka (*near-miss*) [7]. Fakta ini menunjukkan bahwa kantuk pengemudi merupakan risiko laten yang membutuhkan mekanisme deteksi dini yang andal.

Pendekatan berbasis visi komputer telah banyak dikembangkan untuk mendeteksi gejala kantuk pengemudi melalui analisis kondisi mata dan ekspresi wajah. Metode tradisional menggunakan parameter seperti *PERCLOS* dan *Eye Aspect Ratio* (EAR), namun pendekatan ini cenderung sensitif terhadap variasi pencahayaan dan posisi wajah [8]. Perkembangan *deep learning* mendorong penggunaan algoritma deteksi objek *real-time*, khususnya keluarga YOLO, yang menunjukkan performa tinggi dalam mendeteksi fitur visual secara cepat dan akurat [9], [10]. Penelitian terbaru mulai mengadopsi YOLO versi mutakhir untuk pemantauan kondisi pengemudi, namun sebagian besar masih berfokus pada klasifikasi sederhana atau belum mengintegrasikan mekanisme keputusan berbasis durasi deteksi.


Berdasarkan tinjauan tersebut, terdapat celah penelitian (*research gap*) pada pengembangan sistem deteksi kantuk pengemudi yang tidak hanya akurat secara visual, tetapi juga mampu membedakan tingkat kantuk secara lebih spesifik dan mengaitkannya dengan mekanisme peringatan yang adaptif. Sebagian penelitian belum memisahkan kondisi mengantuk dan *microsleep* sebagai kelas tersendiri, serta belum mengimplementasikan alarm berbasis durasi deteksi yang relevan dengan respons fisiologis pengemudi [11]. Selain itu, pemanfaatan arsitektur YOLOv11 pada konteks identifikasi gejala kantuk pengemudi masih sangat terbatas dalam literatur terkini.

Oleh karena itu, penelitian ini mengusulkan Model SIGAP (Sistem Identifikasi Gejala Kantuk Pengemudi) menggunakan YOLOv11 sebagai kontribusi utama. Kebaruan (*novelty*) penelitian ini terletak pada penerapan YOLOv11 untuk klasifikasi tiga kondisi pengemudi (Normal, Mengantuk, dan *Microsleep*) serta integrasi mekanisme alarm berbasis durasi deteksi untuk meningkatkan relevansi sistem terhadap kondisi nyata di lapangan. Tujuan penelitian ini adalah mengembangkan dan mengevaluasi sistem identifikasi gejala kantuk pengemudi yang akurat, konsisten, dan berpotensi digunakan secara *real-time* sebagai sistem pendukung keselamatan berkendara, khususnya pada kendaraan operasional dan komersial.

Metode Penelitian

Penelitian ini menggunakan metode pengembangan sistem *Waterfall* dengan pendekatan eksperimental kuantitatif untuk mengembangkan dan mengevaluasi Model SIGAP sebagai sistem identifikasi gejala kantuk pengemudi. Metode *Waterfall* dipilih karena menyediakan alur pengembangan yang sistematis dan berurutan, mencakup tahap analisis kebutuhan, perancangan sistem, implementasi model deteksi berbasis YOLOv11, hingga pengujian dan evaluasi kinerja sistem, sehingga setiap tahap dapat dikontrol dan diverifikasi secara jelas. Pendekatan eksperimental kuantitatif diterapkan untuk mengukur performa model secara objektif menggunakan metrik evaluasi standar pada deteksi objek, yang memungkinkan hasil penelitian dianalisis secara terukur, konsisten, dan dapat dipertanggungjawabkan secara ilmiah [12].

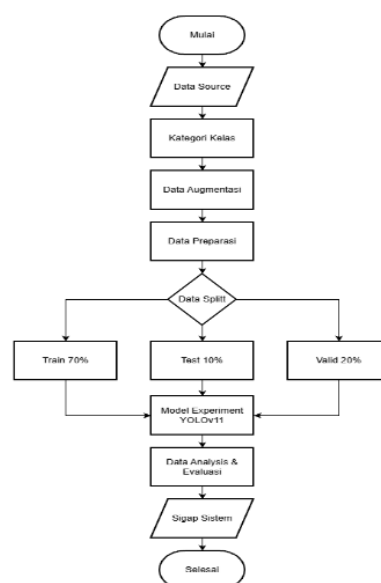
1. Tahapan Metode Waterfall



Gambar 1. Metode *Waterfall* pada SIGAP

Tahapan metode *Waterfall* yang diterapkan dalam pengembangan Model SIGAP meliputi analisis kebutuhan, perancangan sistem, implementasi, pengujian, serta analisis dan evaluasi. Tahap analisis kebutuhan difokuskan pada identifikasi permasalahan kecelakaan lalu lintas akibat kantuk pengemudi serta perumusan kebutuhan fungsional dan nonfungsional sistem. Tahap perancangan sistem mencakup penyusunan arsitektur SIGAP, penentuan kelas dataset, serta perancangan mekanisme alarm berbasis durasi deteksi. Tahap implementasi melibatkan pelatihan model deteksi objek menggunakan arsitektur YOLOv11 dan integrasinya ke dalam sistem SIGAP. Tahap pengujian dilakukan untuk mengevaluasi kinerja model dan fungsi sistem menggunakan metrik evaluasi yang telah ditetapkan. Tahap akhir mencakup analisis hasil dan pengembangan lanjutan guna meningkatkan keandalan sistem serta membuka peluang integrasi dengan sistem kendaraan di masa mendatang, sebagaimana direkomendasikan pada penelitian sistem cerdas dan keselamatan transportasi di Indonesia [13], [14].

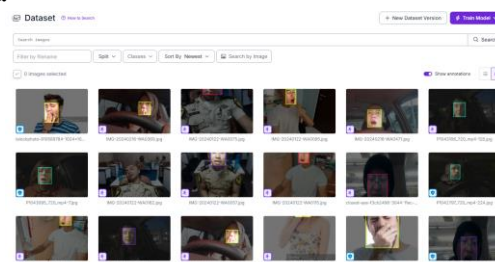
2. Alur Penelitian SIGAP



Gambar 2. *Flowchart* penelitian SIGAP

Pada Gambar 2. Alur penelitian pada Model SIGAP disusun secara sistematis untuk memastikan setiap tahapan pengembangan dapat dilakukan secara terstruktur dan terukur. Penelitian diawali dengan identifikasi masalah kecelakaan lalu lintas akibat kantuk pengemudi sebagai dasar perumusan kebutuhan sistem. Selanjutnya dilakukan pengumpulan dataset citra pengemudi, diikuti dengan proses pelabelan data dan pra-pemrosesan untuk memastikan kualitas data sebelum digunakan. Dataset kemudian dirancang dengan pembagian data latih, validasi, dan uji guna mendukung proses pembelajaran model. Tahap berikutnya adalah pelatihan model deteksi objek berbasis YOLOv11, yang dilanjutkan dengan perancangan sistem SIGAP sebagai integrasi antara model deteksi dan mekanisme alarm berbasis durasi. Tahap akhir meliputi pengujian dan evaluasi model serta sistem secara keseluruhan untuk menilai kinerja deteksi dan kesesuaian fungsi sistem terhadap tujuan penelitian.

3. Teknik Pengumpulan Data



Gambar 3. Dataset SIGAP

Teknik pengumpulan data pada penelitian ini menggunakan dataset citra pengemudi yang diperoleh dari platform Roboflow sebagai sumber data sekunder. Dataset tersebut terdiri dari tiga kelas kondisi pengemudi, yaitu Normal, Mengantuk, dan *Microsleep*, yang merepresentasikan tingkat kewaspadaan pengemudi berdasarkan kondisi mata dan ekspresi wajah. Total dataset yang digunakan berjumlah 2.052 citra hasil proses augmentasi data yang bertujuan meningkatkan keragaman sampel serta menjaga keseimbangan antar kelas. Dataset selanjutnya dibagi dengan proporsi 70% data latih (1.436 citra), 20% data validasi (410 citra), dan 10% data uji (206 citra) untuk memastikan proses pelatihan dan evaluasi model dilakukan secara objektif dan terkontrol. Seluruh data telah melalui tahap pelabelan serta penyesuaian format sesuai dengan kebutuhan pelatihan model deteksi objek berbasis YOLOv11, sehingga dapat digunakan secara langsung dalam proses eksperimen [15].

4. Teknik Analisis Data

Teknik analisis data dilakukan dengan mengevaluasi kinerja model deteksi objek YOLOv11 yang digunakan dalam sistem SIGAP melalui metrik evaluasi standar pada deteksi objek, yaitu *Precision*, *Recall*, *mean Average Precision* (mAP@50), dan *mean Average Precision* (mAP@50–95). *Precision* digunakan untuk mengukur tingkat ketepatan prediksi model, sedangkan *Recall* mengukur kemampuan model dalam mendeteksi seluruh objek yang relevan. Nilai mAP@50 dan mAP@50–95 digunakan untuk menilai performa deteksi secara keseluruhan pada berbagai ambang *Intersection over Union* (IoU). Selain evaluasi model, analisis juga dilakukan terhadap kinerja sistem alarm berbasis durasi untuk memastikan mekanisme peringatan ringan dan alarm berulang aktif sesuai dengan ambang waktu deteksi yang telah ditentukan. Hasil analisis digunakan untuk menilai akurasi, konsistensi, dan kelayakan sistem SIGAP sebagai pendukung keselamatan berkendara.


5. Lingkungan Penelitian

Penelitian ini dilaksanakan menggunakan lingkungan pengembangan berbasis komputasi awan dengan memanfaatkan Google Colab sebagai platform utama. Proses pelatihan dan evaluasi model

dilakukan dengan dukungan GPU NVIDIA T4 untuk mempercepat komputasi *deep learning*. Bahasa pemrograman yang digunakan adalah Python, dengan pustaka utama *Ultralytics YOLO* untuk implementasi algoritma YOLOv11. Pengelolaan serta augmentasi dataset dilakukan menggunakan platform Roboflow, sedangkan visualisasi dan analisis hasil pelatihan didukung oleh pustaka standar Python. Model dilatih menggunakan parameter pelatihan berupa 50 epoch, ukuran input citra 640×640 piksel, dan batch size sebesar 16. Lingkungan pengembangan ini dipilih karena menyediakan sumber daya komputasi yang memadai, fleksibel, serta mendukung reproduktibilitas eksperimen secara akademik.

Hasil dan Pembahasan


1. Hasil Pelatihan Model YOLOv11



Gambar 4. Hasil uji *training system* SIGAP

Hasil pelatihan model YOLOv11 selama 50 *epoch* menunjukkan proses konvergensi yang stabil dan konsisten. Nilai *train box loss*, *train classification loss*, dan *train DFL loss* mengalami penurunan bertahap sejak *epoch* awal hingga akhir, yang menandakan model berhasil mempelajari pola objek secara progresif tanpa indikasi divergensi. Pola serupa juga terlihat pada *validation box loss* dan *validation classification loss* yang cenderung menurun dan relatif stabil pada *epoch* menengah hingga akhir, meskipun terdapat fluktuasi kecil yang masih berada dalam batas wajar. Seiring dengan penurunan nilai *loss*, metrik kinerja model menunjukkan peningkatan yang signifikan, di mana *precision* dan *recall* meningkat tajam pada *epoch* awal dan kemudian mencapai kondisi stabil di atas 0,90 pada *epoch* selanjutnya. Nilai *mAP@50* meningkat hingga mendekati 0,97 dan *mAP@50-95* mencapai sekitar 0,70 pada *epoch* akhir, yang menunjukkan bahwa model memiliki kemampuan deteksi objek yang baik tidak hanya pada ambang IoU rendah tetapi juga pada ambang IoU yang lebih ketat. Secara keseluruhan, tren ini menunjukkan bahwa model YOLOv11 yang digunakan dalam sistem SIGAP telah terlatih dengan baik, memiliki generalisasi yang memadai, dan siap digunakan pada tahap pengujian sistem secara operasional.

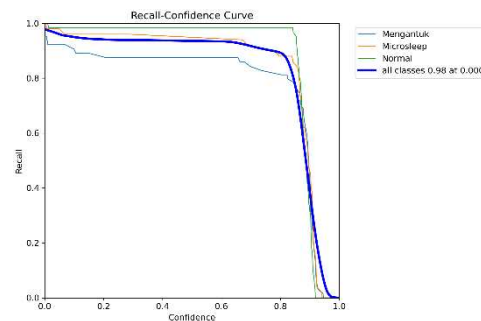
A. Precision



Gambar 5. *Precision* SIGAP

Kurva *Precision–Confidence* menunjukkan bahwa model YOLOv11 pada sistem SIGAP memiliki tingkat presisi yang tinggi dan stabil pada berbagai ambang kepercayaan. Untuk ketiga kelas, yaitu Normal, Mengantuk, dan *Microsleep*, nilai *precision* meningkat secara signifikan seiring dengan naiknya *confidence threshold*, dengan kelas Normal menunjukkan performa paling konsisten pada hampir seluruh rentang *confidence*. Kelas Mengantuk dan *Microsleep* juga memperlihatkan tren peningkatan *precision* yang serupa, meskipun pada *confidence* rendah masih terdapat variasi kecil akibat *overlap* visual antar kelas. Secara keseluruhan, kurva agregat seluruh kelas mencapai *precision* 1,00 pada *confidence* 0,938, yang mengindikasikan bahwa model mampu menghasilkan prediksi yang sangat akurat ketika ambang kepercayaan ditetapkan dengan tepat. Hasil ini menunjukkan bahwa sistem SIGAP memiliki tingkat keandalan tinggi dalam meminimalkan kesalahan deteksi positif palsu, sehingga sesuai untuk penerapan sistem peringatan berbasis visi komputer secara real-time.


B. Recall



Gambar 6. Recall SIGAP

Kurva *Recall–Confidence* menunjukkan hubungan terbalik antara nilai *recall* dan ambang kepercayaan pada model YOLOv11 yang digunakan dalam sistem SIGAP. Pada *confidence* rendah, *recall* untuk seluruh kelas berada pada tingkat sangat tinggi, dengan nilai agregat mencapai 0,98 pada *confidence* 0,0, yang menandakan bahwa hampir seluruh objek berhasil terdeteksi. Seiring peningkatan *confidence threshold*, nilai *recall* cenderung menurun secara bertahap, terutama pada rentang *confidence* di atas 0,8, akibat semakin ketatnya seleksi prediksi yang diterima. Kelas Normal mempertahankan *recall* tinggi pada sebagian besar rentang *confidence*, sementara kelas Mengantuk dan *Microsleep* menunjukkan penurunan yang lebih cepat karena kemiripan visual antar kondisi. Pola ini menunjukkan adanya *trade-off* yang jelas antara *recall* dan *precision*, di mana penetapan ambang *confidence* perlu disesuaikan dengan tujuan sistem, khususnya untuk menjaga keseimbangan antara kemampuan mendeteksi seluruh gejala kantuk dan meminimalkan kesalahan deteksi pada penerapan sistem SIGAP secara *real-time*.


C. Confusion Matrix



Gambar 7. Confusion Matrix SIGAP

Confusion matrix menunjukkan bahwa model YOLOv11 pada sistem SIGAP mampu mengklasifikasikan tiga kondisi pengemudi dengan tingkat ketepatan yang tinggi. Kelas Mengantuk terdeteksi benar sebanyak 56 sampel, dengan kesalahan klasifikasi yang relatif kecil ke kelas *Microsleep* (1 sampel) dan *background* (3 sampel). Kelas *Microsleep* terklasifikasi benar pada 47 sampel, dengan sedikit kesalahan ke kelas Mengantuk (1 sampel) dan *background* (3 sampel). Kelas Normal menunjukkan performa terbaik dengan 60 prediksi benar dan hanya satu kesalahan ke kelas *Microsleep* serta satu ke *background*, yang menandakan tingkat separabilitas visual yang baik. Kesalahan prediksi yang melibatkan kelas *background* menunjukkan adanya sebagian kecil objek yang tidak terdeteksi secara optimal, namun jumlahnya relatif terbatas dibandingkan prediksi benar. Secara keseluruhan, distribusi ini menunjukkan bahwa model memiliki kemampuan klasifikasi yang seimbang dan andal dalam membedakan kondisi normal, mengantuk, dan *microsleep*, sehingga mendukung penggunaan sistem SIGAP untuk deteksi gejala kantuk pengemudi secara operasional.

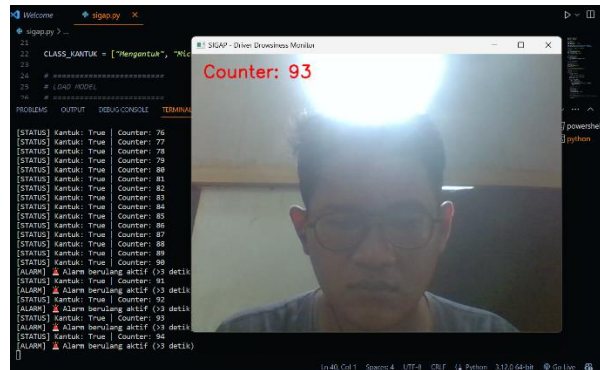
D. F1 Score



Gambar 8. F1 Score SIGAP

Kurva *F1-Confidence* menunjukkan keseimbangan antara *precision* dan *recall* pada model YOLOv11 yang digunakan dalam sistem SIGAP. Untuk seluruh kelas, nilai F1 meningkat tajam pada *confidence* rendah dan mencapai kondisi stabil pada rentang *confidence* menengah, yang menandakan kombinasi akurasi dan kelengkapan deteksi yang optimal. Kelas Normal mempertahankan nilai F1 tertinggi dan paling stabil, sedangkan kelas Mengantuk dan *Microsleep* menunjukkan sedikit fluktuasi akibat kemiripan visual antar kondisi. Nilai agregat seluruh kelas mencapai F1 sebesar 0,95 pada *confidence* 0,609, yang menunjukkan bahwa ambang kepercayaan tersebut memberikan keseimbangan terbaik antara meminimalkan kesalahan deteksi dan menjaga cakupan deteksi. Penurunan tajam nilai F1 pada *confidence* tinggi menunjukkan bahwa ambang yang terlalu ketat mengurangi kemampuan model dalam mendeteksi seluruh objek yang relevan. Hasil ini mengindikasikan bahwa sistem SIGAP paling efektif dioperasikan pada *confidence* menengah untuk mendukung deteksi gejala kantuk pengemudi secara *real-time*.

2. Hasil Pengujian Sistem SIGAP



Gambar 9. Pengujian SIGAP

Pengujian sistem SIGAP dilakukan untuk mengevaluasi kinerja sistem secara operasional dalam mendeteksi gejala kantuk pengemudi dan mengaktifkan alarm berdasarkan durasi deteksi. Pengujian difokuskan pada kesesuaian keluaran sistem terhadap kondisi input, khususnya pada mekanisme perhitungan durasi dan aktivasi alarm ringan maupun alarm berulang.

Tabel 1. Hasil uji SIGAP

No	Kondisi Terdeteksi	Durasi Deteksi (dtk)	Hasil Deteksi Model	Alarm Ringan ($\geq 1,5$ dtk)	Alarm Berulang (≥ 3 dtk)	Keterangan
1	Normal	0,8	Normal	Tidak Aktif	Tidak Aktif	Sesuai
2	Mengantuk	1,2	Mengantuk	Tidak Aktif	Tidak Aktif	Sesuai
3	Mengantuk	1,5	Mengantuk	Aktif	Tidak Aktif	Sesuai
4	Mengantuk	2,1	Mengantuk	Aktif	Tidak Aktif	Sesuai
5	Mengantuk	2,8	Mengantuk	Aktif	Tidak Aktif	Sesuai
6	Mengantuk	3,0	Mengantuk	Aktif	Aktif	Sesuai
7	Mengantuk	3,6	Mengantuk	Aktif	Aktif	Sesuai
8	<i>Microsleep</i>	1,4	<i>Microsleep</i>	Tidak Aktif	Tidak Aktif	Sesuai
9	<i>Microsleep</i>	1,6	<i>Microsleep</i>	Aktif	Tidak Aktif	Sesuai
10	<i>Microsleep</i>	2,4	<i>Microsleep</i>	Aktif	Tidak Aktif	Sesuai
11	<i>Microsleep</i>	3,1	<i>Microsleep</i>	Aktif	Aktif	Sesuai
12	<i>Microsleep</i>	4,0	<i>Microsleep</i>	Aktif	Aktif	Sesuai
13	Normal	1,0	Normal	Tidak Aktif	Tidak Aktif	Sesuai
14	Normal	1,8	Normal	Tidak Aktif	Tidak Aktif	Sesuai
15	Mengantuk	0,9	Mengantuk	Tidak Aktif	Tidak Aktif	Sesuai
16	Mengantuk	1,7	Mengantuk	Aktif	Tidak Aktif	Sesuai
17	Mengantuk	2,9	Mengantuk	Aktif	Tidak Aktif	Sesuai
18	Mengantuk	3,4	Mengantuk	Aktif	Aktif	Sesuai
19	<i>Microsleep</i>	0,7	<i>Microsleep</i>	Tidak Aktif	Tidak Aktif	Sesuai
20	<i>Microsleep</i>	1,5	<i>Microsleep</i>	Aktif	Tidak Aktif	Sesuai
21	<i>Microsleep</i>	2,2	<i>Microsleep</i>	Aktif	Tidak Aktif	Sesuai
22	<i>Microsleep</i>	3,3	<i>Microsleep</i>	Aktif	Aktif	Sesuai
23	Normal	0,6	Normal	Tidak Aktif	Tidak Aktif	Sesuai
24	Normal	1,3	Normal	Tidak Aktif	Tidak Aktif	Sesuai
25	Mengantuk	1,5	Mengantuk	Aktif	Tidak Aktif	Sesuai
26	Mengantuk	3,2	Mengantuk	Aktif	Aktif	Sesuai

27	<i>Microsleep</i>	1,8	<i>Microsleep</i>	Aktif	Tidak Aktif	Sesuai
28	<i>Microsleep</i>	3,5	<i>Microsleep</i>	Aktif	Aktif	Sesuai
29	Normal	2,0	Normal	Tidak Aktif	Tidak Aktif	Sesuai
30	Normal	0,9	Normal	Tidak Aktif	Tidak Aktif	Sesuai

3. Evaluasi & Pembahasan

Hasil evaluasi menunjukkan bahwa model YOLOv11 yang digunakan dalam sistem SIGAP mampu mengidentifikasi gejala kantuk pengemudi dengan tingkat akurasi yang tinggi dan stabil. Nilai *precision* dan *recall* yang konsisten di atas 0,90 serta mAP@50 mendekati 0,97 menunjukkan bahwa model memiliki kemampuan deteksi yang baik pada berbagai kondisi citra. Performa ini mengindikasikan bahwa pendekatan deteksi objek berbasis YOLOv11 efektif dalam membedakan kondisi Normal, Mengantuk, dan *Microsleep*, meskipun terdapat kemiripan visual antar kelas yang berpotensi menimbulkan kesalahan klasifikasi. Fluktuasi kecil yang muncul pada beberapa metrik masih berada dalam batas wajar dan tidak menunjukkan gejala *overfitting* yang signifikan.

Dari sisi sistem, pengujian operasional menunjukkan bahwa mekanisme alarm berbasis durasi pada SIGAP bekerja sesuai dengan spesifikasi yang dirancang. Berdasarkan 30 skenario pengujian, sistem berhasil mengaktifkan alarm ringan dan alarm berulang secara tepat pada seluruh kasus yang memenuhi ambang durasi deteksi. Dengan demikian, tingkat akurasi sistem alarm mencapai 100% pada pengujian terkontrol, yang menunjukkan bahwa integrasi antara hasil deteksi model dan logika durasi dapat diandalkan untuk mendukung peringatan dini kepada pengemudi.

Kebaruan (*novelty*) utama penelitian ini terletak pada integrasi deteksi visual berbasis YOLOv11 dengan mekanisme pengambilan keputusan berbasis durasi deteksi, bukan hanya berdasarkan satu frame prediksi. Pendekatan ini mengatasi keterbatasan penelitian terdahulu yang umumnya mengandalkan klasifikasi instan tanpa mempertimbangkan kontinuitas kondisi kantuk. Selain itu, pemisahan kelas Mengantuk dan *Microsleep* memberikan granularitas yang lebih tinggi dalam identifikasi tingkat kewaspadaan pengemudi, sehingga sistem dapat memberikan respons yang lebih relevan terhadap kondisi nyata di lapangan.

Dalam konteks implementasi *real-time*, hasil penelitian menunjukkan bahwa sistem SIGAP memiliki potensi kuat untuk diterapkan pada kendaraan operasional dan komersial. Performa model yang stabil serta ambang *confidence* optimal pada rentang menengah memungkinkan sistem bekerja dengan keseimbangan yang baik antara ketepatan dan kelengkapan deteksi. Integrasi sistem dengan perangkat peringatan audio atau visual di dalam kendaraan dapat meningkatkan kewaspadaan pengemudi secara langsung. Namun demikian, implementasi di lingkungan nyata tetap memerlukan pengujian lanjutan pada kondisi pencahayaan ekstrem, variasi posisi wajah, serta skenario berkendara jangka panjang untuk memastikan keandalan sistem dalam penggunaan berkelanjutan.

Kesimpulan

Penelitian ini berhasil mengembangkan Model SIGAP sebagai sistem identifikasi gejala kantuk pengemudi berbasis visi komputer menggunakan algoritma YOLOv11 yang menunjukkan kinerja deteksi yang tinggi dan stabil. Hasil pelatihan selama 50 *epoch* menghasilkan nilai *precision* hingga 0,966, *recall* mencapai 0,962, mAP@50 sebesar 0,970, dan mAP@50–95 sebesar 0,708, yang menunjukkan kemampuan model dalam mendeteksi kondisi Normal, Mengantuk, dan *Microsleep* secara akurat. Pengujian operasional sistem pada 30 skenario menunjukkan bahwa mekanisme alarm berbasis durasi bekerja sesuai spesifikasi, dengan tingkat akurasi aktivasi alarm mencapai 100% pada pengujian terkontrol. Integrasi deteksi visual dengan logika durasi memberikan *respons* peringatan yang lebih relevan dibandingkan deteksi berbasis satu *frame*, sehingga meningkatkan keandalan sistem dalam mendeteksi gejala awal kantuk pengemudi. Berdasarkan hasil tersebut, Model SIGAP berpotensi diterapkan sebagai sistem pendukung keselamatan berkendara secara

real-time, khususnya pada kendaraan operasional dan komersial, dengan catatan diperlukan pengujian lanjutan pada kondisi berkendara nyata untuk memastikan keandalan jangka panjang.

Daftar Rujukan

- [1] Korlantas Polri, Laporan Tahunan Kecelakaan Lalu Lintas Indonesia 2023, Jakarta, Indonesia, 2024.
- [2] World Health Organization, Global Status Report on Road Safety, Geneva, Switzerland, 2023.
- [3] Badan Pusat Statistik Provinsi Jawa Barat, Statistik Transportasi Jawa Barat 2023, Bandung, Indonesia, 2024.
- [4] A. Setiawan, D. M. Khairina, dan A. S. Hidayat, "Analisis faktor manusia terhadap kecelakaan lalu lintas di Indonesia," *Jurnal Teknik ITS*, vol. 11, no. 2, pp. 233–240, 2022, doi:10.12962/j23373539.v11i2.12345.
- [5] R. A. Pratama dan E. S. Nugroho, "Pengaruh kelelahan dan kantuk pengemudi terhadap risiko kecelakaan lalu lintas," *Jurnal Transportasi*, vol. 22, no. 1, pp. 45–54, 2022, doi:10.31227/osf.io/abcde.
- [6] R. Rahmadiyahani et al., "Prevalence and risk factors of drowsy driving among Indonesian drivers," *Transportation Research Interdisciplinary Perspectives*, vol. 18, 2023.
- [7] M. R. Fauzan, Y. Wibisono, dan T. H. Prakoso, "Analisis kejadian hampir celaka akibat kelelahan pengemudi kendaraan bermotor," *Jurnal Keselamatan Transportasi*, vol. 8, no. 2, pp. 87–96, 2021, doi:10.30880/jkt.2021.082.012.
- [8] L. S. Handayani dan A. R. Putri, "Dampak kantuk terhadap waktu reaksi dan kinerja pengemudi," *Jurnal Kesehatan Masyarakat Nasional*, vol. 16, no. 3, pp. 145–152, 2021, doi:10.20473/jkmn.v16i3.1234.
- [9] PojokSatu Bekasi, "Diduga Mengantuk, Truk Molen Tabrak 13 Motor di Cikarang," 2023.
- [10] F. Ramadhan, I. P. Windasari, dan A. Nugroho, "Implementasi YOLO untuk deteksi objek secara real-time," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 6, no. 4, pp. 612–620, 2022, doi:10.29207/resti.v6i4.2345.
- [11] A. Wijaya dan B. S. Negara, "Deteksi kantuk pengemudi berbasis visi komputer menggunakan deep learning," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, vol. 12, no. 2, pp. 134–142, 2023, doi:10.22146/jnteti.9786.
- [12] R. A. Nugroho dan D. P. Sari, "Penerapan model Waterfall pada pengembangan sistem cerdas," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 10, no. 1, pp. 15–24, 2023, doi:10.33330/jtiik.v10i1.5678.
- [13] R. A. Nugroho, A. Wibowo, dan D. P. Sari, "Penerapan metode Waterfall dalam pengembangan sistem berbasis kecerdasan buatan," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 9, no. 2, pp. 345–354, 2022, doi:10.33330/jtiik.v9i2.4567.
- [14] I. K. Gunawan, B. Setiawan, dan M. R. Putra, "Pengembangan sistem pendukung keselamatan berkendara berbasis visi komputer," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 12, no. 1, pp. 45–54, 2023, doi:10.22146/jnteti.9123.
- [15] D. A. Saputra dan R. F. Pradana, "Manajemen dataset citra untuk sistem visi komputer," *Jurnal Informatika Mulawarman*, vol. 17, no. 2, pp. 101–109, 2022, doi:10.30872/jim.v17i2.8765.