

## Analisis Algoritma Yolo V11n Untuk Deteksi Kepatuhan Penggunaan Alat Pelindung Diri Pada Live Cam

Shandy Satria Nugraha<sup>1\*</sup>, Teguh Iman Hermanto<sup>2</sup>, Muhammad Rafi Muttaqin<sup>3</sup>

<sup>1\*,2,3</sup>Teknik Informatika, Sekolah Tinggi Teknologi Wastukencana Purwakarta

\*Email: shandysatrian@gmail.com

### Abstract

*Occupational Health and Safety (OHS) implementation is a critical aspect of the industrial sector. However, manual monitoring of Personal Protective Equipment (PPE) compliance is prone to human error, and static surveillance cameras often suffer from blind spots. Utilizing portable live cams offers dynamic real-time monitoring flexibility but necessitates a computationally lightweight artificial intelligence architecture. This study aims to evaluate the YOLOv11n (Nano) algorithm's performance in detecting six PPE target classes (person, helmet, glasses, gloves, shoes, and reflective shirt) and integrating it into a web-based dashboard. The research applies the OSEMN framework, leveraging a private dataset of 346 images. The training process, conducted over 50 epochs with dynamic data augmentation, demonstrated exceptional precision. The proposed model achieved an overall mean Average Precision (mAP50) of 99.2%. The trained model was then converted into TensorFlow.js format to run client-side inference on a Next.js ecosystem. A spatial logic algorithm was employed to determine compliance status, and violations were automatically recorded into Firebase Firestore, safeguarded by an anti-spam filter. In conclusion, YOLOv11n is highly accurate, robust, and computationally efficient for developing a fully automated, real-time OHS audit system.*

*Keywords: computer vision, live cam, personal protective equipment, real-time, YOLOv11n*

### Abstrak

Penerapan Keselamatan dan Kesehatan Kerja (K3) merupakan aspek krusial di sektor industri. Meskipun demikian, pemantauan kepatuhan penggunaan Alat Pelindung Diri (APD) secara manual sangat rentan terhadap kelalaian manusia, sementara kamera pengawas statis kerap memiliki keterbatasan area pantau. Penggunaan kamera langsung (*live cam*) portabel menawarkan fleksibilitas pengawasan seketika, namun menuntut arsitektur kecerdasan buatan yang sangat efisien secara komputasi. Oleh karena itu, penelitian ini bertujuan untuk mengevaluasi kinerja algoritma YOLOv11n (Nano) dalam mengidentifikasi enam kelas target (pekerja, helm, kacamata, sarung tangan, sepatu, dan kemeja reflektor) serta mengintegrasikannya pada sebuah antarmuka web. Metodologi penelitian menerapkan kerangka kerja OSEMN menggunakan 346 data citra privat. Fase pelatihan dieksekusi selama 50 *epoch* dengan memanfaatkan augmentasi data dinamis guna mensimulasikan kondisi riil di lapangan. Hasil pengujian memvalidasi bahwa model sukses mencatatkan nilai rata-rata presisi (*mean Average Precision*/mAP50) sebesar 99,2%. Model prediksi selanjutnya dikonversi ke dalam format TensorFlow.js untuk dijalankan secara murni pada peramban klien (*client-side*). Sistem ini mengadopsi algoritma irisan spasial guna menentukan status kepatuhan, di mana insiden pelanggaran secara otomatis ditransmisikan ke dalam basis data awan Firebase Firestore yang dikendalikan oleh filter pencegah duplikasi data. Kesimpulannya, YOLOv11n terbukti sangat presisi, tangguh, dan berbobot ringan untuk mewujudkan instrumen audit K3 yang terotomatisasi secara komprehensif.

Kata kunci: Alat pelindung diri, *computer vision*, *live cam*, *real-time*, YOLOv11n

## 1. Pendahuluan

Penerapan Keselamatan dan Kesehatan Kerja (K3) adalah landasan fundamental dalam meminimalisasi risiko kecelakaan di sektor operasional industri [1]. Penggunaan Alat Pelindung Diri (APD) secara disiplin berfungsi sebagai benteng pertahanan terakhir untuk mencegah fatalitas cedera fisik [2]. Walaupun regulasi keselamatan telah diberlakukan secara ketat, mekanisme pengawasan konvensional yang mengandalkan observasi visual oleh petugas dinilai memiliki tingkat efisiensi yang rendah. Observasi manual tersebut memiliki keterbatasan bawaan, yakni sangat dipengaruhi oleh tingkat kelelahan pengawas (*human error*), bersifat subjektif, dan tidak memungkinkan pemantauan area secara persisten [3].

Menyikapi celah tersebut, pemanfaatan teknologi kecerdasan buatan, spesifiknya *Computer Vision* dan *Deep Learning*, hadir sebagai solusi modern untuk melakukan ekstraksi fitur kepatuhan pekerja secara otomatis [4]. Sayangnya, implementasi sistem cerdas ini secara umum masih bergantung pada instalasi kamera *Closed-Circuit Television* (CCTV) statis yang kurang adaptif terhadap fluktuasi pencahayaan [5]. Pengawasan berbasis titik tetap tersebut sering kali memicu kemunculan area tak terpantau (*blind spot*) akibat perubahan dinamis tata letak (*layout*) area *workshop*. Sebagai alternatif, instrumen kamera langsung (*live cam*) portabel, seperti perangkat seluler yang dioperasikan oleh pengawas, memberikan fleksibilitas mobilitas yang tinggi untuk mendokumentasikan sudut-sudut proyek secara seketika (*real-time*) [6].

Meskipun demikian, pemrosesan aliran video dinamis dari *live cam* mensyaratkan arsitektur algoritma yang sangat ringan agar tidak memicu kelebihan beban komputasi (*overhead*) [7]. Tinjauan terhadap beberapa studi terdahulu memperlihatkan beragam tantangan teknis. Implementasi arsitektur berbasis segmentasi, seperti Mask R-CNN, terbukti menghasilkan akurasi tinggi namun memiliki latensi waktu komputasi yang sangat lambat, menjadikannya tidak aplikatif untuk


aliran video langsung [8]. Studi lain yang mengevaluasi algoritma *You Only Look Once* (YOLO) generasi sebelumnya (YOLOv4 dan YOLOv5) mengonfirmasi bahwa model tersebut sering kali mengalami kegagalan ekstraksi dan penurunan tingkat kepekaan (*recall*) saat memindai objek APD berskala kecil dari jarak jauh, misalnya sepatu keselamatan dan kaca pelindung [9], [10]. Selain itu, sebagian besar purwarupa sistem deteksi saat ini hanya mendemonstrasikan visualisasi *bounding box* di layar lokal, tanpa didukung mekanisme rekayasa perangkat lunak untuk mengotomatisasi pelaporan log pelanggaran ke dalam basis data [11].

Untuk menjembatani celah penelitian (*research gap*) tersebut, studi ini mengusulkan penggunaan algoritma deteksi objek termutakhir, yaitu YOLOv11 varian Nano (YOLOv11n). Arsitektur ini dipilih karena kapabilitas ekstraksi fiturnya yang telah dioptimasi untuk objek kecil sekaligus memiliki parameter komputasi yang ekstrim ringan [12]. Tujuan utama dari penelitian ini adalah mengevaluasi tingkat presisi komputasi YOLOv11n dalam mendeteksi enam atribut K3, serta merancang integrasi model tersebut ke dalam purwarupa aplikasi web Next.js. Sistem yang diusulkan ini diperkaya dengan algoritma filter spasial guna mengeksekusi pencatatan jejak audit (*audit trail log*) pelanggaran K3 secara otomatis ke dalam infrastruktur basis data awan (*cloud database*) Firebase Firestore, sehingga mampu menciptakan instrumen pengawasan yang efisien, transparan, dan proaktif.

## 2. Metoda Penelitian

Struktur pelaksanaan penelitian ini dikembangkan dengan mengadopsi kerangka kerja operasional OSEM (Obtain, Scrub, Explore, Model, iNterpret) [13]. Metodologi siklus hidup data ini diaplikasikan guna memastikan setiap fase pengolahan komputasi bermula dari ekstraksi data mentah lapangan hingga peluncuran model inferensi pada ekosistem klien berjalan secara sistematis dan dapat direproduksi. Rangkaian sistematis dari

kerangka penelitian ini direpresentasikan secara visual pada Gambar 1.



Gambar 1. Tahapan Penelitian

## 2.1. Prapemrosesan dan Anotasi Data

Metoda Tahap inisiasi difokuskan pada akuisisi *dataset* primer yang direkam secara langsung dari lingkungan operasional industri PT Alat Bumi Permai. Total 346 citra visual beresolusi tinggi diekstraksi untuk merekam variabilitas penggunaan Alat Pelindung Diri (APD) pada kondisi *workshop* yang sebenarnya. Citra yang diakuisisi memuat kompleksitas visual tingkat tinggi, mencakup anomali pencahayaan, keberadaan bayangan, serta berbagai sudut tangkapan (*camera angle*).

Guna mencegah terjadinya galat komputasi akibat inkonsistensi nama *file*, proses standardisasi identitas gambar (*batch renaming*) dieksekusi menggunakan skrip otomasi berbasis Node.js. Tahapan krusial berikutnya adalah pemberian label kebenaran dasar (*ground truth labeling*) secara manual terawasi (*supervised*) melalui anjungan Label Studio. Penarikan garis batas spasial (*bounding box*) diterapkan secara presisi pada enam kelas entitas dengan mematuhi kaidah geometris yang dirinci pada Tabel 1.

Tabel 1. Kriteria Spasial Penarikan Bounding Box

| Kelas Target            | Parameter Anotasi Geometris                                                                                                                                                                 |
|-------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <i>Person</i>           | Area <i>bounding box</i> ditarik secara komprehensif membingkai keseluruhan anatomi pekerja yang terlihat, membentang vertikal dari ekstremitas atas hingga batas ekstremitas bawah.        |
| <i>Safety-Helmet</i>    | Garis batas ditarik merapat pada kontur terluar pelindung kepala. Pada kasus oklusi (tertutup objek lain), batas proyeksional diestimasi berdasarkan rasio visual yang paling proporsional. |
| <i>Safety-Glasses</i>   | Dianotasi secara mendetail dan spesifik, mengelilingi struktur kacamata keselamatan yang menempel pada area fasial pekerja.                                                                 |
| <i>Safety-Gloves</i>    | Diisolasi murni pada tingkat instans ( <i>instance level</i> ); setiap unit sarung tangan dibingkai ke dalam kotak spasial yang terpisah secara independen.                                 |
| <i>Safety-Shoes</i>     | Dianotasi pada tingkat instans. Apabila sepasang sepatu mengalami perpotongan visual, dua kotak berbeda tetap ditarik meskipun saling bertumpukan ( <i>overlapping</i> ).                   |
| <i>Reflective-Shirt</i> | Fokus area penandaan dibatasi pada material pakaian seragam beraksen reflektor yang menutupi bagian <i>torso</i> (badan atas) pekerja.                                                      |

Data anotasional yang terbentuk kemudian diekspor ke dalam ekstensi fail format YOLO (.txt). Validasi akhir prapemrosesan (*sanity check*) dijalankan menggunakan bahasa pemrograman Python untuk membersihkan karakter asing (*hash*) pada nama label dan menyinkronkan seluruh pasangan fail citra dan teks.

## 2.2. Pemodelan Arsitektur

Guna mereduksi bias pelatihan, *dataset* yang telah tervalidasi dipartisi secara acak dengan rasio 80% untuk set pelatihan (*Training*

Set) dan 20% untuk set pengujian (*Validation Set*). Seluruh eksperimen komputasi dieksekusi di atas infrastruktur awan Google Colaboratory, memanfaatkan akselerator perangkat keras NVIDIA Tesla T4 GPU (15GB VRAM) untuk mengakselerasi komputasi propagasi matriks secara optimal.

Riset ini mengimplementasikan algoritma *Deep Learning* YOLOv11 varian Nano (YOLOv11n). Arsitektur ini diunggulkan karena efisiensi parameter komputasinya yang sangat minim (7,6 GFLOPs), sehingga kompatibel untuk perangkat pemrosesan terbatas (*edge computing*). Jaringan saraf tiruan dilatih memanfaatkan teknik *Transfer Learning* selama 50 siklus iterasi (*epoch*) dengan ukuran tumpukan data (*batch size*) sebesar 16. Resolusi spasial gambar (*imgsz*) diskalakan menjadi 832×832 piksel untuk memelihara detail ekstraksi pada objek berskala minor.

Ketahanan model (*robustness*) ditingkatkan melalui skenario augmentasi data adaptif, yang mencakup transformasi spasial (translasi 0.2, skala jarak 0.5, distorsi kemiringan 10°), rekayasa ruang warna HSV (saturasi 0.5 dan intensitas 0.5), serta penggabungan *mosaic* berskala penuh.

### 2.3. Skenario Evaluasi dan Logika Sistem

Kualitas prediksi klasifikasi dari model yang dilatih dievaluasi secara statistik menggunakan parameter Matriks Kebingungan (*Confusion Matrix*) [14]. Matriks ini mengekstraksi empat variabel performa: *True Positive (TP)*, *False Positive (FP)*, *True Negative (TN)*, dan *False Negative (FN)*. Integritas lokalisasi objek diverifikasi melalui rumusan *Precision (P)* pada Persamaan (1) dan sensitivitas *Recall (R)* pada Persamaan (2).

$$P = \frac{TP}{TP + FP} \quad (1)$$

$$R = \frac{TP}{TP + FN} \quad (2)$$

Komprehensivitas performa algoritma untuk seluruh kelas kemudian diukur

menggunakan metrik *mean Average Precision (mAP)*, yang secara matematis dijabarkan pada Persamaan (3).

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (3)$$

di mana  $N$  mewakili jumlah entitas kelas yang dideteksi ( $N = 6$ ), dan  $AP_i$  merupakan luas integrasi di bawah kurva *Precision-Recall* untuk setiap kelas  $i$ .

Pada fasa simulasi, model bobot biner dikonversi ke format TensorFlow.js untuk diintegrasikan pada ekosistem Next.js. Filter *Non-Maximum Suppression (NMS)* diimplementasikan untuk mengeliminasi penumpukan kotak deteksi ganda. Guna mengotomatisasi perekaman jejak audit ke dalam basis data Firebase tanpa memicu lonjakan duplikasi data dari tangkapan *frame* yang persisten, dirumuskan sebuah logika filter spasial *anti-spam*. Dokumen insiden baru hanya akan ditransmisikan apabila pergeseran absolut titik tengah horizontal pekerja ( $\Delta X_{center}$ ) telah melampaui ambang batas toleransi pada Persamaan (4).

$$|X_{center(t)} - X_{center(t-1)}| > 150 \text{ px} \quad (4)$$

## 3. Hasil Penelitian

Bagian ini menguraikan secara komprehensif hasil pengolahan *dataset*, evaluasi metrik algoritma kecerdasan buatan, hingga analisis efektivitas implementasi model pada antarmuka aplikasi pemantauan. Keseluruhan tahapan pengujian ini dieksekusi guna menjawab urgensi pengawasan Alat Pelindung Diri (APD) secara *real-time* di lingkungan operasional industri.

### 3.1. Analisis Distribusi Dataset

Kualitas luaran dari model *Deep Learning* sangat bergantung pada karakteristik data yang diumpankan. Pada penelitian ini, sebanyak 346 citra visual mentah dianalisis dan dikategorikan berdasarkan parameter *Standard Operating Procedure (SOP)* Keselamatan dan Kesehatan

Kerja (K3) perusahaan. Pemetaan kuantitas fail gambar mentah tersebut diuraikan pada Tabel 2.

Tabel 2. Distribusi Kategori Citra Mentah dan Status SOP

| ID Kelas | Kategori Kelas Target | Status Pemenuhan SOP |
|----------|-----------------------|----------------------|
| 0        | Person                | Subjek Utama         |
| 1        | Safety-Helmet         | Wajib                |
| 2        | Safety-Glasses        | Opsional             |
| 3        | Safety-Gloves         | Opsional             |
| 4        | Safety-Shoes          | Wajib                |
| 5        | Reflective-Shirt      | Wajib                |

Setelah citra mentah tersebut melalui fase anotasi spasial (*bounding box*), dilakukan proses ekstraksi informasi kuantitatif untuk melihat sebaran instans secara lebih spesifik pada *dataset* pelatihan. Hasil ekstraksi distribusi instans ini sangat krusial untuk mengidentifikasi potensi ketidakseimbangan kelas (*class imbalance*). Rincian kuantitas objek pasca-anotasi direpresentasikan pada Tabel 3.

Tabel 3. Distribusi Kuantitas Instans Objek Pelatihan

| No.          | Kelas Target        | Jumlah Instans ( <i>Bounding Box</i> ) |
|--------------|---------------------|----------------------------------------|
| 1            | Person              | 81                                     |
| 2            | Safety-Helmet       | 113                                    |
| 3            | Safety-Glasses      | 72                                     |
| 4            | Safety-Gloves       | 140                                    |
| 5            | Safety-Shoes        | 135                                    |
| 6            | Reflective-Shirt    | 81                                     |
| <b>Total</b> | Keseluruhan Instans | <b>622</b>                             |

Merujuk pada Tabel 3, objek pelindung anggota tubuh ganda, yakni *Safety-Gloves* (140 instans) dan *Safety-Shoes* (135 instans), mendominasi kuantitas *dataset*. Proporsi ini merepresentasikan kewajaran lingkungan lapangan, mengingat sepasang sarung tangan maupun sepatu dihitung sebagai dua objek identifikasi yang terpisah dalam satu subjek pekerja.

Tabel 4. Kelas Target pada Citra Visual Mentah

| No.          | Kelas Target      | Jumlah Citra (Images) |
|--------------|-------------------|-----------------------|
| 1            | Person            | 81                    |
| 2            | Safety-Helmet     | 113                   |
| 3            | Safety-Glasses    | 72                    |
| 4            | Safety-Gloves     | 88                    |
| 5            | Safety-Shoes      | 92                    |
| 6            | Reflective-Shirt  | 81                    |
| <b>Total</b> | Keseluruhan Citra | <b>346</b>            |

Berdasarkan Tabel 4, dari total 346 citra mentah yang diakuisisi di lapangan, kelas *Safety-Helmet* mendominasi kemunculan pada 113 citra (32,7%). Terdapat perbedaan kuantitas antara jumlah instans *bounding box* (Tabel 3) dan jumlah citra fisik (Tabel 4). Hal ini disebabkan oleh adanya beberapa citra yang memuat objek ganda (*multi-instance*), seperti sepasang sarung tangan (*Safety-Gloves*) atau sepasang sepatu (*Safety-Shoes*) yang terdeteksi sebagai dua instans terpisah namun berada dalam satu bingkai citra yang sama. Pemetaan distribusi ini memastikan variabilitas sampel data terwakili secara proporsional untuk mencegah bias saat pelatihan model.


### 3.2. Evaluasi Kinerja Algoritma YOLOv11n

Kemampuan arsitektur YOLOv11n dalam melakukan lokalisasi dan klasifikasi dievaluasi secara kuantitatif menggunakan set validasi. Hasil ekstraksi metrik membuktikan bahwa model yang diusulkan memiliki tingkat presisi dan sensitivitas yang sangat superior. Rangkuman performa prediksi untuk keenam kelas target disajikan pada Tabel 5.

Tabel 5. Hasil Evaluasi Metrik Performa YOLOv11n

| Kelas Target       | Precision (P) | Recall (R)   |
|--------------------|---------------|--------------|
| <b>Keseluruhan</b> | <b>0.970</b>  | <b>1.000</b> |
| Person             | 0.983         | 1.000        |
| Safety-Helmet      | 0.980         | 1.000        |
| Safety-Glasses     | 0.952         | 1.000        |
| Safety-Gloves      | 0.965         | 1.000        |
| Safety-Shoes       | 0.954         | 1.000        |
| Reflective-Shirt   | 0.987         | 1.000        |

Berdasarkan Tabel 5, secara kumulatif model sukses menyentuh angka *mean Average Precision* (mAP50) sebesar 0.992 atau 99,2%. Untuk memvalidasi akurasi spesifik terhadap kesalahan tebakan silang antarkelas, Matriks Kebingungan (*Confusion Matrix*) turut dianalisis sebagaimana divisualisasikan pada Gambar 2.



Gambar 2. Visualisasi matriks kebingungan

Garis diagonal utama pada Gambar 2 merepresentasikan rasio tebakan benar (*True Positive*) yang sangat dominan. Model mencatatkan pengenalan mutlak secara sempurna (100%) pada kelas *Person*, *Safety-Helmet*, dan *Reflective-Shirt*. Lebih lanjut, kendala kegagalan deteksi objek minor (*small object detection*) yang acap kali menimpa algoritma pendahulu sukses diatasi; dibuktikan dengan akurasi klasifikasi matriks sebesar 96% pada *Safety-Glasses*, 93% pada *Safety-Gloves*, dan 92% pada *Safety-Shoes*. Kesalahan deteksi terhadap latar belakang (*False Positive Background*) tercatat sangat minim, membuktikan ketangguhan model dalam menghindari halusinasi fitur di lingkungan yang bising (*noisy*).

### 3.3. Implementasi Inferensi dan Otomasi Log Basis Data

Guna menekan latensi jaringan, model YOLOv11n dikompilasi ke format TensorFlow.js (9 MB) untuk memfasilitasi

eksekusi murni di sisi peramban klien (*browser client-side*) melalui akselerasi WebGL. Sistem juga mengimplementasikan algoritma *Non-Maximum Suppression* (NMS) untuk memfilter kotak deteksi ganda. Visualisasi antarmuka dari purwarupa aplikasi *web dashboard* Next.js saat memproses aliran *live cam* disajikan pada Gambar 3.



Gambar 2. Antarmuka Pemindai APD secara Real-time

Sistem akan memberikan umpan balik berupa kotak hijau ("Patuh") jika seluruh APD wajib terpenuhi, dan kotak merah ("Pelanggaran") jika terdapat defisiensi. Berkat evaluasi logika irisan spasial, sistem diintegrasikan untuk mentransmisikan jejak audit (*audit trail*) secara otomatis ke dalam basis data awan (*cloud database*) Firebase Firestore. Skema struktur data (*payload*) yang direkam diuraikan pada Tabel 5.

Tabel 6. Skema Penyimpanan Dokumen Log pada Firestore

| Nama Field | Tipe Data | Keterangan Transmisi Data |
|------------|-----------|---------------------------|
|------------|-----------|---------------------------|

|                  |                        |                                                                                           |
|------------------|------------------------|-------------------------------------------------------------------------------------------|
| waktu_kejadian   | <i>Timestamp</i>       | Waktu pasti komputasi peladen saat insiden terdeteksi.                                    |
| nama_device      | <i>String</i>          | Informasi periferal kamera (misal: <i>Android Device</i> atau PC).                        |
| status           | <i>String</i>          | Representasi akhir kepatuhan ("Patuh" / "Tidak Patuh").                                   |
| missing_apd      | <i>Array of String</i> | Komponen APD wajib mutlak yang gagal teridentifikasi.                                     |
| terpakai_apd     | <i>Array of String</i> | Seluruh komponen APD yang berhasil terekstraksi oleh model.                               |
| opsional_dipakai | <i>Array of String</i> | Komponen APD kondisional (kacamata/sarung tangan) yang dipakai sebagai sikap K3 proaktif. |

Transmisi *payload* pada Tabel 5 dikendalikan sepenuhnya oleh algoritma filter pembatas spasial 150 piksel yang diusulkan sebelumnya. Pendekatan ini terbukti berhasil memitigasi tumpukan data ganda (*spamming log*), menjadikan sistem ini instrumen audit K3 yang tangguh, proaktif, dan terstruktur.

#### 4. Kesimpulan

Penelitian ini menyimpulkan bahwa arsitektur YOLOv11 varian Nano (YOLOv11n) terbukti sangat andal dan komputasional efisien untuk diimplementasikan pada sistem pengawasan Keselamatan dan Kesehatan Kerja (K3) berbasis aliran video dinamis dari kamera portabel (*live cam*). Berdasarkan hasil pengujian kuantitatif, model kecerdasan buatan yang diusulkan mendemonstrasikan tingkat presisi lokalisasi spasial yang superior, ditandai dengan perolehan skor *mean Average Precision* (mAP50) keseluruhan sebesar 99,2%. Penerapan skenario augmentasi data adaptif pada fasa pelatihan berhasil mengatasi defisiensi yang lazim ditemui pada algoritma terdahulu, memastikan model tetap tajam saat

mengekstraksi fitur minor, seperti kacamata dan sepatu pelindung, di tengah guncangan distorsi visual kamera genggam. Lebih lanjut, kompilasi model ke dalam format TensorFlow.js yang dieksekusi secara murni di sisi peramban klien (*client-side inference*), dikombinasikan dengan algoritma filter *Non-Maximum Suppression* (NMS) dan logika ambang batas spasial 150 piksel, sukses menekan beban komputasi peladen secara masif. Integrasi purwarupa *web dashboard* Next.js dengan basis data awan Firebase Firestore terbukti presisi dalam mentransmisikan jejak audit (*audit trail log*) pelanggaran K3 secara *real-time* dan bebas duplikasi *spam*, menjadikan arsitektur ini sebagai instrumen audit pengawasan yang proaktif, tangguh, dan terotomatisasi penuh.

#### 5. Saran

Sebagai arah pengembangan kelanjutan riset di masa mendatang, sangat disarankan adanya implementasi komputasi tepi (*edge computing*) dengan menanamkan bobot model kecerdasan buatan secara langsung ke dalam perangkat keras mikrokontroler mandiri, seperti Raspberry Pi atau *board* komputasi NVIDIA Jetson. Pendekatan arsitektur perangkat keras independen ini diantisipasi mampu mengeliminasi ketergantungan proses inferensi terhadap spesifikasi peramban web pengguna dan meningkatkan stabilitas *frame rate*. Selain itu, ekspansi keragaman *dataset* pelatih sangat direkomendasikan, secara khusus dengan menginjeksi skenario pencahayaan operasional yang ekstrem (*low-light environment*) serta skenario kepadatan visibilitas pekerja (*crowded environment*). Penambahan sampel data minoritas tersebut dinilai esensial guna memaksimalkan ketahanan (*robustness*) daya deteksi algoritma pada kondisi operasional lapangan riil yang memiliki tingkat fluktuasi visual tinggi.

#### 6. Daftar Pustaka

- [1] V. Saxena, "Evolution of International Occupational Health and Safety

- Management Systems,” *BARC newsletter*, 2024.
- [2] M. I. B. Ahmed *et al.*, “Personal Protective Equipment Detection: A Deep-Learning-Based Sustainable Approach,” *Sustainability (Switzerland)*, vol. 15, no. 18, 2023, doi: 10.3390/su151813990.
- [3] J. H. Lo, L. K. Lin, and C. C. Hung, “Real-Time Personal Protective Equipment Compliance Detection Based on Deep Learning Algorithm,” *Sustainability (Switzerland)*, vol. 15, no. 1, 2023, doi: 10.3390/su15010391.
- [4] A. J. Moshayedi, A. S. Roy, A. Taravet, L. Liao, J. Wu, and M. Gheisari, “A secure traffic police remote sensing approach via a deep learning-based low-altitude vehicle speed detector through uavs in smart cities: Algorithm, implementation and evaluation,” *Future transportation*, vol. 3, no. 1, pp. 189–209, 2023.
- [5] X. Suo, W. Tang, and Z. Li, “Motion Capture Technology in Sports Scenarios: A Survey,” 2024. doi: 10.3390/s24092947.
- [6] Y. Tao, B. Li, P. Li, J. Qian, and L. Qi, “Improved Lightweight YOLOv11 Algorithm for Real-Time Forest Fire Detection,” *Electronics (Switzerland)*, vol. 14, no. 8, 2025, doi: 10.3390/electronics14081508.
- [7] J. Ordick, G. Wibowo, A. Fahmi, I. Kurniawan, and E. Haq, “YOLOv11-Based Automated PPE Detection System for Workplace Safety Monitoring in Electric Power Distribution Operations,” *Journal of Information Systems and Informatics*, vol. 7, no. 4, Dec. 2025, doi: 10.63158/journalisi.v7i4.1379.
- [8] M. E. Laily, F. N. Fajri, and G. Q. O. Pratamasunu, “Deteksi Penggunaan Alat Pelindung Diri (APD) Untuk Keselamatan dan Kesehatan Kerja Menggunakan Metode Mask Region Convolutional Neural Network (Mask R-CNN),” *Jurnal Komputer Terapan*, vol. 8, no. 2, 2022, doi: 10.35143/jkt.v8i2.5732.
- [9] M. Sambetbayeva *et al.*, “A Multi-Level Annotation Model for Fake News Detection: Implementing Kazakh-Russian Corpus via Label Studio,” *Big Data and Cognitive Computing*, vol. 9, no. 8, p. 215, 2025.
- [10] International Labour Organization, “Issue Paper: OSH Statistics - Supporting the review and update of the international OSH statistical standards at the 22nd ICLS in 2028.,” Geneva, Oct. 2025. Accessed: Mar. 15, 2026. [Online]. Available: [https://www.google.com/url?sa=t&source=web&rct=j&opi=89978449&url=https://www.ilo.org/sites/default/files/2025-11/TWG\\_OSH\\_Issue\\_Paper\\_2025\\_10\\_22.pdf&ved=2ahUKEwjOyMCE96CTAxUTxzgGHQ2WLwQQFnoECBgQAQ&usg=AOvVaw2ozrik-5V7DCiLkihW\\_8e-](https://www.google.com/url?sa=t&source=web&rct=j&opi=89978449&url=https://www.ilo.org/sites/default/files/2025-11/TWG_OSH_Issue_Paper_2025_10_22.pdf&ved=2ahUKEwjOyMCE96CTAxUTxzgGHQ2WLwQQFnoECBgQAQ&usg=AOvVaw2ozrik-5V7DCiLkihW_8e-)
- [11] M. M. Taye, “Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions,” 2023. doi: 10.3390/computers12050091.
- [12] J. Zhao, S. Miao, R. Kang, L. Cao, L. Zhang, and Y. Ren, “Insulator defect detection algorithm based on improved YOLOv11n,” *Sensors*, vol. 25, no. 5, p. 1327, 2025.
- [13] K. Shameti and B. Cico, “Comparison of Methodological Approaches: CRISP-DM vs OSEMN Methodology Using Linear Regression and Statistical Analysis,” in *Balkan Conference in Informatics*, Springer, 2024, pp. 47–60.
- [14] A. Hayat and F. Morgado-Dias, “Deep learning-based automatic safety helmet detection system for construction safety,” *Applied Sciences*, vol. 12, no. 16, p. 8268, 2022.