

## **BAB II**

### **KAJIAN LITERATUR**

#### **2.1 Keselamatan dan Kesehatan Kerja (K3)**

Keselamatan dan Kesehatan Kerja (K3) merupakan aspek penting dalam kegiatan industri, terutama pada sektor konstruksi yang memiliki tingkat risiko kecelakaan kerja yang tinggi. Tujuan utama K3 adalah melindungi tenaga kerja dari potensi bahaya di tempat kerja agar tercipta lingkungan kerja yang aman, efisien, dan produktif. Implementasi K3 tidak hanya berfokus pada pencegahan kecelakaan, tetapi juga pada pembentukan budaya keselamatan yang mendorong pekerja untuk berperilaku aman selama bekerja. Menurut Ariyanto [1], kesadaran pekerja dalam menerapkan K3 sangat dipengaruhi oleh tingkat pengetahuan dan sikap mereka terhadap keselamatan kerja. Penelitian tersebut menunjukkan adanya hubungan signifikan antara pengetahuan dan kepatuhan pekerja dalam menggunakan Alat Pelindung Diri (APD). Artinya, semakin tinggi pemahaman pekerja terhadap K3, maka semakin tinggi pula tingkat kepatuhannya terhadap peraturan keselamatan. Oleh karena itu, penerapan K3 tidak dapat dipisahkan dari pembiasaan perilaku disiplin dalam menggunakan APD di setiap aktivitas kerja.

#### **2.2 Alat Pelindung Diri (APD)**

Alat Pelindung Diri (APD) merupakan perlengkapan wajib yang digunakan oleh pekerja untuk melindungi diri dari potensi bahaya di lingkungan kerja. Jenis APD meliputi helm keselamatan, rompi reflektif, sarung tangan, sepatu pelindung, masker, dan kacamata pelindung. Setiap jenis APD dirancang untuk memberikan perlindungan pada bagian tubuh tertentu terhadap bahaya seperti benturan, jatuhnya benda, percikan bahan kimia, maupun paparan debu. Namun, kepatuhan pekerja dalam menggunakan APD masih menjadi permasalahan yang sering terjadi di lapangan. Banyak pekerja yang tidak menggunakan APD dengan alasan ketidaknyamanan atau menganggap area kerja mereka aman. Ariyanto [1] menjelaskan bahwa faktor pengetahuan, sikap, dan pengawasan dari pihak perusahaan berperan penting dalam membentuk perilaku pekerja terhadap penggunaan APD. Kurangnya pengawasan yang efektif menjadi salah satu penyebab masih rendahnya tingkat kepatuhan, sehingga diperlukan sistem yang dapat memantau penggunaan APD secara lebih konsisten dan otomatis.

### **2.3 Sistem Pengawasan Keselamatan Kerja oleh Koordinator Lapangan**

Pengawasan keselamatan kerja merupakan bagian penting dalam penerapan sistem Keselamatan dan Kesehatan Kerja (K3) di lingkungan industri. Tujuan utama pengawasan ini adalah memastikan bahwa seluruh aktivitas kerja dilakukan sesuai dengan prosedur keselamatan yang telah ditetapkan perusahaan, termasuk kepatuhan pekerja dalam menggunakan Alat Pelindung Diri (APD). Secara umum, proses pengawasan dilakukan melalui inspeksi lapangan, pemantauan perilaku pekerja, serta evaluasi terhadap kondisi lingkungan kerja yang berpotensi menimbulkan bahaya. Kegiatan ini biasanya dilakukan oleh pihak yang ditunjuk oleh perusahaan untuk bertanggung jawab terhadap penerapan K3, seperti petugas keselamatan kerja, koordinator lapangan, atau tim manajemen proyek. Selain melakukan pemantauan langsung, pengawas juga bertugas mencatat pelanggaran, memberikan peringatan kepada pekerja, serta menyusun laporan keselamatan kerja sebagai bahan evaluasi perusahaan.

Dalam praktiknya, metode pengawasan yang dilakukan secara manual melalui observasi langsung masih memiliki beberapa keterbatasan, seperti cakupan pengawasan yang terbatas, ketergantungan pada ketelitian individu, serta kesulitan dalam memantau seluruh area kerja secara bersamaan, terutama pada lingkungan kerja yang luas dan melibatkan banyak pekerja. Kondisi tersebut dapat menyebabkan pelanggaran penggunaan APD tidak selalu terdeteksi secara langsung. Oleh karena itu, diperlukan pendekatan yang lebih efektif untuk mendukung proses pengawasan keselamatan kerja, salah satunya melalui pemanfaatan teknologi berbasis Artificial Intelligence dan Computer Vision yang mampu melakukan pemantauan secara otomatis melalui kamera pengawas. Dengan sistem monitoring otomatis, proses pengawasan dapat dilakukan secara lebih konsisten, efisien, serta mampu memberikan informasi mengenai tingkat kepatuhan pekerja terhadap penggunaan APD.

### **2.4 Black Box Testing**

Black Box Testing merupakan metode pengujian perangkat lunak yang berfokus pada pengujian fungsionalitas sistem tanpa memperhatikan struktur internal atau kode program. Pengujian ini dilakukan dengan memberikan input tertentu dan mengamati output yang dihasilkan untuk memastikan kesesuaian dengan spesifikasi sistem [8].

Metode ini digunakan untuk mengidentifikasi kesalahan pada fungsi sistem, seperti kesalahan pada proses input, pengolahan data, maupun output yang dihasilkan. Selain itu,

Black Box Testing juga dapat digunakan untuk menguji antarmuka sistem agar sesuai dengan kebutuhan pengguna dan tidak menimbulkan kesalahan saat digunakan.

Penggunaan Black Box Testing sangat sesuai untuk sistem berbasis aplikasi mobile karena pengujian difokuskan pada fungsi yang langsung digunakan oleh pengguna. Dengan metode ini, sistem dapat divalidasi dari sisi pengguna tanpa perlu memahami struktur internal sistem, sehingga hasil pengujian lebih relevan dengan kondisi penggunaan nyata.

Pengujian ini bertujuan memastikan bahwa setiap fitur bekerja sesuai kebutuhan. Tahapan Black Box Testing secara umum meliputi:

1. Menentukan fitur yang diuji.
2. Menyusun skenario input dan output yang diharapkan.
3. Menjalankan pengujian.
4. Membandingkan hasil aktual dengan hasil yang diharapkan.
5. Menentukan status hasil pengujian.

Dalam penelitian ini, Black Box Testing digunakan untuk menguji fitur-fitur utama aplikasi, seperti tampilan hasil deteksi, pencatatan pelanggaran, dan ekspor laporan.

## 2.5 System Usability Scale (SUS)

System Usability Scale (SUS) merupakan metode pengujian usability yang digunakan untuk mengukur tingkat kemudahan penggunaan suatu sistem berdasarkan persepsi pengguna. SUS terdiri dari 10 pernyataan yang dinilai menggunakan skala Likert dan menghasilkan skor dalam rentang 0 hingga 100 [9].

Metode ini dikenal sebagai alat ukur yang valid dan reliabel serta dapat digunakan dengan jumlah responden yang relatif kecil. SUS banyak digunakan dalam evaluasi sistem karena sederhana, cepat, dan mampu memberikan gambaran umum mengenai kualitas usability suatu aplikasi. Perhitungan skor SUS dilakukan dengan Langkah :

1. Untuk item bernomor ganjil:

$$X_i = S_i - 1 \dots\dots\dots (2.1)$$

2. Untuk item bernomor genap:

$$X_i = 5 - S_i \dots\dots\dots (2.2)$$

3. Jumlah seluruh skor kontribusi dikalikan 2,5:

$$SUS\ Score = \left( \sum_{i=1}^{10} X_i \right) \times 2.5 \dots\dots\dots (2.3)$$

Nilai SUS berada pada rentang 0–100. Semakin tinggi nilai SUS, maka semakin baik tingkat usability sistem. Tahapan pengujian usability menggunakan metode System Usability Scale (SUS) dalam penelitian ini dilakukan melalui beberapa langkah sebagai berikut:

1. Penentuan Responden

Responden dalam pengujian ini adalah pengguna sistem, yaitu koordinator lapangan atau pihak yang terkait dengan proses monitoring penggunaan APD. Jumlah responden disesuaikan dengan kebutuhan penelitian.

2. Penyusunan Kuesioner SUS

Kuesioner yang digunakan terdiri dari 10 pernyataan standar SUS yang mencakup aspek kemudahan penggunaan, serta kepuasan pengguna terhadap sistem.

3. Pelaksanaan Pengujian

Responden diminta untuk menggunakan aplikasi monitoring APD yang telah dikembangkan, kemudian mengisi kuesioner SUS berdasarkan pengalaman penggunaan sistem.

4. Pengumpulan Data Kuesioner

Data hasil pengisian kuesioner dikumpulkan dalam bentuk skor Likert dengan rentang nilai 1 (sangat tidak setuju) hingga 5 (sangat setuju).

5. Perhitungan Skor SUS

Setiap jawaban responden dihitung menggunakan rumus SUS, di mana nilai untuk item ganjil dan genap diolah sesuai ketentuan, kemudian dijumlahkan dan dikalikan dengan 2,5 untuk mendapatkan skor akhir.

6. Interpretasi Hasil

Skor SUS yang diperoleh kemudian dianalisis untuk menentukan tingkat usability sistem. Nilai SUS yang tinggi menunjukkan bahwa sistem memiliki tingkat kemudahan penggunaan yang baik dan dapat diterima oleh pengguna.

## 2.6 Confusion Matrix

Confusion Matrix merupakan metode evaluasi yang digunakan untuk mengukur performa model klasifikasi dengan membandingkan hasil prediksi model terhadap kondisi sebenarnya. Metode ini umum digunakan dalam machine learning untuk mengevaluasi kinerja model, baik pada klasifikasi biner maupun multikelas. Confusion matrix memberikan

gambaran yang lebih detail dibandingkan hanya menggunakan nilai akurasi, karena mampu menunjukkan distribusi kesalahan klasifikasi yang terjadi[10].

Confusion matrix terdiri dari empat komponen utama, yaitu True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Berdasarkan keempat komponen tersebut, berbagai metrik evaluasi dapat dihitung, seperti accuracy, precision, dan recall. Pada penelitian klasifikasi citra menggunakan model deep learning, confusion matrix digunakan untuk mengevaluasi performa model berdasarkan hasil prediksi terhadap data sebenarnya sehingga diperoleh metrik evaluasi yang menggambarkan kemampuan model dalam melakukan klasifikasi [10].

Selain digunakan pada klasifikasi biner, confusion matrix juga dapat diterapkan pada klasifikasi multikelas untuk menghitung nilai accuracy, precision, dan recall pada setiap kelas objek. Dalam penelitian ini, performa model deteksi APD berbasis YOLOv8 dievaluasi menggunakan metrik accuracy, precision, recall, dan mean Average Precision (mAP). Nilai accuracy, precision, dan recall diperoleh berdasarkan confusion matrix, sedangkan nilai mAP dihitung berdasarkan kurva Precision-Recall.

Berdasarkan nilai True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN), maka kinerja model dapat dihitung menggunakan beberapa metrik evaluasi. Perhitungan metrik tersebut dirumuskan sebagai berikut:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} * 100 \dots\dots\dots (2.4)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} * 100 \dots\dots\dots (2.5)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} * 100 \dots\dots\dots (2.6)$$

Keterangan :

TP : True Positive

TN : True Negative

FP : False Positive

FN : False Negative

Selain menggunakan metrik accuracy, precision, dan recall, evaluasi performa model deteksi objek juga dilakukan menggunakan Average Precision (AP) dan mean Average Precision (mAP). Average Precision merupakan luas area di bawah kurva Precision-Recall pada setiap kelas objek, sedangkan mean Average Precision merupakan rata-rata nilai AP

dari seluruh kelas objek yang dideteksi. Nilai mAP digunakan untuk mengukur kemampuan model dalam mendeteksi objek secara keseluruhan, di mana semakin tinggi nilai mAP menunjukkan semakin baik performa model dalam melakukan deteksi objek.[11]

$$mAP = \frac{\sum_{i=1}^n AP_i}{n} \dots\dots\dots (2.7)$$

Keterangan :

$AP_i$  = Average Precision pada setiap kelas


$n$  = jumlah kelas objek

$mAP$  = mean Average Precision

## 2.7 Algoritma You Only Look Once (YOLO)

YOLO (You Only Look Once) merupakan algoritma deteksi objek yang sangat populer karena kemampuannya melakukan deteksi secara cepat dan akurat dalam satu kali proses inferensi. Berbeda dengan metode konvensional seperti R-CNN yang membutuhkan banyak tahapan, YOLO langsung memprediksi lokasi dan kelas objek dari seluruh gambar sekaligus. Djaohar dan Sunawar [2] dalam penelitiannya berhasil mengimplementasikan YOLO untuk mendeteksi penggunaan APD seperti helm dan masker dengan tingkat akurasi 100% pada jarak 0–5 meter. Sementara itu, Bahtiar et al. [3] mengembangkan algoritma YOLOv8 yang mampu mendeteksi tujuh jenis APD dengan tingkat akurasi sebesar 85,71%. YOLOv8 menggunakan arsitektur yang lebih efisien dengan kombinasi backbone, neck, dan head yang dioptimalkan untuk pemrosesan cepat tanpa mengorbankan akurasi. Hasil serupa juga ditemukan oleh Santi et al. [7], yang mengembangkan sistem pemantauan APD berbasis YOLOv5 dengan akurasi deteksi mencapai 87%. Hal ini menunjukkan bahwa algoritma YOLO, khususnya versi terbarunya, sangat efektif untuk mendukung pengawasan keselamatan kerja otomatis.

Secara operasional, YOLO membagi citra menjadi sejumlah grid, di mana setiap grid memprediksi *bounding box*, nilai kepercayaan (*confidence score*), dan probabilitas kelas objek. Pada penelitian ini digunakan **YOLOv8**, generasi terbaru yang menawarkan arsitektur lebih efisien dan akurasi yang lebih tinggi untuk mendeteksi objek kecil seperti sarung tangan (*gloves*) maupun objek besar seperti helm (*helmet*). Struktur arsitektural YOLOv8 secara umum dapat dilihat pada Gambar 2.1.



Gambar 2. 1 Arsitektur umum YOLOv8 dalam proses ekstraksi fitur hingga deteksi objek APD (Helmet, Gloves, Safety Shoes).

Struktur Gambar 2.1 menunjukkan tiga komponen utama: *Backbone* untuk ekstraksi fitur citra, *Neck* untuk penggabungan fitur antar skala, dan *Head* untuk menghasilkan prediksi akhir. Dalam implementasi skripsi ini, *Output Detection* difokuskan pada tiga kelas utama: *helmet*, *gloves*, dan *safety shoes*.

## 2.8 Multi-task Cascaded Convolutional Neural Networks (MTCNN)

Multi-task Cascaded Convolutional Networks (MTCNN) merupakan algoritma berbasis deep learning yang digunakan untuk mendeteksi lokasi wajah sekaligus menentukan titik-titik karakteristik wajah (facial landmarks). Algoritma ini mengintegrasikan proses deteksi wajah dan face alignment dalam satu arsitektur sehingga mampu menghasilkan deteksi wajah yang akurat dan efisien. MTCNN banyak digunakan sebagai tahap awal pada sistem face recognition sebelum proses ekstraksi fitur menggunakan algoritma FaceNet [12].

MTCNN terdiri atas tiga jaringan konvolusi yang bekerja secara bertahap, yaitu Proposal Network (P-Net), Refine Network (R-Net), dan Output Network (O-Net). P-Net bertugas menghasilkan kandidat lokasi wajah beserta bounding box. Selanjutnya, R-Net

melakukan penyaringan terhadap kandidat yang tidak sesuai serta memperbaiki posisi bounding box yang dihasilkan pada tahap sebelumnya. Tahap terakhir dilakukan oleh O-Net untuk menghasilkan lokasi wajah yang lebih presisi sekaligus mendeteksi lima titik facial landmarks, yaitu kedua mata, hidung, dan kedua sudut mulut, yang digunakan dalam proses face alignment [12].

Dalam penelitian ini, MTCNN digunakan sebagai tahap awal sebelum proses identifikasi wajah menggunakan FaceNet. MTCNN berfungsi mendeteksi dan melakukan crop pada area wajah dari setiap frame video yang diperoleh melalui kamera CCTV. Hasil deteksi wajah tersebut kemudian diproses menggunakan FaceNet untuk menghasilkan embedding vector yang selanjutnya dibandingkan menggunakan metode Cosine Similarity dalam proses identifikasi karyawan [12].

## 2.9 Face Recognition dan Algoritma FaceNet

Face recognition merupakan teknologi yang digunakan untuk mengenali atau memverifikasi identitas seseorang berdasarkan citra wajah. Teknologi ini memanfaatkan karakteristik unik wajah manusia untuk membedakan satu individu dengan individu lainnya. Dalam perkembangannya, teknologi ini banyak digunakan dalam berbagai bidang, termasuk sistem keamanan dan identifikasi karyawan, karena mampu memberikan tingkat akurasi yang tinggi dalam proses identifikasi.

Dalam penelitian ini, proses pengenalan wajah dilakukan untuk mengidentifikasi karyawan yang melakukan pelanggaran APD secara otomatis. Sistem ini mengintegrasikan MTCNN untuk deteksi wajah dan FaceNet untuk ekstraksi fitur numerik (*embedding*). Skema umum proses pengenalan wajah pada sistem ini diilustrasikan pada Gambar 2.2.



Gambar 2. 2 Alur kerja sistem pengenalan wajah dari Input Video hingga keputusan identitas.

Proses dimulai dengan deteksi area wajah menggunakan MTCNN, diikuti dengan proses *crop* untuk memisahkan wajah dari latar belakang. Citra wajah tersebut kemudian diproses oleh FaceNet untuk menghasilkan *embedding vector*. FaceNet, yang diperkenalkan

oleh Schroff et al. [6], menggunakan mekanisme *Deep Convolutional Neural Network* untuk memetakan wajah ke dalam ruang vektor berdimensi tinggi (biasanya 512-d).

Secara umum, sistem face recognition terdiri atas beberapa tahapan utama, yaitu face detection, feature extraction, face representation, matching, dan recognition. Tahap face detection bertujuan untuk mendeteksi area wajah pada gambar atau video. Selanjutnya, pada tahap feature extraction, sistem mengekstraksi ciri-ciri unik wajah. Tahap face representation mengubah ciri wajah menjadi representasi numerik, yang kemudian dibandingkan dengan data yang tersimpan pada basis data pada tahap matching. Hasil dari proses tersebut digunakan untuk menentukan apakah wajah dikenali atau dikategorikan sebagai unknown.

Salah satu algoritma yang banyak digunakan dalam face recognition adalah FaceNet yang diperkenalkan oleh Schroff et al. [6]. FaceNet merupakan metode berbasis deep learning yang menggunakan convolutional neural network (CNN) untuk menghasilkan representasi wajah dalam bentuk vektor numerik yang disebut embedding. Representasi ini memungkinkan sistem untuk membandingkan wajah berdasarkan jarak antar vektor dalam ruang fitur.

Secara matematis, FaceNet memetakan citra wajah ke dalam ruang vektor berdimensi tertentu yang dinyatakan sebagai:


$$f(x) \in \mathbb{R}^d \dots\dots\dots (2.9)$$

Keterangan :

- x adalah citra wajah input,
- f(x) adalah embedding wajah,
- d adalah dimensi vektor embedding.

Tujuan utama FaceNet adalah memastikan bahwa embedding dari wajah yang sama berada pada jarak yang berdekatan, sedangkan wajah yang berbeda memiliki jarak yang lebih jauh dalam ruang vektor.

Untuk mencapai hal tersebut, FaceNet menggunakan fungsi triplet loss yang membandingkan tiga jenis data, yaitu anchor, positive, dan negative. Anchor merupakan wajah referensi, positive adalah wajah dari individu yang sama, dan negative adalah wajah dari individu yang berbeda. Fungsi ini bertujuan untuk meminimalkan jarak antara anchor dan positive serta memaksimalkan jarak antara anchor dan negative.



Gambar 2. 3 Ilustrasi mekanisme triplet loss untuk mengoptimalkan jarak embedding wajah.

Setelah embedding wajah diperoleh, proses selanjutnya adalah membandingkan embedding tersebut dengan data yang tersimpan dalam basis data. Metode yang digunakan adalah cosine similarity, yang mengukur tingkat kemiripan antara dua vektor berdasarkan sudut di antara keduanya. Rumus cosine similarity adalah:

$$\text{Cosine Similarity} = \frac{A \cdot B}{\|A\| \|B\|} \dots\dots\dots (2.10)$$

Keterangan :

A = embedding wajah input,

B = embedding wajah pada basis data,

$A \cdot B$  = dot product antara dua vektor,

$\|A\|$  dan  $\|B\|$  = norma masing-masing vektor.

Nilai similarity yang mendekati 1 menunjukkan tingkat kemiripan yang tinggi, sehingga wajah dapat dikenali. Sebaliknya, nilai yang lebih rendah menunjukkan bahwa wajah tidak dikenali.

Penelitian yang dilakukan oleh Li [4] menunjukkan bahwa FaceNet memiliki tingkat akurasi yang tinggi pada dataset LFW, sementara Mukherjee et al. [5] menunjukkan bahwa teknologi face recognition dapat digunakan secara efektif dalam sistem identifikasi karyawan. Dengan kemampuan tersebut, FaceNet menjadi solusi yang tepat dalam mendukung sistem monitoring kepatuhan penggunaan APD, karena tidak hanya mampu

mendeteksi pelanggaran, tetapi juga mengidentifikasi individu yang terlibat secara otomatis. Berdasarkan penelitian tersebut, FaceNet dipilih pada penelitian ini karena mampu menghasilkan representasi wajah yang diskriminatif serta memiliki tingkat akurasi yang tinggi dalam proses identifikasi karyawan.

## 2.10 Roboflow


Roboflow merupakan platform berbasis web yang digunakan untuk membantu pengelolaan dataset pada pengembangan model Computer Vision. Platform ini menyediakan berbagai fitur yang mendukung proses persiapan dataset, seperti anotasi (annotation), preprocessing, augmentation, pembagian dataset (training, validation, dan testing), pelatihan model, serta ekspor dataset ke berbagai format yang kompatibel dengan berbagai framework deep learning, termasuk format YOLO. Melalui fitur tersebut, Roboflow membantu menghasilkan dataset yang terstruktur dan siap digunakan pada proses pelatihan model[13]

Dalam Roboflow, proses persiapan dataset dilakukan dengan membuat dataset version. Pada tahap ini pengguna dapat menentukan langkah preprocessing, menerapkan augmentation apabila diperlukan, mengatur proporsi pembagian dataset menjadi data training, validation, dan testing, serta mengekspor dataset sesuai format yang dibutuhkan untuk proses pelatihan model [13].

Pada penelitian ini, Roboflow digunakan untuk melakukan anotasi objek pada citra pekerja dengan memberikan bounding box pada objek helm keselamatan, sarung tangan, dan sepatu keselamatan. Selain itu, Roboflow juga digunakan untuk melakukan preprocessing berupa auto-orient dan resizing, membagi dataset menjadi data training, validation, dan testing, serta mengekspor dataset dalam format YOLO sebelum digunakan pada proses pelatihan model [13].

## AI that sees and understands the physical world

Over 1 million engineers deploy visual intelligence for video, images, and real-time streams with Roboflow.

[Get Started](#)[Request a Demo](#)

Gambar 2. 4 Tampilan Dashboard Roboflow

### 2.11 Real-Time Streaming Protocol (RTSP)

Real-Time Streaming Protocol (RTSP) merupakan protokol pada lapisan aplikasi (application layer) yang digunakan untuk mengendalikan sesi streaming multimedia melalui jaringan. RTSP menyediakan mekanisme untuk mengontrol proses streaming, seperti memulai (SETUP), menjalankan (PLAY), menghentikan sementara (PAUSE), dan mengakhiri (TEARDOWN) sesi komunikasi antara client dan server. Berbeda dengan protokol pengiriman data, RTSP berfungsi sebagai protokol kontrol yang mengatur jalannya sesi streaming multimedia melalui jaringan [14].

Pada sistem Closed Circuit Television (CCTV), RTSP banyak digunakan untuk mengakses aliran video (video stream) dari kamera IP maupun perangkat perekam (Network Video Recorder (NVR) atau Digital Video Recorder (DVR)). Video streaming yang diperoleh melalui RTSP dapat ditampilkan maupun diproses lebih lanjut oleh sistem berbasis Computer Vision. Pemanfaatan RTSP pada sistem monitoring CCTV memungkinkan video dari kamera dikirimkan secara kontinu ke perangkat komputer maupun perangkat bergerak yang terhubung ke jaringan untuk keperluan pemantauan dan analisis [15].

Dalam penelitian ini, RTSP digunakan sebagai media komunikasi untuk memperoleh video streaming dari kamera CCTV yang terpasang pada area workshop PT Premier Engineering Indonesia. Setiap frame yang diterima dari video streaming kemudian diproses menggunakan algoritma YOLOv8 untuk mendeteksi penggunaan Alat Pelindung Diri (APD), selanjutnya dilakukan proses identifikasi wajah menggunakan FaceNet. Hasil deteksi yang diperoleh kemudian dikirimkan melalui Flask API dan ditampilkan pada aplikasi mobile berbasis Flutter, sehingga sistem dapat membantu proses monitoring kepatuhan penggunaan APD dan identifikasi karyawan secara otomatis.

