

Perancangan Sistem Monitoring Penggunaan Helm Keselamatan Kerja Berbasis Area Menggunakan YOLOv10 dengan Mekanisme Peringatan Otomatis dan Dashboard Website

Elsa Marina Silalahi *

* Teknologi Rekayasa Perangkat Lunak, Politeknik Negeri Batam
elsam13@gmail.com *

Article Info

Article history:

Received

Revised

Accepted

Keyword:

Keselamatan Kerja
Deteksi Helm
YOLOv10
Computer Vision
Monitoring Real-Time
Internet of Things (IoT)

ABSTRACT

Head injuries caused by falling objects and mechanical collisions remain a major cause of workplace accidents in the construction and manufacturing sectors, yet compliance with safety-helmet regulations is still difficult to enforce because conventional CCTV monitoring only records events without automatic analysis. This research designs and builds an area-based helmet-compliance monitoring system that integrates the YOLOv10 object-detection model with an ESP32-based automatic voice-alert mechanism and a web dashboard. The model was trained on 5,000 annotated construction-worker images (head and helmet classes) for 98 epochs (out of a maximum of 100, stopped via early stopping, with the best checkpoint at epoch 78). Testing on the validation set shows the system achieves precision of 92.2%, recall of 87.2%, mAP50 of 92.5%, and mAP50-95 of 60.4%, with the helmet class (AP 96.0%) outperforming the head class (AP 89.0%) due to the larger amount of training data. Each detected violation is automatically logged with a timestamp and snapshot, and a warning is triggered on the speaker of the corresponding zone through the ESP32 controller. Black-box testing of all system modules produced results in accordance with the functional requirements, indicating that the developed prototype is feasible for use as a real-time occupational-safety monitoring tool.

Copyright © 201x Institute of Advanced Engineering and Science.
All rights reserved.

1. PENDAHULUAN

Keselamatan dan Kesehatan Kerja (K3) merupakan komponen krusial dalam pengelolaan industri, khususnya pada bidang konstruksi dan manufaktur, di mana risiko cedera kepala akibat benda jatuh maupun benturan mekanis menjadi salah satu penyebab utama kematian dan kecacatan permanen pekerja. Penggunaan Alat Pelindung Diri (APD), terutama helm keselamatan, menjadi perlindungan utama untuk mengurangi risiko tersebut, dan kewajiban penggunaannya telah diatur melalui Undang-Undang Nomor 1 Tahun 1970. Meskipun demikian, penerapan aturan ini di lapangan masih belum maksimal, tercermin dari meningkatnya jumlah kecelakaan kerja dari 182.835 kasus pada 2019 menjadi 360.635 kasus pada periode Januari-November 2023 (BPJS Ketenagakerjaan, 2024), dengan tingkat

kecelakaan kerja Indonesia yang masih lebih tinggi dibandingkan rata-rata global (WHO, 2021). Rendahnya kepatuhan pekerja dalam menggunakan APD dipengaruhi oleh perilaku pekerja, kurangnya pengawasan yang konsisten, dan lemahnya penegakan aturan di lapangan (Rafindadi et al., 2022), sementara metode pengawasan manual oleh petugas K3 memiliki keterbatasan dalam menjangkau seluruh area kerja secara bersamaan sehingga pencatatan pelanggaran menjadi tidak terstruktur dan sulit dianalisis (Rahman et al., 2026). Observasi pada PT XYZ, produsen fatty alcohol dengan area kerja berupa instalasi perpipaan dan platform kerja bertingkat, menunjukkan bahwa ruang gerak yang terbatas serta jalur akses yang berdekatan dengan struktur perpipaan menghadirkan risiko benturan dan cedera kepala apabila helm keselamatan tidak digunakan sesuai ketentuan.


Kamera CCTV yang telah banyak diterapkan pada industri umumnya masih bersifat pasif karena hanya merekam kejadian tanpa analisis otomatis, sehingga respons terhadap pelanggaran sangat bergantung pada kewaspadaan manusia yang rentan mengalami kelelahan (Vukicevic et al., 2022). Kemajuan computer vision dan deep learning menawarkan solusi melalui deteksi objek otomatis, salah satunya algoritma YOLO (You Only Look Once) yang dikenal karena kecepatan dan akurasi. YOLOv10 sebagai versi terbaru mengusung pendekatan end-to-end detection tanpa Non-Maximum Suppression (NMS-free) sehingga mampu menurunkan latensi inferensi hingga 46% dibandingkan model sebelumnya (Wang et al., 2024) dan mencapai mAP50 hingga 94,2% pada berbagai kasus deteksi (Amangeldy et al., 2025).

Penelitian terdahulu masih menyisakan celah: Nath et al. (2020) membuktikan efektivitas deep learning untuk deteksi APD namun belum terintegrasi dengan dashboard monitoring; Imran et al. (2024) mengevaluasi YOLOv10 untuk deteksi helm tetapi tidak mengembangkan sistem secara menyeluruh; Ravikumar et al. (2024) mengintegrasikan penyimpanan data dan peringatan suara namun masih menggunakan YOLOv8; sedangkan Du et al. (2025) berfokus pada peningkatan akurasi model tanpa integrasi sistem monitoring yang utuh. Berdasarkan celah tersebut, penelitian ini merancang dan membangun sistem deteksi objek berbasis YOLOv10 untuk mengidentifikasi kepatuhan penggunaan helm keselamatan secara real-time per area/zona kamera, yang diintegrasikan dengan mekanisme peringatan otomatis berbasis ESP32 dan speaker per zona serta dashboard website sebagai pusat monitoring dan pencatatan pelanggaran secara terstruktur.

II. METODE

A. Jalannya Penelitian


Metode pengembangan perangkat lunak yang digunakan adalah model Waterfall, yang dipilih karena kebutuhan fungsional sistem monitoring helm dapat didefinisikan secara lengkap sejak tahap awal berdasarkan observasi lapangan, teknologi yang digunakan telah matang, serta ruang lingkup sistem bersifat terbatas dan terdefinisi (Bassil, 2012). Penelitian dilaksanakan melalui tahapan studi literatur, pengumpulan data, analisis kebutuhan, persiapan dan anotasi dataset, pelatihan dan evaluasi model YOLOv10, perancangan sistem, implementasi, pengujian, hingga analisis dan penarikan kesimpulan sebagaimana diilustrasikan pada Gambar 1.



Gambar 1. Tahapan Penelitian

B. Gambaran Umum Sistem

Sistem yang dikembangkan mengintegrasikan model deteksi YOLOv10, kamera IP berbasis aplikasi DroidCam pada smartphone, backend web (Flask), basis data MySQL, node speaker berbasis ESP8266/ESP32, dan dashboard berbasis web. Alur kerja sistem dimulai ketika admin mengonfigurasi alamat IP kamera dan speaker melalui website. Website kemudian mengambil video stream dari kamera CCTV, meneruskan setiap frame ke model YOLOv10 untuk dideteksi. Apabila terdeteksi pekerja tanpa helm, sistem menyimpan data pelanggaran (zona, waktu, snapshot, confidence) ke basis data dan mengirimkan permintaan ke speaker pada zona bersangkutan untuk membunyikan peringatan. Petugas K3 dapat memantau kondisi tersebut secara real-time melalui dashboard monitoring, sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. Gambaran Umum Sistem

C. Kebutuhan Fungsional

Kebutuhan fungsional sistem dirumuskan berdasarkan hasil observasi dan wawancara dengan pihak terkait di lapangan, sebagaimana dirangkum pada Tabel 1.

Tabel 1. Kebutuhan Fungsional Sistem

Kode	Kebutuhan Fungsional
FR-01	Pengguna (Admin, Petugas K3) dapat melakukan login ke sistem.
FR-02	Pengguna dapat mengakses dashboard monitoring secara real-time.
FR-03	Pengguna dapat melihat riwayat pelanggaran yang terdeteksi.
FR-04	Pengguna dapat mengekspor data riwayat pelanggaran.
FR-05	Admin dapat mengelola data peringatan (speaker).
FR-06	Admin dapat mengelola data kamera per zona.
FR-07	Admin dapat mengelola data pengguna sistem.
FR-08	Pengguna dapat melakukan logout dari sistem.

D. Kebutuhan Non Fungsional


Tabel 2. Kebutuhan Non Fungsional Sistem

Parameter	Deskripsi
Performance	Sistem menampilkan hasil deteksi secara cepat dan responsif.
Usability	Antarmuka mudah digunakan melalui web tanpa pelatihan khusus.
Reliability	Sistem menyimpan dan mengelola data secara konsisten.
Security	Akses dibatasi sesuai hak akses (role) pengguna.
Maintainability	Struktur sistem terorganisir sehingga mudah dikembangkan.
Compatibility	Sistem dapat berjalan pada lingkungan jaringan lokal yang tersedia.
Availability	Sistem dapat digunakan saat dibutuhkan untuk kegiatan monitoring.

E. Perancangan Basis Data

Rancangan basis data digambarkan melalui Entity Relationship Diagram (ERD) pada Gambar 3, yang terdiri atas entitas Pengguna, Sesi, Kamera, Speaker, dan Pelanggaran. Entitas Pelanggaran menyimpan atribut kamera_id, nama_zona, timestamp, snapshot, bounding box, dan

confidence hasil deteksi model, sedangkan entitas Kamera dan Speaker saling berelasi satu-ke-satu untuk memastikan peringatan dibunyikan pada zona yang tepat ketika pelanggaran terdeteksi.



Gambar 3. Entity Relationship Diagram

F. Dataset dan Pelatihan Model YOLOv10

Dataset yang digunakan adalah Hard Hat Detection Dataset dari Kaggle (andrewmvd/hard-hat-detection) yang terdiri atas 5.000 citra pekerja konstruksi beserta anotasi format Pascal VOC (XML). Anotasi asli memuat tiga kelas (head, helmet, person); kelas person dibuang karena berada di luar cakupan penelitian, sehingga hanya dipertahankan dua kelas, yaitu head (kepala tanpa helm) dan helmet (kepala berhelm), yang dikonversi ke format YOLO (class, x_center, y_center, width, height ternormalisasi). Dataset dibagi menggunakan pendekatan stratified split berbasis bucket komposisi kelas dengan rasio 60:20:20, menghasilkan 3.000 citra data latih, 1.000 citra data validasi, dan 1.000 citra data uji, dengan distribusi instance yang tidak seimbang antar kelas sebagaimana dirangkum pada Tabel 3.

Tabel 3. Distribusi Kelas pada Data Latih

Kelas	Jumlah Instance	Proporsi
head	5.785	23,4%
helmet	18.966	76,6%
Total	24.751	100%

Model dilatih menggunakan arsitektur YOLOv10 dengan pendekatan transfer learning dari bobot pretrained, dikonfigurasi untuk berjalan maksimum 100 epoch dengan mekanisme early stopping (patience 20 epoch), ukuran citra 640×640 piksel, dan augmentasi mosaik, horizontal flip, HSV, translate, scale, random erasing, serta close-mosaic pada 10 epoch terakhir untuk meningkatkan generalisasi model. Pelatihan berhenti otomatis pada epoch ke-98, dengan bobot performa terbaik (best.pt) tercatat pada epoch ke-78. Konfigurasi hyperparameter utama dirangkum pada Tabel 4.

Tabel 4. Konfigurasi Hyperparameter Pelatihan

Parameter	Nilai
Model dasar	yolov10.pt (pretrained)
Epoch	100 (early stopping; aktual 98, terbaik 78)
Batch size	16
Image size	640 × 640
Optimizer	auto → AdamW (lr=0,001667)
Momentum	0,9
Weight decay	0,0005
Warmup epochs	3,0
Box / Class / DFL loss gain	7,5 / 0,5 / 1,5

Performa model dievaluasi menggunakan metrik precision, recall, F1-score, mAP50, dan mAP50-95 yang diturunkan dari confusion matrix (Du et al., 2025), dengan persamaan sebagai berikut.

$$Precision = TP / (TP + FP)$$

$$Recall = TP / (TP + FN)$$

$$F1 = 2 \times (Precision \times Recall) / (Precision + Recall)$$

$$mAP = (1/n) \times \sum AP_{kelas}$$

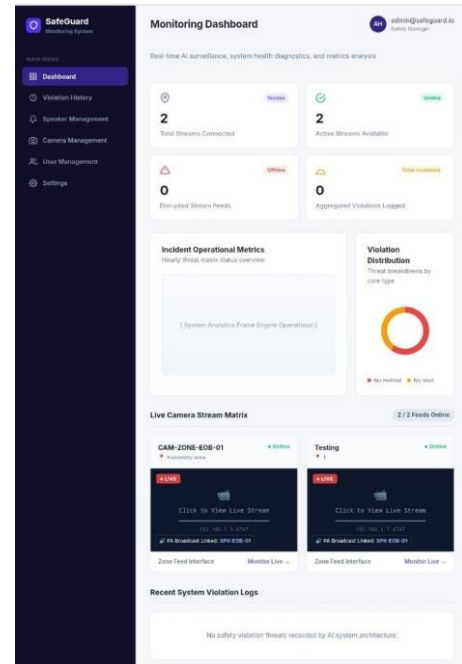
III. HASIL DAN PEMBAHASAN

A. Implementasi Antarmuka Sistem

Sistem diimplementasikan sebagai aplikasi web responsif dengan halaman Login sebagai mekanisme autentikasi awal (Gambar 4) sebelum pengguna dapat mengakses Dashboard Monitoring (Gambar 5). Dashboard menampilkan jumlah kamera terhubung, jumlah zona patuh dan zona pelanggaran, distribusi pelanggaran dalam bentuk pie chart, serta live camera stream matrix yang menampilkan hasil deteksi bounding box secara real-time dari seluruh zona yang dipantau.

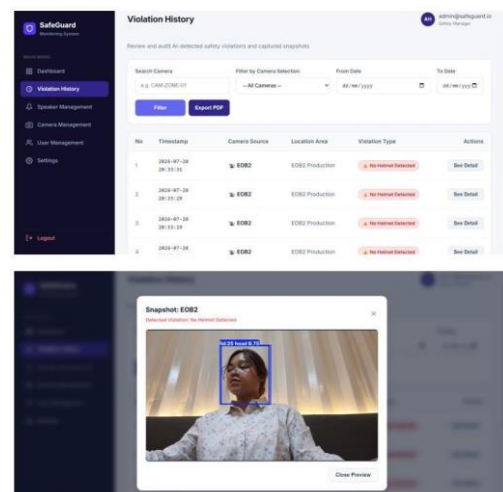


Gambar 4. Halaman Login




Gambar 5. Halaman Dashboard Monitoring

Setiap kejadian pelanggaran yang terdeteksi model YOLOv10 secara otomatis disimpan ke basis data dan dapat ditelusuri pada halaman Riwayat Pelanggaran (Gambar 6) yang menampilkan timestamp, zona, confidence, serta snapshot sebagai bukti visual. Admin selanjutnya dapat mengelola perangkat speaker melalui halaman Kelola Peringatan (Gambar 7) dengan menambahkan nama speaker, zona, dan alamat IP agar sistem dapat mengirimkan permintaan bunyi peringatan ke perangkat yang tepat ketika pelanggaran terjadi pada zona tersebut.



Gambar 6. Halaman Riwayat Pelanggaran




Gambar 7. Halaman Kelola Peringatan (Speaker)

B. Hasil Pelatihan Model YOLOv10

Proses pelatihan dikonfigurasi maksimum 100 epoch namun berhenti secara otomatis pada epoch ke-98 melalui mekanisme early stopping (patience 20 epoch), dengan total waktu komputasi $\pm 77,7$ menit (1,295 jam). Bobot dengan performa terbaik (best.pt) tercatat pada epoch ke-78. Perkembangan nilai loss dan metrik evaluasi pada beberapa titik epoch disajikan pada Tabel 5, sedangkan grafik perkembangan selama pelatihan ditampilkan pada Gambar 8.

Tabel 5. Perkembangan Metrik Pelatihan per Epoch

Epoch	Precision	Recall	mAP50	mAP50-95
1	0,563	0,559	0,541	0,286
20	0,887	0,827	0,899	0,568
40	0,897	0,880	0,927	0,600
78 (terbaik)	0,918	0,886	0,936	0,622
98 (akhir)	0,916	0,883	0,936	0,620




Gambar 8. Grafik Perkembangan Loss dan Metrik Evaluasi Selama Training

Nilai box loss dan class loss menurun konsisten masing-masing sebesar 26,6% (dari 1,546 menjadi 1,135) dan 86,2% (dari 3,158 menjadi 0,437) dari epoch pertama hingga terakhir, sedangkan mAP50 meningkat tajam dari 0,541 menjadi stabil pada kisaran 0,927-0,938 sejak epoch ke-40, mengindikasikan model telah mendekati titik konvergensi. Berdasarkan nilai fitness gabungan, bobot model terbaik (best.pt) diperoleh pada epoch ke-78, bukan pada epoch terakhir, sehingga

mekanisme checkpoint terbaik penting diterapkan dalam proses pelatihan.

C. Evaluasi Model


Evaluasi akhir dilakukan menggunakan confusion matrix (Gambar 9) pada data validasi, yang menunjukkan model berhasil mengenali dengan benar 1.053 objek head dan 3.385 objek helmet, dengan kesalahan klasifikasi antar kelas yang relatif kecil (11 objek head diprediksi sebagai helmet dan 14 objek helmet diprediksi sebagai head), sehingga sumber kesalahan utama berasal dari objek yang gagal terdeteksi (missed detection) sebanyak 96 objek head dan 275 objek helmet pada objek berukuran kecil atau mengalami oklusi, ditambah 152 dan 361 objek latar belakang yang salah dikenali sebagai head dan helmet, bukan dari kekeliruan membedakan kelas head dan helmet itu sendiri.



Gambar 9. Confusion Matrix Hasil Pengujian Model

Tabel 6. Precision, Recall, F1-Score, dan AP per Kelas

Kelas	Precision	Recall	F1-Score	AP@0,5
head	86,6%	90,5%	88,5%	92,4%
helmet	90,0%	92,2%	91,1%	94,9%
Rata-rata / mAP50	88,3%	91,4%	89,8%	93,6%



Gambar 10. Kurva Precision-Recall pada Ambang IoU 0,5

Kelas helmet secara konsisten unggul dibandingkan kelas head pada seluruh metrik, sejalan dengan jumlah data latih helmet yang sekitar 3,3 kali lebih banyak (18.966 berbanding 5.785 instance pada keseluruhan dataset). Model memperoleh mAP50 sebesar 93,6% dan mAP50-95 sebesar 62,2% pada data validasi; kesenjangan antara kedua nilai tersebut wajar terjadi pada

model deteksi objek karena mAP50-95 menuntut kesesuaian bounding box yang jauh lebih presisi pada ambang IoU tinggi. Evaluasi tambahan pada data uji (test set) yang sama sekali tidak dilibatkan selama pelatihan menunjukkan mAP50 sebesar 92,5%, atau hanya turun sekitar 1,1 poin persentase dibandingkan data validasi, sehingga generalization gap ini tergolong wajar dan tidak mengindikasikan overfitting yang berarti pada model yang dihasilkan.

D. Pengujian Blackbox Sistem

Pengujian fungsional dilakukan dengan metode black-box terhadap seluruh modul sistem untuk memastikan setiap fitur berjalan sesuai kebutuhan fungsional yang telah didefinisikan pada Tabel 1. Hasil pengujian dirangkum pada Tabel 7.

Tabel 7. Ringkasan Hasil Pengujian Blackbox

Modul	Jumlah Skenario	Status
Login & Logout	4	Valid
Dashboard Monitoring	6	Valid
Riwayat Pelanggaran	4	Valid
Kelola Peringatan (Speaker)	4	Valid
Kelola Pengguna	5	Valid
Settings (Ubah Password)	4	Valid

Seluruh 27 skenario pengujian pada enam modul menunjukkan hasil yang sesuai harapan (status Valid), yang menunjukkan bahwa fungsi autentikasi, monitoring real-time, pencatatan pelanggaran, pengelolaan perangkat speaker dan kamera, serta pengelolaan pengguna telah berjalan sebagaimana dirancang.

IV. KESIMPULAN

Penelitian ini berhasil merancang dan membangun sistem monitoring kepatuhan penggunaan helm keselamatan kerja berbasis area yang mengintegrasikan model YOLOv10, mekanisme peringatan otomatis berbasis ESP32 dan speaker per zona, serta dashboard website sebagai pusat monitoring. Model YOLOv10 yang dilatih selama 98 epoch (dari maksimum 100 epoch dengan mekanisme early stopping) pada 5.000 citra beranotasi menghasilkan performa yang tergolong baik dengan precision 92,2%, recall 87,2%, mAP50 92,5%, dan mAP50-95 60,4% pada data validasi, dengan kelas helm (AP 96,0%) menunjukkan performa lebih baik dibandingkan kelas head (AP 89,0%) sebagai konsekuensi dari ketidakseimbangan jumlah data latih antar kelas.

Sistem mampu menyimpan setiap pelanggaran secara terstruktur beserta bukti snapshot dan memicu peringatan suara secara langsung pada zona yang terdeteksi pelanggaran tanpa harus menunggu teguran manual dari petugas K3,

sebagaimana dibuktikan melalui pengujian black-box yang menunjukkan seluruh fitur berjalan sesuai kebutuhan. Pengembangan lebih lanjut disarankan untuk memperluas cakupan deteksi pada jenis APD lain seperti rompi dan sepatu keselamatan, menyeimbangkan jumlah data latih antar kelas, serta menguji model pada kondisi pencahayaan dan sudut kamera yang lebih beragam guna meningkatkan kemampuan generalisasi sistem di lingkungan kerja nyata.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada Ibu Sukma Evadini selaku dosen pembimbing atas arahan dan bimbingan selama penyusunan penelitian ini, kepada pihak PT XYZ yang telah memberikan izin observasi dan pengumpulan data di lingkungan kerja, serta kepada keluarga dan rekan-rekan mahasiswa atas dukungan yang diberikan selama proses penelitian.

DAFTAR PUSTAKA

- Amangeldy, B., Imankulov, T., Tasmurzayev, N., Dikhanbayeva, G., & Nurakhov, Y. (2025). A review of artificial intelligence and deep learning approaches for resource management in smart buildings. *Buildings*, 15(15), 2631.
- Bassil, Y. (2012). A simulation model for the waterfall software development life cycle. *International Journal of Engineering & Technology*, 2(5), 1-7.
- BPJS Ketenagakerjaan. (2024). Kecelakaan kerja makin marak dalam lima tahun terakhir. <https://www.bpjsketenagakerjaan.go.id>.
- Du, Q., Zhang, S., & Yang, S. (2025). BLP-YOLOv10: Efficient safety helmet detection for low-light mining. *Journal of Real-Time Image Processing*, 22, 10.
- Imran, A., Hulikal, M. S., & Gardi, H. A. A. (2024). Safety helmet monitoring on construction sites using YOLOv10 and advanced transformer architectures with surveillance and body-worn cameras. *Journal of Construction Engineering and Management*, 151(11).
- Nath, N. D., Behzadan, A. H., & Paal, S. G. (2020). Deep learning for site safety: Real-time detection of personal protective equipment. *Automation in Construction*, 112, 103085.
- Rafindadi, A. D., Napiah, M., Othman, I., Alarifi, H., Musa, U., Iro, U. I., & Memon, A. H. (2022). Significant factors that influence the use and non-use of personal protective equipment (PPE) on construction sites: supervisors' perspective. *Ain Shams Engineering Journal*, 13(3), 101619.
- Vukicevic, A. M., Djapan, M., Isailovic, V., Milasinovic, D., Savkovic, M., & Milosevic, P. (2022). Generic compliance of industrial PPE by using deep learning techniques. *Safety Science*, 148, 105646.

Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J., & Ding, G. (2024). YOLOv10: Real-time end-to-end object detection. arXiv preprint arXiv:2405.14458.

World Health Organization. (2021). WHO/ILO joint estimates of the work-related burden of disease and injury, 2000-2016. Geneva: World Health Organization.