

Sistem Terintegrasi YOLO dan Logika *Fuzzy* Mamdani untuk Deteksi APD dan Klasifikasi Respons Keselamatan Kerja

Muhammad Rais Fahd Al Hakim¹, Tri Joko Wahyu Adi^{2*}, Yusroniya Eka Putri Rachman Waliulu³

¹⁻³Institut Teknologi Sepuluh Nopember, Indonesia

Corresponding Author's e-mail: trijoko@its.ac.id



e-ISSN: 2964-2981

ARMADA : Jurnal Penelitian Multidisiplin

<https://ejournal.45mataram.ac.id/index.php/armada>

Vol. 04, No. 07 Juli, 2026

Page: 2353-2363

DOI:

<https://doi.org/10.55681/armada.v4i7.2790>

Article History:

Received: Mei 09, 2026

Revised: Juni 16, 2026

Accepted: Juli 16, 2026

Abstract : Workplace accidents in the industrial and construction sectors still frequently cause serious injuries and deaths. Manual monitoring of compliance with Personal Protective Equipment (PPE) use is considered inefficient and prone to human error. This study develops a real-time PPE detection and adaptive safety response system by integrating YOLOv12 and the Mamdani Fuzzy Logic Inference System. YOLOv12 is used to detect helmets, safety vests, gloves, boots, dust masks, and face shields from video streams. The compliance level is calculated through weighting based on the type of work activity, then processed by the fuzzy system to determine four response categories: safe, warning, local alarm, and stop work. Testing on real-world construction videos resulted in an overall mAP50 of 0.796 and reached 0.972 in the Safety Shoes class. The fuzzy system produced a Local Alarm response of 38.61 at 50.0% compliance and a Safe response of 85.4 at 97.0% compliance. This YOLO-Fuzzy framework demonstrates potential as an automated, adaptive, and scalable solution for PPE compliance monitoring in construction environments.

Keywords : YOLO, Fuzzy Logic, Personal Protective Equipment, Object Detection, Construction Safety

Abstrak : Kecelakaan kerja di sektor industri dan konstruksi masih sering menyebabkan cedera serius dan kematian. Pemantauan kepatuhan penggunaan Alat Pelindung Diri (APD) secara manual dinilai tidak efisien dan rentan terhadap kesalahan manusia. Penelitian ini mengembangkan sistem deteksi APD dan respons keselamatan adaptif secara real-time dengan mengintegrasikan YOLOv12 dan Sistem Inferensi Logika Fuzzy Mamdani. YOLOv12 digunakan untuk mendeteksi helm, rompi keselamatan, sarung tangan, sepatu bot, masker debu, dan pelindung wajah dari aliran video. Tingkat kepatuhan dihitung melalui pembobotan berdasarkan jenis aktivitas kerja, kemudian diproses oleh sistem fuzzy untuk menentukan empat kategori respons, yaitu aman, peringatan, alarm lokal, dan hentikan pekerjaan. Pengujian pada video konstruksi dunia nyata menghasilkan mAP50 keseluruhan sebesar 0,796 dan mencapai 0,972 pada kelas Sepatu Keselamatan. Sistem fuzzy menghasilkan respons Alarm Lokal bernilai 38,61 pada kepatuhan 50,0% serta respons Aman bernilai 85,4 pada kepatuhan 97,0%. Kerangka YOLO-Fuzzy ini menunjukkan potensi sebagai solusi otomatis, adaptif, dan skalabel untuk pemantauan kepatuhan APD di lingkungan konstruksi.

Kata Kunci : YOLO, Logika *Fuzzy*, Alat Pelindung Diri, Deteksi Objek, Keselamatan Konstruksi

PENDAHULUAN

Kecelakaan kerja pada sektor industri dan konstruksi masih menjadi isu keselamatan yang serius karena pekerjaan di lapangan berlangsung dalam kondisi dinamis, melibatkan alat berat, perpindahan material, area kerja yang berubah, serta interaksi pekerja yang padat. Tinjauan sistematis menunjukkan bahwa sektor konstruksi tetap berkontribusi besar terhadap cedera dan kematian kerja, sehingga membutuhkan sistem pencegahan yang lebih proaktif dan berkelanjutan (Babalola *et al.*, 2023; Almaskati *et al.*, 2024). Penggunaan Alat Pelindung Diri (APD), seperti helm, rompi keselamatan, sarung tangan, sepatu pelindung, dan kacamata kerja, menjadi salah satu strategi utama untuk menurunkan risiko paparan bahaya di tempat kerja (Almaskati *et al.*, 2024; Jin & Goodrum, 2024). Namun, kepatuhan APD masih dipengaruhi oleh berbagai faktor, termasuk lemahnya pengawasan, rendahnya persepsi risiko, kurangnya pelatihan, ketidaknyamanan APD, dan dukungan manajemen yang belum konsisten (Al-Bayati *et al.*, 2023). Karena lokasi konstruksi bersifat luas dan berubah cepat, pengawasan manual sering sulit menjangkau seluruh area secara konsisten, sehingga teknologi berbasis *computer vision* dan kecerdasan buatan mulai dipandang sebagai pendekatan penting untuk pemantauan keselamatan secara *real-time* (Fang *et al.*, 2020; Shah & Mishra, 2024).

Pendekatan *deep learning* menunjukkan potensi besar dalam meningkatkan efektivitas pemantauan keselamatan kerja, terutama untuk mendeteksi objek visual seperti pekerja, alat berat, area bahaya, dan kelengkapan APD. Algoritma *You Only Look Once* (YOLO) banyak digunakan karena mampu menyeimbangkan kecepatan inferensi dan akurasi deteksi, sehingga sesuai untuk kebutuhan pemantauan lapangan secara *real-time* (Sapkota *et al.*, 2025; Then Yung *et al.*, 2022). Dalam deteksi APD, Arip *et al.* (2024) melaporkan bahwa model YOLOv8 mampu mengenali beberapa atribut keselamatan dengan skor deteksi di atas 0,8, termasuk helm keselamatan, sarung tangan, dan rompi. Selain itu, tinjauan sistematis terbaru menunjukkan bahwa CNN dan YOLO merupakan pendekatan yang dominan dalam aplikasi AI untuk pengenalan APD, deteksi bahaya, dan pemantauan kepatuhan keselamatan konstruksi (Badhan & Samsami, 2025). Meskipun demikian, banyak sistem deteksi masih berhenti pada tahap pengenalan objek, sehingga belum sepenuhnya menyediakan penilaian risiko, prioritas respons, atau keputusan keselamatan yang mudah ditafsirkan oleh pengawas lapangan (Fang *et al.*, 2020; Badhan & Samsami, 2025).

Untuk menjembatani hasil deteksi visual dengan keputusan keselamatan yang lebih adaptif, logika *fuzzy* dapat digunakan sebagai mekanisme penalaran berbasis aturan. *Fuzzy inference system* sesuai untuk konteks keselamatan kerja karena mampu menangani ketidakpastian, data yang tidak lengkap, serta penilaian linguistik seperti rendah, sedang, tinggi, aman, atau berbahaya (Ilbahar *et al.*, 2018; Mitrakas *et al.*, 2025). Sadeghi *et al.* (2020) menunjukkan bahwa integrasi jaringan saraf dan *fuzzy inference* dapat membantu menilai besaran risiko keselamatan konstruksi serta memberikan strategi evaluasi yang lebih informatif. Sejalan dengan itu, Al-Bayati *et al.* (2023) menggunakan teori *fuzzy* untuk memetakan faktor-faktor penyebab ketidakpatuhan APD, sehingga pendekatan *fuzzy* relevan untuk mengubah indikator kepatuhan menjadi kategori keputusan yang lebih operasional. Dalam penelitian ini, *fuzzy Mamdani* diarahkan untuk mengolah skor deteksi APD, tingkat pelanggaran, paparan bahaya, dan tingkat risiko menjadi keluaran kualitatif seperti Aman, Peringatan, Alarm Lokal, dan Hentikan Pekerjaan.

Berdasarkan uraian tersebut, penelitian ini mengusulkan kerangka kerja terintegrasi YOLO-*Fuzzy* untuk manajemen keselamatan adaptif secara *real-time*. YOLO berperan sebagai modul deteksi visual yang mengenali keberadaan pekerja dan kelengkapan APD, sedangkan *fuzzy Mamdani* berperan sebagai modul pengambilan keputusan yang mengklasifikasikan tingkat kepatuhan dan menentukan respons keselamatan. Model hibrida ini menghubungkan keluaran kuantitatif dari *deep learning* dengan aturan keputusan yang lebih interpretatif, sehingga sistem tidak hanya mendeteksi pelanggaran, tetapi juga membantu menentukan tingkat urgensi tindakan. Dengan demikian, kerangka kerja ini diharapkan dapat mengurangi ketergantungan pada inspeksi manual, meningkatkan konsistensi pemantauan, dan memperkuat pencegahan risiko pada

lingkungan industri dan konstruksi (Sadeghi *et al.*, 2020; Jin & Goodrum, 2024; Mitrakas *et al.*, 2025).

METODE PENELITIAN

Penelitian ini mengintegrasikan model deteksi otomatis berbasis YOLO dengan Sistem Logika Fuzzy Mamdani untuk membangun kerangka kerja manajemen keselamatan adaptif secara *real-time*. Proses penelitian terdiri atas empat tahap utama: (1) deteksi APD menggunakan YOLO, (2) pembobotan kepentingan APD berdasarkan jenis aktivitas kerja, (3) perhitungan skor kepatuhan APD, dan (4) penentuan tingkat respons keselamatan melalui inferensi fuzzy. Alur kerja konseptual sistem yang diusulkan ditunjukkan pada Gambar 1.



Gambar 1. Alur Kerja Sistem Terintegrasi YOLO-Fuzzy untuk Deteksi APD dan Pengambilan Keputusan Respons Keselamatan Adaptif

Sumber: Hasil Analisis, 2026

Tahap pertama menerapkan algoritma YOLOv12 untuk mendeteksi komponen APD seperti helm, sarung tangan, rompi keselamatan, sepatu bot, masker, dan pelindung wajah/kacamata dari *frame* video secara *real-time* (Tian *et al.*, 2025). YOLO digunakan karena mampu melakukan deteksi objek secara cepat melalui pendekatan *single-stage detection*, sekaligus mempertahankan akurasi yang memadai untuk aplikasi pemantauan visual *real-time* (Sapkota *et al.*, 2025; Badhan & Samsami, 2025). Dalam konteks keselamatan kerja, model YOLO telah banyak digunakan untuk mendeteksi atribut APD seperti helm, sarung tangan, sepatu keselamatan, dan rompi keselamatan sebagai dasar pemantauan kepatuhan pekerja (Arip *et al.*, 2024; Vukicevic *et al.*, 2024).

Setiap *frame* video yang diproses menghasilkan *bounding box*, skor kepercayaan, dan probabilitas kelas untuk setiap objek APD yang terdeteksi. Untuk meningkatkan konsistensi temporal, hasil deteksi diagregasi dalam interval satu menit, sehingga setiap item APD dikonversi menjadi nilai biner, yaitu 1 apabila terdeteksi dan 0 apabila tidak terdeteksi (Zaidi *et al.*, 2024; Kim *et al.*, 2025). Penentuan status deteksi menggunakan ambang skor kepercayaan 0,3 sebagai batas minimum untuk mengklasifikasikan keberadaan APD dalam *frame* pengamatan (Wenkel *et al.*, 2021). Karena setiap aktivitas kerja memiliki karakteristik risiko dan kebutuhan perlindungan yang berbeda, setiap item APD diberi bobot sesuai tingkat kepentingannya. Skema pembobotan pada Tabel 1 diadaptasi dari penelitian terdahulu mengenai penggunaan dan prioritas APD pada pekerjaan konstruksi (Atasoy *et al.*, 2024; Yankson *et al.*, 2021). Pendekatan ini juga sejalan dengan studi pengambilan keputusan keselamatan konstruksi yang menggunakan metode multi-kriteria berbasis fuzzy untuk menilai prioritas APD dalam kondisi informasi yang tidak pasti atau bersifat linguistik (Jin & Goodrum, 2024).

Tabel 1. Penugasan Bobot Alat Pelindung Diri (APD)

Nama Aktivitas	Alat Pelindung Diri	Skor
Pembengkok Besi	Sepatu Keselamatan (0,40)	1,00
	Rompi Keselamatan (0,28)	
	Helm Pelindung (0,14)	
	Masker Debu (0,10)	
	Sarung Tangan (0,08)	

Pekerja Beton	Helm Pelindung (0,20) Pelindung Wajah (0,03) Rompi Keselamatan (0,24) Sepatu Keselamatan (0,30) Sarung Tangan (0,23)	1,00
---------------	--	------

Sumber: Hasil Analisis, 2026


Tahap selanjutnya adalah menghitung tingkat kepatuhan APD pekerja. Skor kepatuhan, yang dilambangkan sebagai S , dihitung menggunakan penjumlahan berbobot sebagaimana ditunjukkan pada Persamaan (1).

$$S_a = \left(\sum_{i=1}^{n_a} w_{a,i} G_{a,i} \right) \times 100\% \text{ dengan } \sum_{i=1}^{n_a} w_{a,i} = 1, G_{a,i} \in \{0,1\} \quad (1)$$

Sumber: Hasil Analisis, 2026

$w_{a,i}$ menyatakan bobot kepentingan item APD ke- i pada aktivitas kerja a sebagaimana ditetapkan pada Tabel 1, $G_{a,i}$ merupakan hasil deteksi biner item APD ke- i (bernilai 1 apabila terdeteksi dan 0 apabila tidak terdeteksi, dengan indeks i mengikuti urutan penulisan item APD pada Tabel 1), dan n_a adalah jumlah item APD yang dipersyaratkan pada aktivitas a . Seluruh bobot dinormalisasi sehingga penjumlahannya bernilai tepat 1,00. Dengan demikian, nilai S_a berada pada rentang 0 sampai 100%, yang menunjukkan persentase kelengkapan APD selama periode pengamatan sesuai profil risiko masing-masing aktivitas. Semakin tinggi nilai S_a , semakin tinggi tingkat kepatuhan pekerja terhadap penggunaan APD yang dipersyaratkan. Skor ini kemudian digunakan sebagai input pada sistem inferensi *fuzzy* untuk menentukan tingkat respons keselamatan adaptif.

Proses pengambilan keputusan menggunakan Logika *Fuzzy* Mamdani karena metode ini mudah diinterpretasikan, menggunakan aturan linguistik IF-THEN, dan sesuai untuk memodelkan keputusan dalam kondisi yang mengandung ketidakpastian (Gu *et al.*, 2023; Muhammad *et al.*, 2021). Sistem inferensi *fuzzy* terdiri atas satu variabel *input*, yaitu Skor Kepatuhan APD (%), dan satu variabel *output*, yaitu Tingkat Respons Keselamatan (%). Variabel *input* diklasifikasikan ke dalam tiga istilah linguistik, yaitu Tidak Digunakan, Digunakan Sebagian, dan Digunakan Lengkap. Sementara itu, variabel *output* diklasifikasikan ke dalam empat tingkat respons keselamatan, yaitu Hentikan Pekerjaan, Alarm Lokal, Peringatan, dan Aman (Nor *et al.*, 2013).



Gambar 2. Fungsi Keanggotaan *Input* dan *Output* Sistem Inferensi *Fuzzy* untuk Skor Kepatuhan APD dan Tingkat Respons Keselamatan

Sumber: Hasil Analisis, 2026

Tabel 2. Aturan Inferensi Logika *Fuzzy* untuk Menentukan Tingkat Respons Keselamatan

No	Aturan Inferensi <i>Fuzzy</i>
R1	IF Skor Kepatuhan APD is Tidak Digunakan THEN Tingkat Respons Keselamatan is Hentikan Pekerjaan
R2	IF Skor Kepatuhan APD is Digunakan Sebagian THEN Tingkat Respons Keselamatan is Alarm Lokal
R3	IF Skor Kepatuhan APD is Digunakan Lengkap THEN Tingkat Respons Keselamatan is Aman

Sumber: Hasil Analisis, 2026

Sebagaimana ditunjukkan pada Gambar 2, variabel input Skor Kepatuhan APD direpresentasikan oleh tiga fungsi keanggotaan, yaitu Tidak Digunakan (trapesium; keanggotaan penuh pada 0–5 dan menurun hingga 31), Digunakan Sebagian (segitiga; 12–44–70), dan Digunakan Lengkap (trapesium; naik mulai 54 dan penuh pada 84–100). Variabel output Tingkat Respons Keselamatan direpresentasikan oleh empat fungsi keanggotaan, yaitu Hentikan Pekerjaan (trapesium; 0–5–31), Alarm Lokal (segitiga; 14–40–62), Peringatan (segitiga; 31–56–80), dan Aman (trapesium; 60–86–100). Batas-batas numerik tersebut ditentukan melalui pertimbangan keselamatan kerja dan penyesuaian empiris pada data validasi. Dengan demikian, seluruh batas numerik dinyatakan sepenuhnya pada fungsi keanggotaan, sedangkan aturan inferensi pada Tabel 2 dinyatakan murni dalam ekspresi linguistik.

Kategori output Peringatan dipertahankan dalam semesta output sebagai tingkat transisi antara Alarm Lokal dan Aman. Meskipun tidak diaktifkan langsung oleh aturan pada konfigurasi satu input saat ini, kategori ini disediakan untuk pengembangan sistem multi-input pada penelitian selanjutnya, misalnya penambahan variabel faktor risiko lingkungan atau durasi pelanggaran tanpa mengubah arsitektur empat tingkat respons yang digunakan dalam prosedur keselamatan di lapangan.

Fungsi keanggotaan dirancang menggunakan bentuk segitiga dan trapesium karena kedua bentuk tersebut umum digunakan dalam sistem *fuzzy*, mudah diinterpretasikan, dan mampu menghasilkan transisi antarkategori yang halus (Khairuddin *et al.*, 2021; Sabripoor *et al.*, 2024). Hubungan antara variabel *input* dan *output* didefinisikan melalui basis aturan inferensi sebagaimana dirangkum pada Tabel 2. Aturan inferensi dinyatakan sepenuhnya dalam ekspresi linguistik IF-THEN, sedangkan seluruh batas numerik ditetapkan pada fungsi keanggotaan Gambar 2 melalui pertimbangan keselamatan kerja dan penyesuaian empiris pada data validasi, sehingga sistem dapat menghasilkan respons yang proporsional terhadap tingkat kepatuhan APD (Gu *et al.*, 2023; Ojha *et al.*, 2019). Proses *defuzzifikasi* dilakukan menggunakan metode *centroid* atau *center of gravity* untuk menghasilkan nilai *crisp* tunggal sebagai dasar penentuan respons keselamatan secara *real-time* (Sabripoor *et al.*, 2024).

Sistem terintegrasi YOLO-Fuzzy diimplementasikan dalam lingkungan pemantauan *real-time*. Modul YOLO dijalankan pada platform berbasis GPU untuk menjaga performa *frame-per-second* yang memadai, sedangkan modul *fuzzy* berjalan secara paralel untuk menginterpretasikan skor kepatuhan dan menghasilkan respons adaptif. Melalui integrasi ini, sistem dapat mendukung pengawasan keselamatan secara berkelanjutan, menampilkan peringatan visual, mengaktifkan Alarm Lokal, atau memberikan instruksi Hentikan Pekerjaan ketika pelanggaran APD terdeteksi.

HASIL DAN PEMBAHASAN

Fase implementasi bertujuan untuk mengevaluasi kinerja model YOLO yang telah dilatih dalam mendeteksi berbagai item Alat Pelindung Diri (APD) dan untuk menilai bagaimana sistem inferensi *fuzzy* terintegrasi menerjemahkan skor kepatuhan menjadi respons keselamatan adaptif. Model diuji pada sampel video dunia nyata yang mewakili dua aktivitas konstruksi yang berbeda, yaitu pembengkokan besi (*steel bending*) dan pengecoran beton (*concrete work*), yang masing-masing memerlukan set APD yang berbeda sesuai dengan bahaya terkait (BlackBoxGuild, 2025; Roboflow, 2024). Kinerja deteksi model YOLO dievaluasi secara kuantitatif menggunakan metrik utama termasuk *Precision* (P), *Recall* (R), *mean Average Precision* pada ambang batas *IoU* 50% (*mAP50*), dan *mean Average Precision* pada berbagai ambang batas (*mAP50-95*). Hasil kinerja deteksi objek di semua kelas APD dirangkum dalam Tabel 3.

Tabel 3. Evaluasi Kinerja Deteksi Objek YOLO pada *Dataset* APD


Class	Images	Instances	P	R	mAP50	mAP50-95
All	637	3064	0,855	0,735	0,796	0,518
Masker Debu	299	308	0,943	0,834	0,896	0,593
Kacamata Pelindung	146	147	0,710	0,667	0,706	0,375
Sarung Tangan	346	631	0,882	0,853	0,893	0,579
Sepatu Keselamatan	298	608	0,865	0,956	0,972	0,666
Helm Pelindung	403	753	0,859	0,866	0,919	0,652

Rompi Keselamatan	359	592	0,723	0,828	0,846	0,593
Pelindung Wajah	25	25	1,000	0,144	0,343	0,168

Sumber: Hasil Analisis, 2026


Tabel 3 menunjukkan bahwa model YOLO mencapai akurasi deteksi keseluruhan $mAP50 = 0,796$ dan $mAP50-95 = 0,518$, menunjukkan kemampuan yang kuat di berbagai kelas APD. Di antara semua item, Sepatu Keselamatan memperoleh *recall* tertinggi ($R = 0,956$) dengan *precision* 0,865 dan $mAP50$ sebesar 0,972, diikuti oleh Helm Pelindung (0,919) dan Sarung Tangan (0,893). Hasil ini mengonfirmasi bahwa objek APD dengan kontur yang jelas, kontras warna yang tinggi, dan bentuk yang konsisten lebih mudah diidentifikasi secara akurat oleh jaringan YOLO (Tian *et al.*, 2025). *Precision* tertinggi justru tercatat pada Pelindung Wajah ($P = 1,000$) dan Masker Debu ($P = 0,943$), namun nilai pada Pelindung Wajah tidak dapat ditafsirkan sebagai keunggulan karena hanya didukung 25 *instance* dengan *recall* yang sangat rendah ($R = 0,144$). Sebaliknya, Kacamata Pelindung dan Pelindung Wajah mencatat akurasi yang lebih rendah ($mAP50 = 0,706$ dan 0,343) karena keterbatasan representasi *dataset*, ukuran objek yang lebih kecil, dan oklusi visual dalam kondisi lapangan.

Mean *average precision* lintas ambang batas *IoU* ($mAP50-95 = 0,518$) juga menunjukkan bahwa meskipun model berkinerja sangat baik pada ambang batas standar ($IoU = 0,5$), kinerja sedikit menurun pada overlap yang lebih ketat. Hal ini merupakan hasil yang khas dalam deteksi dunia nyata (Wenkel *et al.*, 2021). *Precision* keseluruhan ($P = 0,855$) dan *recall* ($R = 0,735$) lebih lanjut mengindikasikan bahwa YOLOv12 (Tian *et al.*, 2025) tidak hanya mendeteksi objek APD secara efektif tetapi juga menekan *false negative* pada tingkat agregat, meskipun capaian ini belum merata pada seluruh kelas. Keseimbangan antara *precision* dan *recall* ini mencerminkan generalisasi yang kuat di berbagai *scene* industri yang kompleks. Pola klasifikasi antar kelas dianalisis lebih lanjut melalui *confusion matrix* yang dinormalisasi pada Gambar 3. Kelas Sepatu Keselamatan menunjukkan tingkat klasifikasi benar tertinggi sebesar 0,96, diikuti oleh Helm Pelindung (0,92), Rompi Keselamatan (0,89), serta Masker Debu dan Sarung Tangan yang masing-masing mencapai 0,86. Sebaliknya, kelas Pelindung Wajah hanya memperoleh nilai sebesar 0,36 disebabkan oleh terbatasnya jumlah data pelatihan (25 *instance*). Kacamata Pelindung juga menunjukkan kecenderungan serupa dengan nilai diagonal 0,72 dan tingkat misklasifikasi terhadap *background* sebesar 0,09. Selain itu, baris *background* pada *confusion matrix* menunjukkan adanya *false positive*, di mana objek latar belakang salah teridentifikasi sebagai Kacamata Pelindung (0,27) dan Sarung Tangan (0,13), yang mengindikasikan bahwa model masih memerlukan penyempurnaan pada kelas dengan fitur visual yang kecil dan kurang distingtif.



Gambar 3. *Confusion Matrix* model YOLOv12 pada Deteksi Kelas APD

Sumber: Hasil Analisis, 2026



Gambar 4. Visualisasi Hasil Deteksi APD Secara *Real-Time* Menggunakan YOLOv12

Sumber: Hasil Analisis, 2026

Meskipun demikian, kinerja deteksi pada kelas Pelindung Wajah memerlukan ulasan kritis. Nilai *recall* sebesar 0,144 mengindikasikan bahwa sistem melewati sekitar 85,6% pekerja yang sebenarnya memakai Pelindung Wajah di lapangan. Dalam konteks keselamatan dan kesehatan kerja (K3), *false negative* semacam ini berbahaya secara operasional: pekerja yang patuh dapat dinilai melanggar, sehingga skor kepatuhan *S* terhitung lebih rendah dari kondisi sesungguhnya dan memicu *false alarm* pada sistem keputusan *fuzzy* hilir, misalnya aktivasi Alarm Lokal atau instruksi Hentikan Pekerjaan yang keliru. Penghentian pekerjaan yang tidak perlu tidak hanya menimbulkan kerugian produktivitas, tetapi juga dapat menurunkan kepercayaan pengguna terhadap sistem (*alarm fatigue*), sehingga peringatan yang sesungguhnya penting berisiko diabaikan. Fenomena ini telah terindikasi pada skenario Pekerja Beton (Tabel 4), di mana Pelindung Wajah tidak terdeteksi meskipun sistem tetap mengklasifikasikan kondisi sebagai Aman karena bobotnya kecil (0,03); pada aktivitas dengan bobot Pelindung Wajah yang lebih besar, kegagalan deteksi serupa akan langsung menggeser keputusan ke tingkat respons yang lebih ketat secara keliru. Akar masalahnya adalah representasi data latih yang sangat terbatas (25 *instance*), ukuran objek yang kecil, dan oklusi visual. Oleh karena itu, penelitian selanjutnya perlu memprioritaskan (1) penambahan dan augmentasi data untuk kelas minoritas, (2) strategi pelatihan yang peka terhadap ketidakseimbangan kelas seperti *oversampling* atau *class-balanced loss*, serta (3) penyesuaian ambang kepercayaan per kelas dan mekanisme agregasi temporal yang lebih toleran, agar keputusan *fuzzy* hilir tidak digerakkan oleh kegagalan deteksi tunggal.

Gambar 4 menyajikan contoh hasil deteksi APD secara *real-time* pada skenario aktivitas pengecoran beton. Pada *frame* tersebut, model berhasil mendeteksi tiga objek Rompi Keselamatan dengan skor kepercayaan masing-masing 0,85, 0,69, dan 0,60, serta satu objek Helm Pelindung dengan skor 0,49. Variasi skor kepercayaan ini mengindikasikan bahwa pekerja dengan posisi tubuh yang jelas dan tidak terhalang memperoleh skor deteksi yang lebih tinggi, sedangkan pekerja yang membungkuk atau mengalami oklusi parsial cenderung memperoleh skor yang lebih rendah. Meskipun demikian, APD lain seperti Sarung Tangan dan Sepatu Keselamatan tidak terdeteksi pada *frame* ini, yang kemungkinan disebabkan oleh sudut pandang kamera dan oklusi oleh material konstruksi.

Setelah deteksi berhasil, sistem melanjutkan untuk mengevaluasi skor kepatuhan APD menggunakan mekanisme pembobotan skor yang dijelaskan pada bagian metode. Setiap APD yang terdeteksi berkontribusi secara proporsional terhadap skor kepatuhan keseluruhan (*S*), yang berfungsi sebagai input untuk Sistem Inferensi *Fuzzy* Mamdani (FIS). Sistem *fuzzy* kemudian mengklasifikasikan tingkat respons keselamatan menjadi empat kategori, yaitu Aman, Peringatan, Alarm Lokal, atau Hentikan Pekerjaan, seperti yang didefinisikan dalam Tabel 2. Output dari proses pengambilan keputusan *fuzzy* untuk dua aktivitas sampel disajikan dalam Tabel 4.

Tabel 4. Hasil Skor Kepatuhan APD dan Klasifikasi Respons Keselamatan Adaptif

Aktivitas	Deteksi APD	S (%)	Respons	Aksi	Keterangan
Pembengkok Besi	G1=0,G2=1,G3=1,G4=0,G5=1	50,0	38,61	Alarm Lokal	Sepatu Keselamatan dan Masker

Pekerja Beton	G1=1,G2=0,G3=1,G4=1,G5=1	97,0	85,4	Aman	Debu tidak terdeteksi Pelindung Wajah tidak terdeteksi
---------------	--------------------------	------	------	------	---

Sumber: Hasil Analisis, 2026

Seperti yang ditunjukkan, pembengkok besi memperoleh skor kepatuhan APD sebesar 50,0% yang setelah defuzzifikasi *centroid* menghasilkan nilai respons keselamatan 38,61, sehingga diklasifikasikan sebagai Alarm Lokal, yang menunjukkan penggunaan APD parsial akibat tidak terdeteksinya sepatu keselamatan dan masker debu. Sementara itu, pekerja beton memperoleh skor kepatuhan APD sebesar 97,0% dengan nilai respons keselamatan 85,4, dikategorikan sebagai Aman, mencerminkan kepatuhan yang hampir lengkap kecuali tidak terdeteksinya pelindung wajah.

Untuk membuktikan validitas konversi dari penilaian kualitatif menjadi keputusan aksi konkret, berikut disajikan contoh perhitungan defuzzifikasi *centroid* secara bertahap untuk aktivitas Pembengkok Besi dengan input skor kepatuhan $S = 50,0\%$. Pada tahap fuzzifikasi, nilai tersebut hanya mengaktifkan satu himpunan input, yaitu Digunakan Sebagian, dengan derajat keanggotaan $\mu = (70 - 50)/(70 - 44) = 0,769$, sedangkan himpunan Tidak Digunakan dan Digunakan Lengkap bernilai $\mu = 0$ karena berada di luar rentang dukungannya. Dengan demikian, hanya aturan R2 yang aktif. Pada tahap implikasi, fungsi keanggotaan output Alarm Lokal (segitiga 14–40–62) dipotong dengan operator min pada tingkat $\alpha = 0,769$, sehingga terbentuk himpunan trapesium dengan titik potong pada $z = 34,00$ dan $z = 45,08$. Tahap agregasi menghasilkan himpunan *fuzzy* gabungan yang identik dengan hasil pemotongan tersebut karena tidak terdapat aturan lain yang aktif. Nilai *crisp* selanjutnya diperoleh melalui metode centroid sebagaimana ditunjukkan pada Persamaan (2).

$$z^* = \frac{\int z \cdot \mu(z) dz}{\int \mu(z) dz} \quad (2)$$

Sumber: Hasil Analisis, 2026

Perhitungan luas dan momen dilakukan dengan membagi himpunan hasil agregasi menjadi tiga segmen, yaitu segmen naik ($14 \leq z \leq 34,00$) dengan luas 7,69 dan titik berat 27,33; segmen datar ($34,00 \leq z \leq 45,08$) dengan luas 8,52 dan titik berat 39,54; serta segmen turun ($45,08 \leq z \leq 62$) dengan luas 6,51 dan titik berat 50,72. Substitusi ketiga segmen tersebut ke Persamaan (2) menghasilkan $z^* = 877,09 / 22,72 = 38,61$, sebagaimana tercantum pada Tabel 4, dan nilai ini berada pada wilayah dominasi himpunan output Alarm Lokal sehingga sistem menetapkan aksi Alarm Lokal. Contoh ini menunjukkan bahwa defuzzifikasi *centroid* tidak semata memilih kategori dengan derajat keanggotaan tertinggi, tetapi juga memperhitungkan asimetri fungsi keanggotaan output. Ketidaksimetrisan segitiga Alarm Lokal, yaitu rentang 26 pada sisi naik dan 22 pada sisi turun, menggeser titik berat ke kiri dari puncak 40 menjadi 38,61, sehingga keputusan yang dihasilkan bersifat kontinu dan proporsional terhadap tingkat kepatuhan, bukan biner.

Temuan ini mengonfirmasi bahwa sistem YOLO-Fuzzy yang diusulkan secara efektif mengkuantifikasi kepatuhan APD dari skor deteksi dan mengubahnya menjadi respons keselamatan adaptif. Transisi bertahap antar tingkat keselamatan, dari Aman menuju Peringatan, kemudian Alarm Lokal, hingga Hentikan Pekerjaan, mendemonstrasikan kemampuan inferensi *fuzzy* dalam menginterpretasikan hasil deteksi numerik menjadi logika keputusan menyerupai manusia, sehingga menghindari hasil yang tiba-tiba atau biner yang khas pada sistem berbasis ambang batas (Mohandes & Zhang, 2019). Integrasi metrik akurasi deteksi (*Precision*, *Recall*, dan *mAP*) dengan output keputusan *fuzzy* menciptakan hubungan yang kuat antara kepercayaan model dan respons keselamatan yang sesuai. Secara keseluruhan, integrasi YOLO-Fuzzy menyediakan kerangka kerja yang robust dan cerdas untuk pemantauan keselamatan *real-time*, meminimalkan ketergantungan manusia dan memungkinkan intervensi proaktif untuk mencegah kecelakaan kerja (Zaidi *et al.*, 2024).

KESIMPULAN DAN SARAN

Penelitian ini mengembangkan sistem cerdas dan otomatis untuk mendeteksi Alat Pelindung Diri (APD) dan menghasilkan respons keselamatan adaptif dengan mengintegrasikan model *deep learning* YOLO dengan metode inferensi Logika Fuzzy Mamdani. Model YOLO mencapai akurasi deteksi yang tinggi, dengan *mAP50* keseluruhan sebesar 0,796 dan hingga 0,972 untuk kelas APD tertentu seperti Sepatu Keselamatan, menunjukkan keandalan yang kuat dalam lingkungan konstruksi yang kompleks dan dinamis. Integrasi logika fuzzy mengubah output deteksi YOLO menjadi kerangka pengambilan keputusan interpretatif yang mampu mengklasifikasikan kondisi keselamatan menjadi empat tingkat adaptif, yaitu Aman, Peringatan, Alarm Lokal, dan Hentikan Pekerjaan, berdasarkan skor kepatuhan APD. Pendekatan ini memungkinkan respons yang kontekstual yang meniru penalaran pengawasan manusia tetapi beroperasi lebih cepat dan lebih konsisten. Namun demikian, hasil analisis *confusion matrix* menunjukkan bahwa akurasi klasifikasi pada kelas Pelindung Wajah masih sebesar 0,36 dari 25 *instance* dan Kacamata Pelindung sebesar 0,72 dari 147 *instance*, dengan tingkat misklasifikasi terhadap *background* masing-masing mencapai 0,60 dan 0,09, yang mengindikasikan perlunya peningkatan pada kelas dengan representasi data terbatas dan fitur visual yang kecil.

Kerangka kerja hibrida YOLO-Fuzzy berhasil mengatasi keterbatasan inspeksi keselamatan manual dengan menawarkan pemantauan yang berkelanjutan, objektif, dan *real-time*. Sistem ini meningkatkan pelacakan kepatuhan APD, meminimalkan kesalahan manusia, dan berkontribusi dalam mengurangi kecelakaan kerja, sehingga berpotensi mendukung pengawas lapangan dalam menentukan tingkat intervensi keselamatan secara lebih cepat dan berbasis data pada proyek konstruksi. Pengembangan di masa depan dapat mencakup integrasi data multi-sensor, pemantauan lingkungan, serta sistem visi berbasis drone untuk memperluas cakupan pengawasan pada proyek konstruksi berskala besar dengan area kerja yang tersebar. Selain itu, augmentasi dan perluasan *dataset*, khususnya pada kelas Pelindung Wajah dan Kacamata Pelindung, direkomendasikan untuk mengurangi *false positive* terhadap *background* dan meningkatkan generalisasi model deteksi secara keseluruhan.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada Bapak Tri Joko Wahyu Adi, S.T., M.T., Ph.D., selaku Pembimbing I, atas gagasan awal, arahan konseptual, serta bimbingan intensif yang menjadi landasan dalam pengembangan kerangka kerja terintegrasi YOLO-Fuzzy pada penelitian ini. Penulis juga mengucapkan terima kasih kepada Ibu Dr. Yusroniya Eka Putri Rachman W, S.T., M.T., selaku Pembimbing II, atas ketelitian, kesabaran, serta kontribusi beliau dalam melakukan *review* dan memberikan saran yang membangun selama proses penyusunan manuskrip ini.

DAFTAR PUSTAKA

- Al-Bayati, A. J., Renner, A. T., Listello, M. P., & Mohamed, M. (2023). PPE non-compliance among construction workers: An assessment of contributing factors utilizing fuzzy theory. *Journal of Safety Research*, 85, 242–253. <https://doi.org/10.1016/j.jsr.2023.02.008>
- Almaskati, D., Kermanshachi, S., Pamidimukkala, A., Loganathan, K., & Yin, Z. (2024). A review on construction safety: Hazards, mitigation strategies, and impacted sectors. *Buildings*, 14(2), 526. <https://doi.org/10.3390/buildings14020526>
- Arip, A. A. S., Sazali, N., Kadirgama, K., Jamaludin, A. S., Turan, F. M., & Ab. Razak, N. (2024). Object detection for safety attire using YOLO (You Only Look Once). *Journal of Advanced Research in Applied Mechanics*, 113(1), 37–51. <https://doi.org/10.37934/aram.113.1.3751>
- Atasoy, M., Temel, B. A., & Basaga, H. B. (2024). A study on the use of personal protective equipment among construction workers in Türkiye. *Buildings*, 14(8), 2430. <https://doi.org/10.3390/buildings14082430>
- Babalola, A., Manu, P., Cheung, C., Yunusa-Kaltungo, A., & Bartolo, P. (2023). A systematic review of the application of immersive technologies for safety and health management in the construction sector. *Journal of Safety Research*, 85, 66–85. <https://doi.org/10.1016/j.jsr.2023.01.007>

- Badhan, S. J., & Samsami, R. (2025). Artificial intelligence (AI) in construction safety: A systematic literature review. *Buildings*, 15(22), 4084. <https://doi.org/10.3390/buildings15224084>
- BlackBoxGuild. (2025). Medium shot, workers are busy in the middle of a big construction [Video]. Freepik. https://www.freepik.com/premium-video/medium-shot-workers-are-busy-middle-big-construction_921115
- Fang, W., Ding, L., Luo, H., & Love, P. E. D. (2020). Computer vision applications in construction safety assurance. *Automation in Construction*, 110, 103013. <https://doi.org/10.1016/j.autcon.2019.103013>
- Gu, X., Han, J., Shen, Q., & Angelov, P. P. (2023). Autonomous learning for fuzzy systems: A review. *Artificial Intelligence Review*, 56, 7549–7595. <https://doi.org/10.1007/s10462-022-10355-6>
- Ilbahar, E., Karaşan, A., Cebi, S., & Kahraman, C. (2018). A novel approach to risk assessment for occupational health and safety using Pythagorean fuzzy AHP & fuzzy inference system. *Safety Science*, 103, 124–136. <https://doi.org/10.1016/j.ssci.2017.10.025>
- Jin, H., & Goodrum, P. M. (2024). Prioritization of personal protective equipment plans for construction projects based on an integrated analytic network process and fuzzy VIKOR method. *Applied Sciences*, 14(21), 9904. <https://doi.org/10.3390/app14219904>
- Khairuddin, S. H., Hasan, M. H., Hashmani, M. A., & Azam, M. H. (2021). Generating clustering-based interval fuzzy type-2 triangular and trapezoidal membership functions: A structured literature review. *Symmetry*, 13(2), Article 239. <https://doi.org/10.3390/sym13020239>
- Kim, M. S., Park, B., Sippel, G. J., Mun, A. H., Yang, W., McCarthy, K. H., Fernandez, E., Linguraru, M. G., Sarcevic, A., Marsic, I., & Burd, R. S. (2025). Comparative analysis of personal protective equipment nonadherence detection: Computer vision versus human observers. *Journal of the American Medical Informatics Association*, 32(1), 163–171. <https://doi.org/10.1093/jamia/ocae262>
- Mitrakas, C., Xanthopoulos, A., & Koulouriotis, D. (2025). Techniques and models for addressing occupational risk using fuzzy logic, neural networks, machine learning, and genetic algorithms: A review and meta-analysis. *Applied Sciences*, 15(4), 1909. <https://doi.org/10.3390/app15041909>
- Mohandes, S. R., & Zhang, X. (2019). Towards the development of a comprehensive hybrid fuzzy-based occupational risk assessment model for construction workers. *Safety Science*, 115, 294–309. <https://doi.org/10.1016/j.ssci.2019.02.013>
- Muhammad, K., Obaidat, M. S., Hussain, T., Del Ser, J., Kumar, N., Tanveer, M., & Doctor, F. (2021). Fuzzy logic in surveillance big video data analysis. *ACM Computing Surveys*, 54(3), Article 3444693. <https://doi.org/10.1145/3444693>
- Nor, R. M., Khairunizam, W., Saifizi, S. M., Ayob, M. N., & Wan Yahya, W. M. N. (2013). Design membership functions of a fuzzy logic controller based on experimental study for an obstacle avoidance algorithm. <https://doi.org/10.13140/2.1.2179.7128>
- Ojha, V., Abraham, A., & Snášel, V. (2019). Heuristic design of fuzzy inference systems: A review of three decades of research. *Engineering Applications of Artificial Intelligence*, 85, 845–864. <https://doi.org/10.1016/j.engappai.2019.08.010>
- Roboflow. (2024). PPE detection dataset. Roboflow Universe. https://universe.roboflow.com/project-uyrxf/ppe_detection-v1x3l
- Sabripoor, A., Ghousi, R., Najafi, M., Barzinpour, F., & Makuei, A. (2024). Risk assessment of organ transplant operation: A fuzzy hybrid MCDM approach based on fuzzy FMEA. *PLOS ONE*, 19(5), Article e0299655. <https://doi.org/10.1371/journal.pone.0299655>
- Sadeghi, H., Mohandes, S. R., Hosseini, M. R., Banihashemi, S., Mahdiyar, A., & Abdullah, A. (2020). Developing an ensemble predictive safety risk assessment model: Case of Malaysian construction projects. *International Journal of Environmental Research and Public Health*, 17(22), 8395. <https://doi.org/10.3390/ijerph17228395>
- Sapkota, R., Flores-Calero, M., Qureshi, R., Badgujar, C., Nepal, U., Poulouse, A., Zeno, P., Vaddevolu, U. B. P., Khan, S., Shoman, M., Yan, H., & Karkee, M. (2025). YOLO advances to its genesis: A decadal and comprehensive review of the You Only Look Once (YOLO) series. *Artificial Intelligence Review*, 58, Article 274. <https://doi.org/10.1007/s10462-025-11253-3>

- Shah, I. A., & Mishra, S. (2024). Artificial intelligence in advancing occupational health and safety: An encapsulation of developments. *Journal of Occupational Health*, 66(1), uiad017. <https://doi.org/10.1093/joccuh/uiad017>
- Then Yung, N. D., Wong, W. K., Juwono, F. H., & Sim, Z. A. (2022). Safety helmet detection using deep learning: Implementation and comparative study using YOLOv5, YOLOv6, and YOLOv7. 2022 International Conference on Green Energy, Computing and Sustainable Technology (GECOST). <https://doi.org/10.1109/GECOST55694.2022.10010490>
- Tian, Y., Ye, Q., & Zhang, D. (2025). YOLOv12: Attention-centric real-time object detectors. arXiv preprint arXiv:2502.12524.
- Vukicevic, A. M., Petrovic, M., Milosevic, P., Peulic, A., Jovanovic, K., & Novakovic, A. (2024). A systematic review of computer vision-based personal protective equipment compliance in industry practice: Advancements, challenges, and future directions. *Artificial Intelligence Review*, 57, 319. <https://doi.org/10.1007/s10462-024-10978-x>
- Wenkel, S., Acz, S., Trace, T., Müller, S., & Artz, D. (2021). Confidence score: The forgotten dimension of object detection performance evaluation. *Sensors*, 21(13), 4350. <https://doi.org/10.3390/s21134350>
- Yankson, I. K., Nsiah-Achampong, N. K., Okyere, P., Afukaar, F., Otupiri, E., Donkor, P., Mock, C., & Owusu-Dabo, E. (2021). On-site personal protective equipment signage and use by road construction workers in Ghana: A comparative study of foreign- and locally-owned companies. *BMC Public Health*, 21, 12376. <https://doi.org/10.1186/s12889-021-12376-2>
- Zaidi, S. S. A., Ansari, M. S., Aslam, A., Kanwal, N., Asghar, M., & Lee, B. (2024). A survey of modern deep learning based object detection models. *Digital Signal Processing*, 126, 103514. <https://doi.org/10.1016/j.dsp.2022.103514>