

SentryNap: Sistem Peringatan dan Monitoring Kantuk Operator Industri Menggunakan YOLOv5 dan CCTV

M Ilham Yusuf Gumai¹, Yohana Christy Relyana Sembiring² Sri Lestari³

^{1,2,3}teknik Informatika, Institut Informatika dan Bisnis Darmajaya, Indonesia

¹ilham.gumay619@gmail.com, ²yohana.2411019002p@mail.darmajaya.ac.id ³srilestari@darmajaya.ac.id

Info Artikel

Riwayat Artikel:

Received 2026-01-07

Revised 2026-04-11

Accepted 2026-04-26

Corresponding Author:

M Ilham Yusuf Gumai

Email:

ilham.gumay619@gmail.com



This is an open access article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/) license.

Abstract – This study aims to develop SentryNap, a real-time drowsiness warning and monitoring system for industrial control-room operators based on YOLOv5s using CCTV/webcam image input. Reduced alertness caused by long shift work and operator drowsiness can increase the risk of operational errors, while many previous approaches still rely on intrusive physiological sensors or visual methods that are sensitive to changes in lighting and head pose. The proposed system uses a YOLOv5s model fine-tuned on a Roboflow dataset with two classes, namely normal and sleeping, and integrates the inference results with a Node.js backend for JSON logging. Model training was conducted for 50 epochs at a resolution of 640 x 640 pixels using the SGD optimizer, while evaluation was carried out through static validation and real-time testing scenarios. The model achieved a precision of 0.986, recall of 1.000, mAP@0.5 of 0.995, and mAP@0.5:0.95 of 0.621. Real-time testing showed that detection results could be recorded by the backend in less than one second. These findings indicate that SentryNap has potential as a non-invasive operator safety monitoring prototype, although larger datasets and broader field validation are still required.

Keywords: Computer vision, Drowsiness detection, Industrial Safety, YOLOv5.

Abstrak – Penelitian ini bertujuan untuk mengembangkan SentryNap, sistem peringatan dan pemantauan kantuk operator di ruang kontrol industri secara real-time berbasis YOLOv5s dengan masukan media secara real-time dari CCTV/webcam. Penurunan kewaspadaan akibat kerja shift yang panjang dan kantuk pada operator dapat meningkatkan risiko kesalahan operasional, sedangkan banyak pendekatan sebelumnya masih bergantung pada sensor fisiologis yang invasif atau metode visual yang sensitif terhadap perubahan pencahayaan dan pose kepala. Sistem yang diusulkan menggunakan model YOLOv5s yang difine-tune pada dataset Roboflow dengan dua kelas, yaitu normal dan sleeping, lalu diintegrasikan dengan backend Node.js untuk pencatatan log JSON. Pelatihan pada model dilakukan selama 50 epoch dengan resolusi 640 x 640 piksel dikombinasikan optimizer SGD, sedangkan evaluasi dilakukan pada skenario validasi statis dan pengujian real-time. Model menghasilkan precision 0,986, recall 1,000, mAP@0.5 0,995, dan mAP@0.5:0.95 0,621. Pengujian real-time menunjukkan hasil deteksi dapat dicatat ke backend dalam waktu kurang dari satu detik. Hasil ini menunjukkan bahwa SentryNap berpotensi sebagai prototipe pemantauan keselamatan operator yang non-invasif, meskipun masih memerlukan data yang lebih besar dan validasi lapangan yang lebih luas.

Kata Kunci: Deteksi Kantuk, Keselamatan Industri, Visi Komputer, YOLOv5.

I. PENDAHULUAN

Ruang kontrol industri berfungsi sebagai pusat pengendalian proses modern. Pada ruang kontrol, sekelompok kecil operator bertanggung jawab memantau banyak variabel proses dan mengambil keputusan secara langsung dan cepat, sehingga aspek kemudahan penggunaan, ketelitian, dan kewaspadaan operator menjadi sangat menentukan keberlangsungan operasi [1]. Namun, pola kerja bergiliran dengan durasi shift yang panjang dan terkadang pada malam hari sering kali mengganggu ritme biologis pada tubuh operator dan meningkatkan rasa kantuk. Tinjauan Folkard et al. menunjukkan bahwa risiko kecelakaan cenderung lebih tinggi pada shift malam, meningkat pada rangkaian shift berturut-turut, dan bertambah pada durasi kerja di atas delapan jam [2]. Temuan longitudinal pada operator mesin dan *plant* juga menunjukkan bahwa sistem shift 12 jam berkaitan dengan kualitas tidur yang lebih buruk dan peningkatan kelelahan kerja [3]. Dalam konteks ruang kontrol, beberapa detik *micro-sleep* saja dapat menurunkan respons operator terhadap alarm, panel, atau perubahan proses yang bersifat kritis dan meningkatkan risiko kecelakaan kerja.

Untuk mendeteksi kantuk sedini mungkin, penelitian sebelumnya menempuh jalur visual klasik, pendekatan fisiologis, dan pengamatan wajah secara non-intrusive. Pendekatan visual klasik seperti kombinasi Haar *Cascade Classifier* dan *Support Vector Machine* telah digunakan untuk mendeteksi pengemudi mengantuk secara *real-time* [4]. Di sisi lain, pendekatan fisiologis berbasis respirasi, detak jantung, staging tidur, dan *wearable* sensor dapat menyediakan sinyal yang kaya untuk mengenali penurunan kewaspadaan [5], [6], [7], [8]. Meskipun demikian, pendekatan fisiologis cenderung kurang praktis untuk ruang kontrol karena memerlukan sensor tambahan atau alur

pengukuran yang lebih invasif. Sebaliknya, studi berbasis fitur visual menunjukkan bahwa informasi penutupan mata, gerak mulut, dan pose kepala cukup efektif sebagai indikator kantuk tanpa memerlukan sensor yang dikenakan pengguna [9]. Walaupun lebih praktis untuk implementasi lapangan, metode visual tetap menuntut model yang tangguh terhadap variasi pencahayaan, pose wajah, dan kualitas citra.

Dengan kemajuan jaringan *convolutional neural network* (CNN), terutama YOLOv5, muncul peluang untuk membangun sistem deteksi kantuk yang non-invasif dengan akurasi dan latensi yang lebih baik. Peningkatan pada *backbone*, *feature fusion*, dan mekanisme *attention* dalam YOLOv5 terbukti dapat meningkatkan representasi fitur dan efisiensi deteksi [10]. Pada domain deteksi kantuk, integrasi *lightweight* YOLOv5s dengan *facial 3D keypoints* dilaporkan mampu meningkatkan ketahanan sistem terhadap variasi wajah [11], sedangkan kombinasi *facial landmark* dan YOLOv5 juga telah digunakan untuk skenario *driver drowsiness detection* [12].

Di atas jalur YOLOv5 tersebut, penelitian lain memperlihatkan bahwa analisis wajah *real-time* [13], pendekatan multimodal [14], dan arsitektur transformer [15] dapat mendorong akurasi yang lebih tinggi. Pada saat yang sama, pendekatan berbasis *facial extraction* dan *machine learning* [16] serta *lightweight CNN* dengan data terbatas [17] menegaskan bahwa kompromi antara akurasi dan efisiensi komputasi tetap menjadi isu penting dalam sistem deteksi kantuk *real-time*.

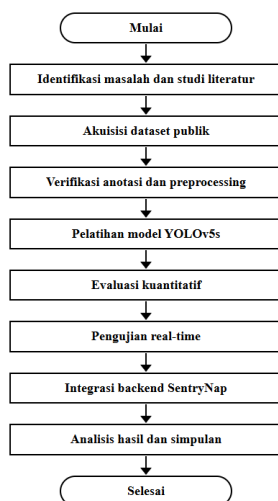
Walaupun demikian, sebagian besar penelitian terdahulu masih berfokus pada pengemudi kendaraan. Pada konteks industri, Yuan et al. telah menggunakan YOLOv5 untuk mendeteksi perilaku abnormal di central control room [18], sedangkan Lozano-Reyes dan Mugruza-Vassallo menunjukkan bahwa sistem *vision-based* juga dapat diterapkan pada operator kereta secara *real-time* [19]. Namun, penelitian-penelitian tersebut belum secara spesifik membahas deteksi *micro-sleep* operator ruang kontrol industri dengan kamera tetap, skema klasifikasi ringan dua kelas yang dapat dijalankan pada perangkat komputasi standar, serta integrasi langsung ke *backend* pencatatan kejadian. Dengan demikian, research gap penelitian ini terletak pada belum tersedianya sistem deteksi kantuk operator industri yang sekaligus non-invasif, real-time, ringan, dan terhubung ke mekanisme logging kejadian.

Berdasarkan gap tersebut, penelitian ini memperkenalkan SentryNap sebagai *prototype* sistem peringatan dan pemantauan kantuk operator berbasis YOLOv5s dan CCTV/webcam. Kebaruan utama dari penelitian ini ada pada pemfokusan deteksi visual dua kelas, yaitu normal dan *sleeping*, untuk konteks operator ruang kontrol industri dengan kamera tetap dan integrasi langsung ke *backend* pencatatan kejadian. Penelitian ini bertujuan merancang dan mengevaluasi SentryNap untuk mendeteksi kondisi kantuk operator secara non-invasif. Kontribusi utama penelitian ini mencakup penyusunan *pipeline* deteksi berbasis citra yang ringan dan *real-time*, integrasi hasil inferensi ke mekanisme *logging backend*, serta evaluasi performa model pada data validasi dan skenario pengujian langsung.

II. METODE

Penelitian ini mengadopsi pendekatan kuantitatif-eksperimental untuk mengembangkan dan mengevaluasi sistem deteksi otomatis yang dapat mengenali kondisi mengantuk atau tertidur pada operator di ruang kontrol industri. Sistem ini memanfaatkan teknologi *computer vision* berbasis *deep learning*, khususnya model deteksi objek YOLOv5s. Deteksi dilakukan menggunakan input visual dari kamera CCTV atau webcam yang kemudian dikategorikan ke dalam dua status, yaitu normal dan *sleeping*.

Sistem ini dirancang untuk beroperasi secara *real-time* dan terintegrasi dengan *backend* Node.js untuk pencatatan log deteksi serta pengembangan mekanisme peringatan. Proses penelitian mencakup akuisisi dataset publik dari Roboflow, pelabelan, *preprocessing*, pelatihan model, evaluasi performa, dan pengujian sistem secara langsung menggunakan kamera tetap. Alur penelitian ditunjukkan pada Gambar 1.



Gambar 1. Flowchart penelitian dan integrasi sistem SentryNap.

A. Rancangan dan Waktu Penelitian

Penelitian ini merupakan penelitian terapan dengan desain eksperimen. Pengembangan, pelatihan, dan pengujian sistem dilakukan pada tahun 2025 di laboratorium pribadi peneliti yang disimulasikan sebagai ruang kontrol industri menggunakan satu kamera tetap yang merepresentasikan CCTV dan satu laptop sebagai node inferensi. Pendekatan kuantitatif digunakan karena performa sistem diukur menggunakan metrik numerik seperti *precision*, *recall*, *confusion matrix*, *mAP@0.5*, dan *mAP@0.5:0.95*. Selain itu, pengujian *real-time* dilakukan untuk mengamati latensi pengiriman data, kestabilan inferensi, dan konsistensi hasil pada kondisi operasional yang berubah.

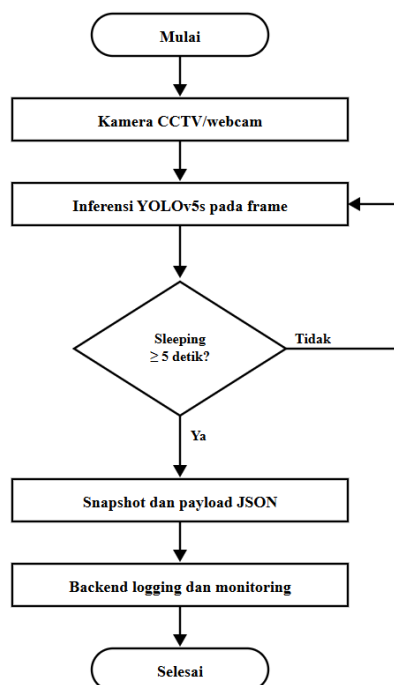
B. Objek, Data, dan Sumber Data

Objek penelitian adalah *prototipe* SentryNap, yaitu sistem deteksi kantuk operator berbasis YOLOv5s yang terhubung dengan *backend Node.js*. Subjek penelitian berupa data visual operator yang berasal dari dua sumber, yaitu dataset publik dan video langsung dari webcam. Aktivitas operator dikategorikan ke dalam dua kelas, yaitu normal dan *sleeping*. Pemodelan dua kelas dipilih untuk menyesuaikan kebutuhan deteksi dini *micro-sleep* pada tahap awal implementasi, sejalan dengan beberapa studi deteksi kantuk berbasis wajah dan sistem kamera *real-time* [12], [13], [20], [21], [22]. Dataset pelatihan berasal dari *Roboflow* dengan format anotasi YOLO. Setelah berkas metadata non-gambar diabaikan, dataset yang benar-benar digunakan terdiri dari 157 citra training dan 17 citra *validation*. Pada split training terdapat 118 *instance* kelas normal dan 97 *instance* kelas *sleeping*, sedangkan pada split *validation* terdapat 11 *instance* normal dan 10 *instance* *sleeping*. Selain data statis, video langsung dari webcam digunakan untuk menilai perilaku sistem pada skenario *real-time*.

C. Preprocessing dan Perancangan Sistem

Tahap preprocessing mengikuti pipeline YOLOv5, yaitu pembacaan anotasi format YOLO, normalisasi bawaan loader, dan perubahan ukuran citra menjadi 640 x 640 piksel pada saat training. Untuk meningkatkan keragaman data, digunakan augmentasi berupa *hsv_h* 0.015, *hsv_s* 0.7, *hsv_v* 0.4, translasi 0.1, skala 0.5, *flip horizontal* 0.5, dan *mosaic* 1.0, sehingga model lebih adaptif terhadap variasi pencahayaan, pose wajah, dan komposisi frame.

Pada tahap perancangan sistem, SentryNap dibangun dalam beberapa komponen utama, yaitu modul akuisisi citra, modul inferensi YOLOv5s, modul validasi durasi kejadian *sleeping*, dan modul *backend logging* berbasis *Node.js*. Hubungan antar komponen tersebut ditunjukkan pada Gambar 2, yang memperlihatkan alur aplikasi mulai dari pengambilan frame kamera, proses inferensi, validasi durasi kantuk, penyimpanan snapshot, hingga pengiriman *payload* JSON ke *backend* untuk keperluan *logging* dan monitoring.



Gambar 2. Flowchart aplikasi SentryNap pada deteksi real-time.

D. Implementasi dan Konfigurasi Model

Model utama yang digunakan adalah YOLOv5s dengan bobot awal yolov5s.pt. Pemilihan model ini didasarkan pada karakteristik YOLO yang efisien untuk deteksi *real-time*, hasil komparatif yang menunjukkan keluarga YOLO tetap kompetitif pada kompromi kecepatan dan akurasi [23], serta keberhasilannya pada tugas deteksi perilaku abnormal dan perilaku tidak aman di lingkungan kerja [10], [18], [24], [25]. Implementasi sistem dilakukan menggunakan Python, PyTorch, dan Node.js. Pelatihan dilakukan selama 50 epoch dengan *batch size* 16 dan *image size* 640. Optimizer yang digunakan adalah SGD dengan *learning rate* awal 0.01, momentum 0.937, *weight decay* 0.0005, dan 8 *worker*. Pada tahap inferensi *real-time*, *confidence threshold* diset sebesar 0.4. Ambang *sleeping event* ditetapkan selama 5 detik berturut-turut untuk mengurangi alarm palsu akibat deteksi sesaat. *Hyperparameter* yang digunakan pada penelitian ini ditunjukkan pada Tabel 1.

TABEL 1
HYPERPARAMETER SISTEM SENTRYNAP

Parameter	Nilai
Model	YOLOv5s
Input size	640 x 640
Epoch	50
Batch size	16
Optimizer	SGD
Learning rate	0.01
Momentum	0.937
Weight decay	0.0005
Workers	8
Confidence threshold	0.4
Sleeping duration	5 detik

E. Pengujian dan Teknik Analisis

Pengujian dilakukan pada dua tahap, yaitu evaluasi kuantitatif pada data validation dan evaluasi implementasi pada skenario real-time. Evaluasi kuantitatif menggunakan confusion matrix, precision, recall, mAP@0.5, dan mAP@0.5:0.95 untuk menilai kemampuan model dalam membedakan kondisi normal dan sleeping. Pada pengujian real-time, kamera mengirim frame ke modul Python berbasis YOLOv5s. Jika label sleeping terdeteksi konsisten selama minimal 5 detik, sistem menyimpan snapshot dan mengirim payload JSON ke endpoint backend yang berisi *device_id*, label, confidence, timestamp, durasi, nama berkas gambar, dan bounding box. Skenario uji real-time mencakup operator dalam posisi tegak, operator menunduk seperti tertidur, perubahan sudut wajah terhadap kamera, dan pencahayaan yang lebih redup daripada kondisi pelatihan. Evaluasi implementasi meliputi waktu respons backend, konsistensi logging, dan kestabilan deteksi pada variasi pose kepala dan pencahayaan.

III. HASIL DAN PEMBAHASAN

A. Hasil Pelatihan dan Evaluasi Kuantitatif

Model yang digunakan pada penelitian ini adalah YOLOv5s yang telah dilatih selama 50 epoch dengan resolusi 640 x 640 piksel dan batch size 16. Hasil akhir training menunjukkan nilai *train/box_loss* 0.0236, *val/box_loss* 0.0262, dan konvergensi yang stabil tanpa indikasi kenaikan *loss* validasi yang tajam. Tabel 2 memperlihatkan bahwa model mencapai *precision* 0.986, *recall* 1.000, mAP@0.5 0.995, dan mAP@0.5:0.95 0.621. Nilai *recall* yang sempurna menunjukkan bahwa seluruh *instance sleeping* pada data validasi berhasil dikenali, sedangkan selisih antara mAP@0.5 dan mAP@0.5:0.95 mengindikasikan bahwa kualitas lokalisasi *bounding box* masih lebih sensitif pada ambang IoU yang lebih ketat.

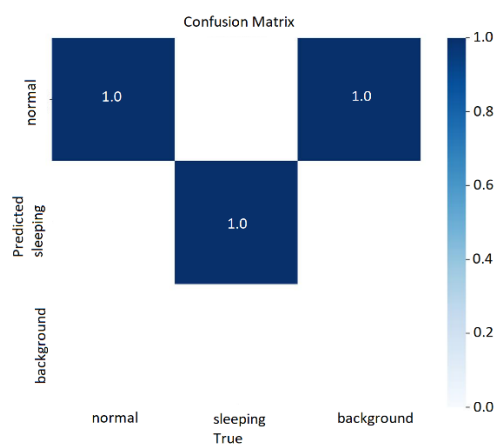
TABEL 2
METRIK EVALUASI MODEL PADA DATA VALIDASI

Metrik	Nilai
Precision	0.986
Recall	1.000
mAP@0.5	0.995
mAP@0.5:0.95	0.621


B. Visualisasi Performa Model

Visualisasi performa digunakan untuk memverifikasi bahwa hasil numerik benar-benar mencerminkan perilaku model. *Confusion matrix* pada Gambar 3 menunjukkan bahwa seluruh data validasi berada pada diagonal utama, sehingga kesalahan klasifikasi antar kelas tidak muncul pada set validasi yang terbatas. Kurva *precision-recall* pada Gambar 4 berada sangat dekat dengan sudut kanan atas. Hal ini menunjukkan bahwa model mampu menjaga precision tetap tinggi ketika *recall* ditingkatkan, sehingga prediksi *sleeping* tidak terlalu sering menghasilkan false

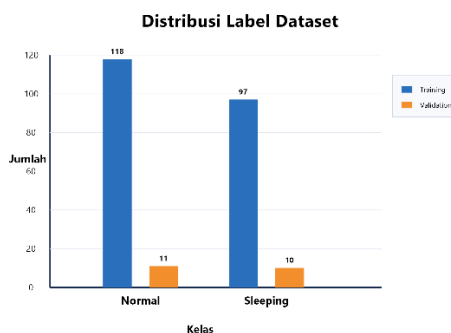
alarm. Jika ruang masih mencukupi, distribusi label dataset dapat ditampilkan pada Gambar 5 untuk menunjukkan bahwa dua kelas utama tidak sangat timpang.



Gambar 3. Confusion matrix.



Gambar 4. Kurva precision-recall.




Gambar 5. Distribusi label dataset.

C. Pengujian Real-Time dan Integrasi Sistem

Contoh inferensi real-time ditunjukkan pada Gambar 6, yang memuat dua kondisi, yaitu normal dan sleeping, dalam satu panel visual. Penyajian gabungan ini lebih hemat ruang, tetapi tetap cukup untuk menunjukkan bahwa sistem mampu memberikan *bounding box* dan *confidence score* secara langsung pada dua kondisi utama. Pada pengujian *real-time*, sistem dijalankan pada perangkat komputasi standar tanpa GPU dan tetap mampu mengirim hasil deteksi ke *backend* dalam waktu kurang dari satu detik setelah kejadian sleeping memenuhi ambang waktu 5 detik.

Inferensi Real-Time



Gambar 5. Pengujian real-time: (a) kondisi normal, (b) kondisi sleeping.

Setiap deteksi *sleeping* yang telah melewati durasi ambang menghasilkan objek JSON yang memuat label, *confidence*, *timestamp*, durasi, nama berkas gambar, image base64, dan *bounding box*. Payload ini kemudian dikirim melalui HTTP POST ke *endpoint backend* agar dapat dicatat sebagai log kejadian. Hasil pengujian menunjukkan bahwa pencatatan hasil deteksi dapat dilakukan dalam rata-rata waktu kurang dari satu detik, koneksi antara modul

Python dan Node.js tetap stabil selama pengujian berulang, dan format *payload* JSON konsisten sehingga data dapat langsung diproses untuk keperluan log, audit, atau analitik lanjutan.

D. Pembahasan

Penelitian menunjukkan bahwa tujuan utama penelitian, yaitu membangun sistem deteksi kantuk operator secara *real-time*, telah tercapai pada level *prototipe*. Nilai *precision* 0.986 dan *recall* 1.000 menunjukkan bahwa pendekatan *computer vision* berbasis YOLOv5s cukup efektif untuk membedakan dua kondisi utama, yakni normal dan *sleeping*, tanpa memerlukan sensor yang menempel pada tubuh operator.

Jika dibandingkan dengan studi *vision-based* yang paling dekat, performa SentryNap berada pada kisaran yang kompetitif untuk sistem dua kelas berbasis kamera tunggal. Penelitian Albadawi et al. [9], Kanigoro dan Asdyo [12], serta Essahraui et al. [13] sama-sama menunjukkan bahwa *drowsiness detection real-time* sangat dipengaruhi oleh kualitas fitur wajah, konsistensi pose kepala, dan keragaman data. Temuan pada SentryNap sejalan dengan pola tersebut, karena performa terbaik muncul ketika wajah operator berada dalam area pandang yang stabil dan pencahayaan tidak terlalu berubah.

Pada sisi implementasi, literatur berbasis YOLO untuk deteksi kantuk *real-time* menegaskan bahwa kecepatan inferensi dan modularitas deployment sama pentingnya dengan akurasi model [20], [21], [22]. Karena itu, nilai tambah SentryNap bukan hanya pada klasifikasi visual, tetapi pada integrasi hasil inferensi ke *backend logging*. Alur ini membuat hasil deteksi tidak berhenti sebagai *bounding box* dan label, melainkan langsung menjadi jejak data yang dapat dipakai untuk audit kejadian, notifikasi supervisor, dan pemantauan shift.

Jika dibandingkan dengan pendekatan yang lebih kompleks, seperti multimodal [14], transformer [15], *wearable sensor* berbasis *heart rate variability* [8], *facial extraction* berbasis *machine learning* [16], dan *lightweight CNN* dengan data terbatas [17], SentryNap menawarkan kompromi yang lebih sederhana untuk deployment. Keunggulan utamanya bukan sekadar mengejar angka akurasi tertinggi, melainkan menjaga keseimbangan antara performa, kemudahan integrasi, dan kebutuhan operasional pada skenario pemantauan operator.

Dari sisi konteks industri, penelitian pada ruang kontrol dan operator transportasi menunjukkan bahwa kamera tetap relevan untuk sistem keselamatan berbasis AI [18], [19]. Temuan pada deteksi perilaku tidak aman di lingkungan industri dan konstruksi juga mendukung pendekatan *vision-based* untuk area kerja yang menuntut kewaspadaan tinggi [24], [25]. Namun, sebagian besar studi tersebut masih berfokus pada perilaku abnormal umum atau pengemudi, bukan *micro-sleep* operator ruang kontrol yang terhubung ke sistem pencatatan kejadian. Di titik inilah SentryNap mengisi celah yang lebih spesifik.

E. Keterbatasan dan Implikasi Praktis

Performa model yang tinggi pada penelitian ini dipengaruhi oleh beberapa faktor: tugas klasifikasi hanya dua kelas, posisi wajah pada frame relatif konsisten, dan augmentasi data membantu model beradaptasi terhadap variasi terbatas. Namun, faktor yang sama juga menjadi sumber keterbatasan. Dataset masih kecil, belum ada test set independen, pengujian dilakukan pada satu jenis kamera, dan skenario lapangan nyata dengan *occlusion*, *glare*, atau banyak operator belum dievaluasi. Karena itu, hasil penelitian ini harus dibaca sebagai bukti awal yang menjanjikan, bukan sebagai validasi akhir untuk implementasi industri berskala penuh.

Dari sisi praktis, sistem ini menunjukkan bahwa kamera tunggal yang dipadukan dengan model ringan dan *backend logging* sudah cukup untuk membangun *prototipe* pemantauan kantuk operator. Implikasi utamanya adalah peluang integrasi dengan *dashboard* pengawasan shift, notifikasi *supervisor*, audit kejadian, dan analisis perilaku operator secara berkala. Meski demikian, penerapan industri nyata tetap memerlukan validasi lapangan, pengujian multi kamera, dan penyesuaian terhadap kondisi pencahayaan yang lebih beragam.

IV. SIMPULAN

Penelitian ini berhasil mengembangkan SentryNap sebagai *prototipe* sistem peringatan dan pemantauan kantuk operator industri berbasis YOLOv5s yang terintegrasi dengan *backend* Node.js untuk pencatatan kejadian secara *real-time*. Model yang dilatih pada dataset dua kelas menghasilkan *precision* 0.986, *recall* 1.000, mAP@0.5 0.995, dan mAP@0.5:0.95 0.621, serta mampu mengirim hasil deteksi ke server dalam waktu kurang dari satu detik pada skenario pengujian normal. Temuan ini menunjukkan bahwa pendekatan non invasif berbasis kamera tunggal cukup potensial untuk mendukung keselamatan kerja operator pada lingkungan ruang kontrol. Meskipun demikian, ukuran dataset yang masih terbatas, belum adanya test set independen, dan belum dilakukannya validasi lapangan pada CCTV industri nyata menjadi batasan utama penelitian ini. Oleh karena itu, penelitian lanjutan perlu menambah variasi data, menguji pada multi-kamera dan kondisi pencahayaan yang lebih beragam, serta mengevaluasi integrasi notifikasi agar sistem siap diterapkan pada skenario industri yang sesungguhnya.

DAFTAR PUSTAKA

- [1] T. Mentler, T. Rasim, M. Müßiggang, and M. Herczeg, "Ensuring usability of future smart energy control room systems," *Energy Informatics*, vol. 1, pp. 167–182, Oct. 2018, doi: 10.1186/s42162-018-0029-z.
- [2] S. Folkard, D. A. Lombardi, and P. T. Tucker, "Shiftwork: Safety, Sleepiness and Sleep," 2005.
- [3] R. Seibt, S. Kreuzfeld, and B. Hunger, "Effects of a 12-hour shift system on sleep and cardiovascular health of male machine and plant operators – a longitudinal study over four years," *Front. Public Health*, vol. 13, no. August, pp. 1–20, 2025, doi: 10.3389/fpubh.2025.1616810.
- [4] H. Zidny Ilmadina, D. Apriliani, and D. S. Wibowo, "Deteksi Pengendara Mengantuk dengan Kombinasi Haar Cascade Classifier dan Support Vector Machine," vol. 7, no. 1, 2022.
- [5] H. Elmoaqet, M. Eid, M. Glos, M. Ryalat, and T. Penzel, "Deep recurrent neural networks for automatic detection of sleep apnea from single channel respiration signals," *Sensors (Switzerland)*, vol. 20, no. 18, pp. 1–19, Sep. 2020, doi: 10.3390/s20185037.
- [6] N. Sridhar *et al.*, "Deep learning for automated sleep staging using instantaneous heart rate," *NPJ Digit. Med.*, vol. 3, no. 1, Dec. 2020, doi: 10.1038/s41746-020-0291-x.
- [7] P. Somaskandhan *et al.*, "Deep learning-based algorithm accurately classifies sleep stages in preadolescent children with sleep-disordered breathing symptoms and age-matched controls," *Front. Neurol.*, vol. 14, 2023, doi: 10.3389/fneur.2023.1162998.
- [8] Z. AlArnaout, C. Zaki, Y. Kotb, M. AlAkkoumi, and N. Mostafa, "Exploiting heart rate variability for driver drowsiness detection using wearable sensors and machine learning," *Sci. Rep.*, vol. 15, no. 1, pp. 1–24, 2025, doi: 10.1038/s41598-025-08582-2.
- [9] Y. Albadawi, A. AlRedhaei, and M. Takruri, "Real-Time Machine Learning-Based Driver Drowsiness Detection Using Visual Features," *J. Imaging*, vol. 9, no. 5, 2023, doi: 10.3390/jimaging9050091.
- [10] H. Chen, Z. Chen, and H. Yu, "Enhanced YOLOv5: An Efficient Road Object Detection Method," *Sensors (Basel)*, vol. 23, no. 20, Oct. 2023, doi: 10.3390/s23208355.
- [11] X. Ran, S. He, and R. Li, "Research on Fatigued-Driving Detection Method by Integrating Lightweight YOLOv5s and Facial 3D Keypoints," *Sensors*, vol. 23, no. 19, 2023, doi: 10.3390/s23198267.
- [12] B. Kanigoro and B. Asdyo, "Facial Landmark and YOLOv5 Drowsiness Detection System," in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 548–554. doi: 10.1016/j.procs.2024.10.281.
- [13] S. Essahraoui *et al.*, "Real-Time Driver Drowsiness Detection Using Facial Analysis and Machine Learning Techniques," *Sensors*, vol. 25, no. 3, Feb. 2025, doi: 10.3390/s25030812.
- [14] S. Priyanka, S. Shanthi, A. Saran Kumar, and V. Praveen, "Data fusion for driver drowsiness recognition: A multimodal perspective," *Egyptian Informatics Journal*, vol. 27, p. 100529, Sep. 2024, doi: 10.1016/J.EIJ.2024.100529.
- [15] O. F. Hassan, A. F. Ibrahim, A. Gomaa, M. A. Makhlof, and B. Hafiz, "Real-time driver drowsiness detection using transformer architectures: a novel deep learning approach," *Sci. Rep.*, vol. 15, no. 1, pp. 1–33, 2025, doi: 10.1038/s41598-025-02111-x.
- [16] J. R. Theivadas and S. Ponnann, "VigilEye: Machine learning-powered driver fatigue recognition for safer roads," *Measurement: Sensors*, vol. 33, no. May, p. 101186, 2024, doi: 10.1016/j.measen.2024.101186.
- [17] M. Venkateswarlu and V. Rami Reddy Ch, "DrowsyDetectNet: Driver Drowsiness Detection Using Lightweight CNN With Limited Training Data," *IEEE Access*, vol. 12, no. August, pp. 110476–110491, 2024, doi: 10.1109/ACCESS.2024.3440585.
- [18] P. Yuan, C. Fan, and C. Zhang, "YOLOv5s-MEE: A YOLOv5-based Algorithm for Abnormal Behavior Detection in Central Control Room," *Information Technology and Control*, vol. 53, no. 1, pp. 220–236, Mar. 2024, doi: 10.5755/j01.itc.53.1.33458.
- [19] G. S. Lozano-Reyes and C. A. Mugruza-Vassallo, "A vision-based drowsiness detection system for railway operators using lightweight convolutional neural networks," *Frontiers in Future Transportation*, vol. 6, no. November, pp. 1–10, 2025, doi: 10.3389/ffut.2025.1677442.
- [20] A. Rehman, M. Z. Waseem, A. Rafey, A. A. Hussaini, H. Parveen, and N. Khan, "Identification Detection and YoloV5 based Driver Drowsiness Framework," *Int. J. Innov. Sci. Res. Technol.*, pp. 2806–2815, May 2025, doi: 10.38124/ijisr/25apr1476.
- [21] Prof. B. S. S. R. Kolhe, N. K. Pingale, and D. Singh Chandel, "Drowsiness Detection System: Integrating YOLOv5 Object Detection with Arduino Hardware for Real-Time Monitoring," *International Journal of Innovative Research in Computer Science and Technology*, vol. 12, no. 2, pp. 59–66, Mar. 2024, doi: 10.55524/ijrcst.2024.12.2.9.
- [22] Y. Disha and A. Upadhyaya, "A YOLO and Machine Learning-Based Framework for Real-Time Driver Drowsiness Detection," 2025.
- [23] S. Srivastava, A. V. Divekar, C. Anilkumar, I. Naik, V. Kulkarni, and V. Pattabiraman, "Comparative analysis of deep learning image detection algorithms," *J. Big Data*, vol. 8, no. 1, 2021, doi: 10.1186/s40537-021-00434-w.
- [24] L. Ying, Z. Lei, G. Junwei, H. Jinhui, M. Lei, and Z. Zilong, "Unsafe behaviour detection with the improved YOLOv5 model," *IET Cyber-Physical Systems: Theory and Applications*, vol. 9, no. 1, pp. 87–98, Mar. 2024, doi: 10.1049/cps2.12070.
- [25] Y. Liu, P. Wang, and H. Li, "An Improved YOLOv5s-Based Algorithm for Unsafe Behavior Detection of Construction Workers in Construction Scenarios," *Applied Sciences (Switzerland)*, vol. 15, no. 4, Feb. 2025, doi: 10.3390/app15041853.