

# Implementation of YOLOv5 for Detecting the Use of Personal Protective Equipment by IPAL Operators in the Pharmaceutical Industry

## Implementasi YOLOv5 untuk Deteksi Penggunaan Alat Pelindung Diri Pada Operator IPAL di Industri Farmasi

Yoga Dwi Anggoro Moekti<sup>1)</sup>, Rohman Dijaya<sup>\*2)</sup>, Suhendro Busono<sup>3)</sup>, Arif Senja Fitriani<sup>4)</sup>

<sup>1)</sup>Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

<sup>2)</sup>Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

<sup>3)</sup>Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

<sup>4)</sup>Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

\*Email Penulis Korespondensi: rohman.dijaya@umsida.ac.id

**Abstract.** Occupational health and safety (OHS) is an important aspect of industrial operations, especially in the area of Wastewater Treatment Plants (WWTP) which have a high level of risk. One of the efforts to implement OHS is to ensure compliance with the use of Personal Protective Equipment (PPE) by operators. However, manual supervision has limitations in terms of effectiveness and consistency. This research aims to develop an automatic PPE usage detection system using the You Only Look Once version 5 (YOLOv5) algorithm. The research method includes data collection and labeling, data preprocessing, model training, and system testing using images and pictures obtained from CCTV recordings. The research results show that the best model was achieved in a scenario with a resolution of 416, a batch size of 16, and 120 epochs, with a mAP value of 89.02%. The system is capable of detecting PPE objects such as helmets and safety shoes with high accuracy, but it experiences a decrease in performance on small-sized objects like masks and gloves, especially under low lighting conditions and occlusion. Overall, the developed system has the potential to support real-time monitoring of PPE usage in the wastewater treatment plant environment.

**Keywords -** Personal Protective Equipment (PPE), Object Detection, Wastewater Treatment Plant (WWTP), Occupational Safety, YOLOv5.

**Abstrak.** Keselamatan dan kesehatan kerja (K3) merupakan aspek penting dalam operasional industri, khususnya pada area Instalasi Pengolahan Air Limbah (IPAL) yang memiliki tingkat risiko tinggi. Salah satu upaya penerapan K3 adalah memastikan kepatuhan penggunaan Alat Pelindung Diri (APD) oleh operator. Namun, pengawasan secara manual memiliki keterbatasan dari segi efektivitas dan konsistensi. Penelitian ini bertujuan untuk mengembangkan sistem deteksi penggunaan APD secara otomatis menggunakan algoritma *You Only Look Once versi 5 (YOLOv5)*. Metode penelitian meliputi pengumpulan dan pelabelan data, praproses data, pelatihan model, serta pengujian sistem menggunakan citra dan gambar yang diperoleh dari rekaman CCTV. Hasil penelitian menunjukkan bahwa model terbaik diperoleh pada skenario dengan resolusi 416, *batch size* 16, dan 120 *epoch*, dengan nilai *mAP* sebesar 89.02%. Sistem mampu mendeteksi objek APD seperti helm dan sepatu keselamatan dengan akurasi tinggi, namun mengalami penurunan performa pada objek berukuran kecil seperti masker dan sarung tangan, terutama pada kondisi pencahayaan rendah dan oklusi. Secara keseluruhan, sistem yang dikembangkan berpotensi mendukung pengawasan penggunaan APD secara real-time di lingkungan IPAL.

**Kata Kunci -** Alat Pelindung Diri (APD), Deteksi Objek, Instalasi Pengolahan Air Limbah (IPAL), Keselamatan Kerja, YOLOv5.

## I. PENDAHULUAN

Keselamatan dan Kesehatan Kerja (K3) merupakan aspek penting dalam melindungi pekerja dari bahaya yang berkaitan dengan bahan kimia berbahaya. Berdasarkan Kementerian Kesehatan Republik Indonesia tahun 2017, penggunaan Alat Pelindung Diri (APD) seperti masker, sarung tangan karet, helm, dan sepatu keselamatan diperlukan untuk mencegah kecelakaan kerja serta paparan bahan berbahaya. Penggunaan APD yang tepat dapat meminimalkan risiko cedera dan dampak negatif terhadap kesehatan pekerja di lingkungan kerja dengan tingkat risiko tinggi [1]. Selain itu, penggunaan APD merupakan kewajiban yang disesuaikan dengan jenis pekerjaan untuk menjamin keselamatan individu maupun pekerja lain di sekitarnya. Jenis APD meliputi alat pelindung kepala, pernapasan, tangan, dan kaki [2].

Pada area Instalasi Pengolahan Air Limbah (IPAL), operator diwajibkan menggunakan APD secara lengkap karena berhadapan langsung dengan limbah cair dan limbah bahan berbahaya dan beracun (B3) dari industri farmasi. Namun, pengawasan penggunaan APD di industri masih dilakukan secara manual. Koordinator IPAL harus melakukan pemeriksaan secara langsung sebelum operator bekerja. Metode ini kurang efisien karena rentan terhadap kesalahan manusia (*human error*) dan tidak mampu melakukan pemantauan secara berkelanjutan. Oleh karena itu, diperlukan sistem otomatis untuk meningkatkan efektivitas pengawasan penggunaan APD.

Perkembangan teknologi *computer vision* dan deep learning memungkinkan pengembangan sistem deteksi objek secara otomatis [12], [13]. Salah satu algoritma yang banyak digunakan adalah *You Only Look Once (YOLO)*, yang mampu melakukan deteksi objek secara real-time dengan tingkat akurasi yang tinggi [14]. *YOLOv5* merupakan pengembangan dari algoritma *YOLO* yang menawarkan peningkatan performa dalam hal kecepatan dan akurasi dibandingkan versi sebelumnya [3], [4].

*YOLOv5* dipilih karena mampu berjalan pada berbagai perangkat, baik CPU maupun GPU, sehingga sesuai untuk implementasi sistem deteksi berbasis video. Kecepatan deteksi menjadi faktor penting dalam sistem real-time karena video terdiri dari banyak frame per detik. Proses deteksi yang lambat dapat menyebabkan keterlambatan (*delay*) yang menurunkan kualitas sistem [5].

Beberapa penelitian sebelumnya telah mengimplementasikan *YOLOv5* dalam berbagai kasus deteksi objek. Nofriyanti *et al.*, [6] mengembangkan sistem deteksi helm keselamatan dengan nilai precision sebesar 0,95 dan recall sebesar 0,93. Suroiyah *et al.*, [7] menunjukkan bahwa *YOLOv5* mampu mendeteksi penggunaan masker dengan nilai F1-score dan mAP@50 sebesar 86%. Rosalina *et al.*, [8] juga menunjukkan bahwa *YOLOv5* efektif dalam mendeteksi perhatian siswa secara *real-time* dengan nilai mAP@50 sebesar 89,9%.

Selain itu, beberapa penelitian menggabungkan *YOLOv5* dengan metode lain untuk meningkatkan performa sistem. Wardani *et al.*, [9] menggabungkan *YOLOv5* dengan LSTM untuk mendeteksi anomali keramaian dan memperoleh akurasi sebesar 98%. Afrialdy *et al.* [10] menerapkan metode preprocessing seperti U-Net dan inpainting yang meningkatkan nilai precision menjadi 0,942 dan F1-score sebesar 0,91. Syifa dan Nugroho [11] juga menunjukkan bahwa *YOLOv5* mampu mendeteksi manusia dengan akurasi rata-rata sebesar 80,5% dalam kondisi nyata.

Penelitian ini memiliki batasan pada jumlah dataset yang digunakan, yaitu sekitar 500 citra. Jumlah data yang terbatas dapat mempengaruhi kemampuan model dalam melakukan generalisasi terhadap berbagai kondisi lingkungan. Selain itu, distribusi data yang kurang seimbang antar kelas juga berpotensi menyebabkan bias pada model. Dampaknya, performa deteksi cenderung lebih baik pada objek tertentu dibandingkan objek lainnya, terutama pada objek berukuran kecil seperti masker dan sarung tangan.

Meskipun berbagai penelitian telah berhasil mengimplementasikan *YOLOv5* dalam deteksi objek, sebagian besar penelitian masih berfokus pada lingkungan umum seperti konstruksi dan area publik. Penerapan deteksi penggunaan APD pada area Instalasi Pengolahan Air Limbah (IPAL) di industri farmasi masih terbatas. Selain itu, kondisi lingkungan IPAL yang kompleks, seperti pencahayaan yang tidak stabil, oklusi, dan variasi jarak objek, menjadi tantangan dalam proses deteksi.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan sistem deteksi penggunaan APD pada operator IPAL di industri farmasi menggunakan algoritma *YOLOv5*. Sistem ini diharapkan mampu mendeteksi penggunaan APD seperti helm, masker, sarung tangan, dan sepatu keselamatan secara otomatis melalui analisis video CCTV. Dengan demikian, sistem yang dikembangkan dapat mendukung pengawasan keselamatan kerja secara lebih efektif dan berkelanjutan.

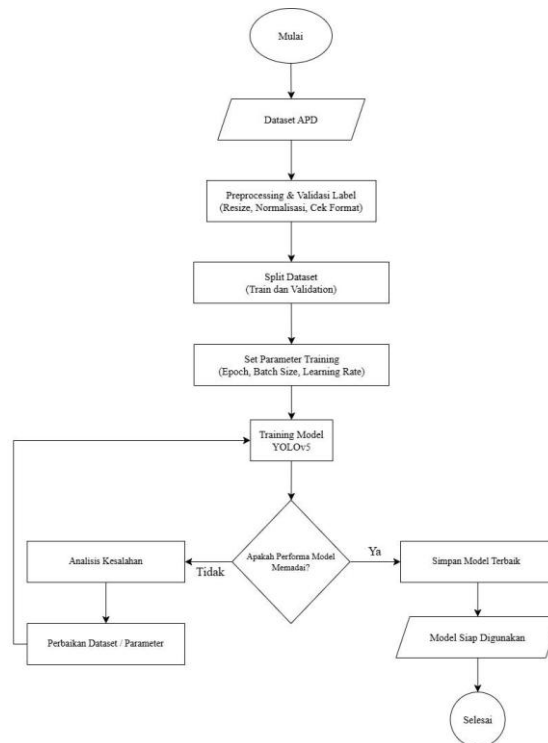
## II. METODE

### 2.1 Tahapan Penelitian

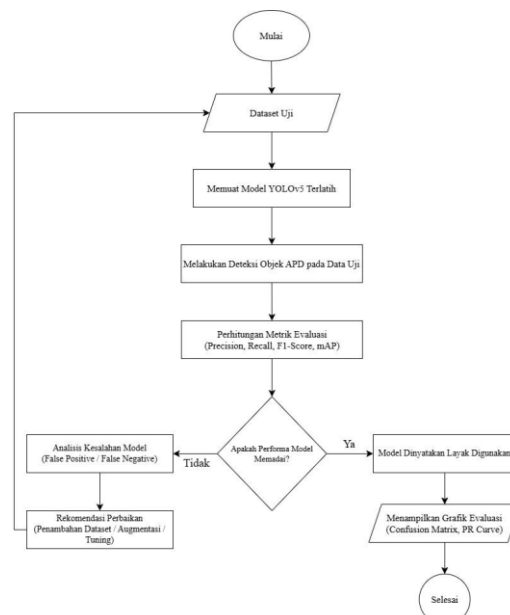
Penelitian ini menggunakan metode deteksi objek berbasis *deep learning* dengan algoritma *YOLOv5* untuk mendeteksi penggunaan APD pada operator Instalasi Pengolahan Air Limbah (IPAL). Proses penelitian dimulai dari pengumpulan dataset APD yang diperoleh dari rekaman *CCTV*, kemudian dilakukan proses pra-proses data yang meliputi seleksi data, pelabelan objek, serta pembagian dataset menjadi data pelatihan dan data validasi. Selanjutnya dilakukan proses pelatihan model menggunakan algoritma *YOLOv5* untuk menghasilkan model deteksi yang mampu mengenali objek APD.

Dataset pada penelitian ini diperoleh dari perekaman video aktivitas pekerja yang menggunakan Alat Pelindung Diri (APD) menggunakan *CCTV* dengan resolusi HD. Video yang direkam dengan durasi sekitar 2 menit, kemudian dikonversi menjadi kumpulan gambar menggunakan fitur *Extract Frame* pada *platform Roboflow*. Dari proses ekstraksi tersebut menghasilkan 500 gambar yang digunakan sebagai dataset penelitian. Selanjutnya seluruh gambar dilakukan proses pelabelan (*annotation*) menggunakan *Roboflow* dengan memberikan *bounding box* pada

objek APD, kemudian diekspor dalam format *YOLO* sehingga dataset dapat digunakan untuk proses pelatihan dan evaluasi model deteksi objek.



**Gambar 1.** Tahapan *Training* Sistem Deteksi APD



**Gambar 2.** Tahapan *Evaluasi* Sistem Deteksi APD

Proses pelatihan dilakukan untuk mengetahui kemampuan sistem dalam mendeteksi penggunaan APD seperti *helmet*, *masker*, *hand gloves*, dan *safety boot* secara otomatis. Hasil deteksi kemudian dievaluasi menggunakan parameter pengukuran kinerja model seperti *precision*, *recall*, dan *mean Average Precision (mAP)*.

Tahapan penelitian yang dilakukan pada sistem deteksi APD menggunakan *YOLOv5* dapat dilihat pada **Gambar 1** dan **Gambar 2** di atas.

Proses *training* model dilakukan menggunakan platform *Google Colab* dengan dukungan *GPU High-RAM T4* untuk mempercepat komputasi. Dataset yang telah dibuat dan diberi label menggunakan *Roboflow* kemudian diunggah ke lingkungan *Colab* dalam format *YOLOv5*. Proses *training* model dengan menentukan parameter seperti *epoch*, ukuran gambar, dan *batch size*. Hasil dari proses training berupa model terbaik (*best.pt*) yang kemudian digunakan pada tahap pengujian dan implementasi sistem deteksi APD.

Evaluasi model dilakukan masing-masing 3 tahap, diantaranya tahap deteksi objek, pelacakan objek, dan perhitungan objek. Matrik evaluasi yang digunakan pada deteksi objek dan perhitungan objek berupa *precision*, *recall*, *mAP*, dan *F1-score*.

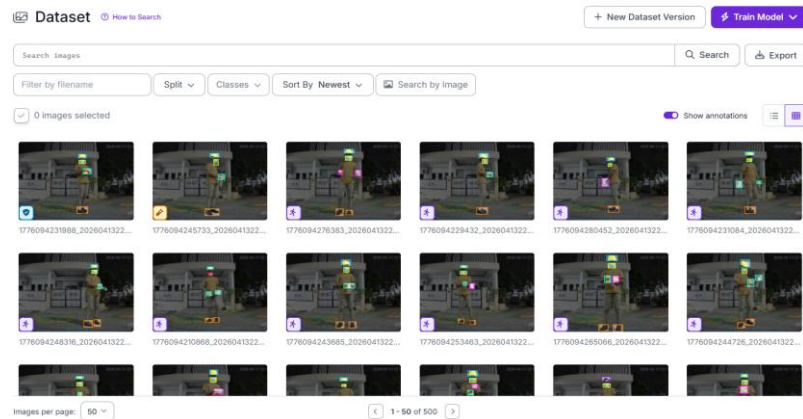
## 2.2 Data Acquisition dan Pelabelan

Dataset yang digunakan dalam penelitian ini terdiri dari citra operator di area Instalasi Pengelolaan Air Limbah (IPAL) industri farmasi. Dataset mencakup variasi penggunaan APD seperti masker, sarung tangan karet, helm, dan *sepatu safety*. Data primer diambil melalui rekaman *real time* dari CCTV dan pengambilan gambar langsung di area IPAL, dengan *frame rate* hingga 25 atau 30 *fps*.



**Gambar 3.** Dataset Gambar

Proses pelabelan (*annotation*) dilakukan menggunakan format *YOLO (.txt)* yang menentukan koordinat bounding box untuk setiap objek. Kelas yang didefinisikan meliputi 8 kelas yaitu. Dataset yang digunakan dalam penelitian ini terdiri dari 500 gambar, seperti yang ditunjukkan pada **Gambar 4**. Proses pelabelan atau anotasi *bounding box* pada setiap bagian tubuh di dalam gambar tersebut dilakukan menggunakan platform *Roboflow*. Dataset ini dikategorikan ke dalam delapan kelas utama, yakni “*with\_helmet*”, “*without\_helmet*”, “*with\_mask*”, “*without\_mask*”, “*with\_hand\_gloves*”, “*without\_hand\_gloves*”, “*with\_safety boot*”, dan “*without\_safety boot*”.



**Gambar 4.** Dataset anotasi/pelabelan

Dari total 500 gambar awal, hasil pelabelan *bounding box* di *Roboflow* mengidentifikasi sebanyak 2.503 objek bagian tubuh. Seperti yang ditunjukkan pada **Gambar 5** rincian distribusi objek untuk masing-masing kelas adalah sebagai berikut: kelas "with\_mask" sebanyak 240 data, kelas "without\_mask" sebanyak 228 data, kelas "with\_helmet" sebanyak 371 data, kelas "without\_helmet" sebanyak 130 data, kelas "with\_hand\_gloves" sebanyak 326 data, kelas "without\_hand\_gloves" sebanyak 453 data, kelas "with\_safety\_boot" sebanyak 683 data, kelas "without\_safety\_boot" sebanyak 72 data. Setelah proses anotasi selesai, dataset diekspor langsung dari platform *Roboflow* ke dalam format teks (.txt) agar sesuai dengan standar arsitektur *YOLOv5*. Tahap selanjutnya adalah pembagian dataset menjadi kelompok data latih (*train*), data validasi (*val*), dan *testing (test)* dengan rasio 70:20:10 sssKonfigurasi rasio ini diterapkan langsung melalui fitur dataset split pada *Roboflow*, di mana pemilihan rasio 70:20:10 dinilai sebagai pembagian terbaik dalam *training* data.

COLOR	CLASS NAME	COUNT
<span style="color: orange;">●</span>	with_safety boot	683
<span style="color: cyan;">●</span>	Without_hand gloves	453
<span style="color: blue;">●</span>	with_helmet	371
<span style="color: magenta;">●</span>	with_hand gloves	326
<span style="color: yellow;">●</span>	with_mask	240
<span style="color: red;">●</span>	Without_mask	228
<span style="color: purple;">●</span>	Without_helmet	130
<span style="color: darkblue;">●</span>	Without_safety boot	72

**Gambar 5.** Objek class

Proses pelatihan dan evaluasi model dilakukan menggunakan bahasa pemrograman *Python* dengan *framework PyTorch*. *Hyperparameter* diatur untuk mengoptimalkan konvergensi model sebagai berikut:

- Epoch* : 120 atau 170
- Batch size* : 8, 16, 32, 64
- Optimizer* : SGD
- Input size* : 416 atau 640

Parameter resolusi citra (*image size*) digunakan untuk mengatur dimensi piksel masukan guna menyeimbangkan penangkapan detail fitur objek dengan beban pemrosesan. Sementara itu, ukuran *batch (batch size)* menentukan kuantitas citra yang diproses secara paralel dalam satu komputasi sebelum terjadinya pembaruan nilai bobot, yang mana konfigurasinya disesuaikan dengan kapasitas memori perangkat. Durasi pembelajaran algoritma dikontrol melalui jumlah *epoch*, yang merepresentasikan siklus iterasi penuh terhadap keseluruhan dataset. Untuk memandu arsitektur jaringan, digunakan berkas konfigurasi data (*YAML*) yang memetakan direktori dataset beserta penamaan kelas objek target. Seluruh akumulasi ekstraksi fitur dan pembelajaran selama proses pelatihan tersebut pada akhirnya diekspor menjadi parameter matematis yang disebut bobot model (*weight*), di mana bobot dengan nilai evaluasi tertinggi (*best.pt*) akan digunakan sebagai rujukan utama pada tahap pengujian

(inferensi). Selanjutnya, semua poin yang telah disebutkan di atas digabungkan menjadi teks perintah *training* model *YOLOv5* seperti yang terlihat pada Gambar 6 berikut.

```
# Membangun perintah YOLOv5 train.py
command = [
    "python", "/content/yolov5/train.py",
    "--img", str(img),
    "--batch", str(batch),
    "--epochs", str(epoch),
    "--data", data_yaml,
    "--weights", weights,
    "--project", project_name,
    "--name", name,
    "--cache" # Menggunakan cache ram untuk mempercepat training
]
```

**Gambar 6.** *Training* model *YOLOv5*

*Training* model *YOLOv5* menggunakan data dari *Github Ultralytic*, yang selanjutnya selama proses *training* menghasilkan beberapa nilai salah satunya adalah nilai *F1* yaitu matriks gabungan yang mempertimbangkan keseimbangan antara *precision* dan *recall* [18]. Hasil tersebut diperoleh dari pernyataan matematis sebagai berikut.

Keterangan:

$$Recall = \frac{TP}{TP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$F1 = 2 \times \frac{1}{\frac{1}{precision} + \frac{1}{recall}} \quad (3)$$

FP = *False Positive* (Ketika model salah mendeteksi)

FN = *False Negative* (Ketika model gagal mendeteksi APD yang sebenarnya ada)

TP = *True Positive* (Ketika terdeteksi dengan benar)

### III. HASIL DAN PEMBAHASAN

Bagian ini memaparkan hasil dari ekstraksi fitur dan evaluasi kinerja deteksi pada model yang telah dikembangkan. Untuk mendapatkan performa algoritma yang paling optimal dalam mengidentifikasi objek target, tahapan *tuning* model menjadi sangat krusial. Proses ini ditunjukkan melalui penggabungan berbagai parameter pelatihan yang telah ditetapkan secara spesifik pada rancangan sistem sebelumnya. Kombinasi silang berbagai metrik pelatihan ini dirancang untuk menguji batas kemampuan model saat dihadapkan pada variasi dalam beban pembelajaran mesin yang berbeda.

#### 3.1 Training Model

Bagian ini menunjukkan berbagai kombinasi konfigurasi instruksi model yang diterapkan dalam penelitian ini. Konfigurasi instruksi model yang telah ditetapkan sebelumnya akan dikombinasikan untuk memperoleh hasil yang terbaik.

**Tabel 1.** Konfigurasi *Training Model Yolov5*

Case	Img	Batch	Epoch
1	416	8	120
2	416	8	170
3	416	16	120
4	416	16	170
5	416	32	120
6	416	32	170
7	416	64	120
8	416	64	170
9	640	8	120
10	640	8	170
11	640	16	120
12	640	16	170
13	640	32	120
14	640	32	170
15	640	64	120
16	640	64	170

Tabel 1 menunjukkan 16 skenario konfigurasi instruksi model yang akan diterapkan dalam penelitian ini. Selanjutnya, dari skenario instruksi model *YOLOv5*, data nilai *F1*, *mAP*, presisi (P), *recall* (R), dan waktu instruksi (*time*) dikumpulkan.

**Tabel 2.** Hasil Training Model *Yolov5*

Case	Img	Batch	Epoch	F1	P	R	mAP	Timer
1	416	8	120	86.15	90.47	82.22	86.43	0:16:35
2	416	8	170	85.23	87.41	83.14	84.97	0:23:12
3	416	16	120	88.79	89.28	88.30	89.02	0:13:09
4	416	16	170	84.61	85.44	83.79	81.88	0:15:41
5	416	32	120	85.99	89.62	82.64	83.62	0:10:10
6	416	32	170	85.92	86.61	85.24	84.95	0:14:24
7	416	64	120	86.05	88.42	83.82	84.51	0:02:25
8	416	64	170	85.83	88.07	83.70	84.27	0:13:37
9	640	8	120	86.32	86.48	86.16	87.21	0:24:33
10	640	8	170	89.14	90.90	87.45	88.95	0:34:05
11	640	16	120	84.62	84.96	84.27	84.13	0:21:58
12	640	16	170	85.89	87.08	84.73	85.80	0:26:43
13	640	32	120	86.86	87.50	86.22	86.34	0:19:13
14	640	32	170	87.93	88.47	87.40	86.29	0:26:03
15	640	64	120	85.32	85.44	85.21	84.92	0:20:26
16	640	64	170	87.37	89.70	85.17	86.53	0:27:49


Menurut Tabel 2 rekapitulasi pengujian, variasi hyperparameter, termasuk resolusi gambar (ukuran gambar), ukuran batch (ukuran batch), dan jumlah iterasi (epoch), sangat mempengaruhi kinerja model *YOLOv5* dalam mendeteksi Alat Pelindung Diri (APD). Empat metrik utama *F1-Score*, *Precision*, *Recall*, dan *mAP* digunakan untuk mengevaluasi kinerja model. Secara keseluruhan, model beroperasi dengan sangat baik, dengan rentang nilai *mAP* antara 83.62% dan 89.02%. Menurut data tersebut, skenario 3 (*Case 3*), yang menggunakan resolusi gambar 416, ukuran batch 16, dan 120 epoch, mencapai nilai *F1-Score* tertinggi sebesar 88.79% dan *mAP* sebesar 89.02%.

### 3.2 Evaluasi Model

Untuk menjamin keakuratan dari hasil penelitian, seluruh skenario model yang telah dilatih harus melalui tahap evaluasi. Validasi kinerja model diuji menggunakan sepuluh gambar dari CCTV di lokasi IPAL dengan berbagai kondisi situasi yang berbeda. Pendekatan ini bertujuan untuk mengukur tingkat keberhasilan setiap model dalam mendeteksi penggunaan Alat Pelindung Diri (APD). Adapun sepuluh gambar yang dibutuhkan untuk proses pengujian tersebut adalah sebagai berikut.



**Gambar 7.** Bahan 1 sebagai evaluasi model  
Pemilihan gambar 7 bertujuan untuk mengevaluasi performa model terhadap objek yang berada pada jarak pantau maksimal dari kamera CCTV. Kondisi ini menuntut ketajaman model dalam mengenali fitur Alat Pelindung Diri berukuran sangat kecil (minim piksel) tanpa kehilangan tingkat keyakinan (*confidence score*).



**Gambar 8.** Bahan 2 sebagai evaluasi model  
Gambar 8 dipilih karena merepresentasikan kondisi lingkungan IPAL dengan pencahayaan yang tidak merata atau area bayangan (*low-light/shadows*). Bahwa algoritma tetap mampu membedakan tepian objek (seperti helm atau sepatu) dari latar belakang yang gelap.



**Gambar 9.** Bahan 3 sebagai evaluasi model  
Penggunaan gambar 9 difokuskan pada skenario oklusi, di mana postur atau bagian tubuh pekerja terhalang oleh struktur fisik di lapangan seperti pipa atau perancah besi.



**Gambar 10.** Bahan 4 sebagai evaluasi model  
Gambar 10 perubahan sudut pandang ini sering kali menyembunyikan fitur utama kelas masker dan sarung tangan, sehingga berpotensi memicu *False Negative*.



**Gambar 11.** Bahan 5 sebagai evaluasi model  
Gambar 11 adanya kemiripan spektrum warna antara APD yang dikenakan pekerja dengan latar



**Gambar 12.** Bahan 6 sebagai evaluasi model  
Gambar 12 untuk menganalisis hasil deteksi pada objek pekerja yang berada di sudut ekstrem atau tepian

belakang lingkungan kerja (*background camouflaje*).



**Gambar 13.** Bahan 7 sebagai evaluasi model Gambar 13 kondisi operasional standar dengan pencahayaan optimal, jarak ideal, dan posisi pekerja yang terbuka. Pemilihan citra ini berfungsi sebagai parameter kontrol (*baseline*) untuk membuktikan bahwa model dapat mencapai akurasi deteksi maksimal pada situasi yang minim gangguan visual.

bingkai (*frame*) kamera CCTV. Pada area ini, objek sering kali mengalami distorsi visual.



**Gambar 14.** Bahan 8 sebagai evaluasi model Gambar 14 ini memuat tantangan ambiguitas visual yang tinggi, seperti keberadaan benda (topi putih di tangan pekerja) yang memiliki karakteristik bentuk dan warna menyerupai kelas masker, guna menguji tingkat presisi (*False Positive*) dari model.



**Gambar 15.** Bahan 9 sebagai evaluasi model Gambar 15, model dituntut untuk mampu memisahkan *bounding box* masing-masing individu tanpa menggabungkannya menjadi satu deteksi yang salah.



**Gambar 16.** Bahan 10 sebagai evaluasi model Gambar 16, model tetap tangguh dan tidak kehilangan jejak deteksi pada objek ekstremitas (seperti sarung tangan dan sepatu) yang mungkin mengalami sedikit *motion blur*.




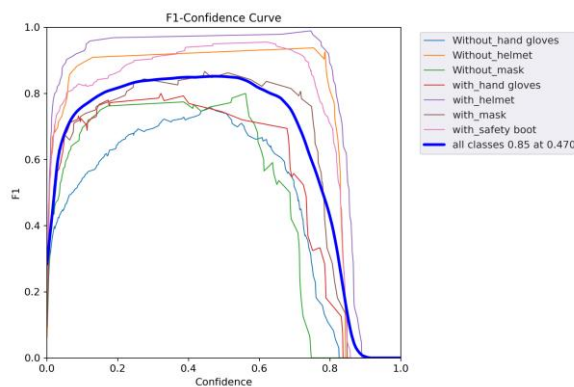
**Tabel 3.** Hasil Evaluasi Akurasi dari setiap model

Case	Img	Batch	Epoch	Jumlah Deteksi	
				Benar	Salah
1	416	8	120	116	49
2	416	8	170	119	50
3	416	16	120	121	47
4	416	16	170	115	48
5	416	32	120	119	54
6	416	32	170	123	43
7	416	64	120	112	57
8	416	64	170	116	49
9	640	8	120	124	36
10	640	8	170	119	56
11	640	16	120	115	67
12	640	16	170	113	62
13	640	32	120	114	64
14	640	32	170	121	50
15	640	64	120	116	53
16	640	64	170	115	47

Data pada Tabel 3 menunjukkan hasil yang di luar ekspektasi awal. Case 9 (*img 640, batch 8, epoch 120*) yang merupakan model dengan akurasi *training* terbaik, justru mencatatkan performa deteksi tingkat menengah (124 deteksi benar) diimbangi dengan jumlah kesalahan yang sangat rendah (36 salah).

### 3.3 Analisis Kinerja Model

Hasil pengujian dari 16 skenario menunjukkan bahwa konfigurasi *hyperparameter* memberikan dampak yang sangat krusial terhadap titik konvergensi model. Secara umum, penggunaan *batch size* yang lebih kecil (seperti 8 atau 16) menghasilkan pembaruan bobot (*weight update*) yang lebih sering dalam setiap *epoch*, sehingga model mampu mempelajari detail fitur objek dengan lebih teliti dibandingkan *batch size* besar (64). Selain itu, peningkatan resolusi citra masukan (*img 640*) secara teoritis terbukti meningkatkan nilai metrik *F1-Confidence Curve* seperti yang ditunjukkan pada **Gambar 17**, *Precision-Recall Curve* seperti yang ditunjukkan pada **Gambar 18**, *Recall-Confidence Curve* seperti yang ditunjukkan pada **Gambar 19**, dan *Confusion Matrix*, seperti yang ditunjukkan pada **Gambar 20** selama masa pelatihan karena arsitektur jaringan memiliki lebih banyak piksel untuk mengekstraksi fitur spasial. Berdasarkan evaluasi kualitatif pada sepuluh citra lapangan dengan berbagai kondisi ekstrem, arsitektur YOLOv5 terbukti sangat tangguh (*robust*) dalam mengenali kelas makro seperti Sepatu Keselamatan (*Safety Boots*) dan Sarung Tangan, bahkan dalam kondisi pencahayaan minim. Meskipun demikian, deteksi kelas mikro seperti Helm dan Sarung Tangan masih menjadi tantangan komputasi. Kesalahan deteksi (*False Positive*) umumnya terjadi akibat adanya ambiguitas visual yang ekstrem, seperti pada kasus pengujian citra ke-8, di mana model salah mengenali objek topi putih di tangan pekerja sebagai masker karena kemiripan bentuk dan pigmen warna.

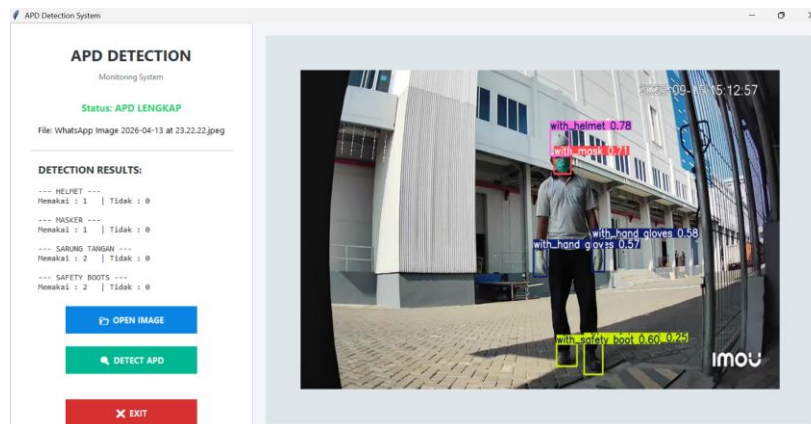


**Gambar 19.** Recall-Confidence Curve

**Gambar 20.** Confusion Matrix

Untuk memfasilitasi pengujian model secara interaktif, penelitian ini mengimplementasikan Antarmuka *Pengguna Grafis* (GUI) berbasis *web* menggunakan *library* Gradio. Seperti yang ditunjukkan pada **Gambar 21**, sistem dirancang untuk menerima masukan berupa citra pekerja lapangan dan secara otomatis mengeksekusi proses inferensi menggunakan bobot model terbaik (*best.pt*). Sistem memberikan dua luaran informasi secara berdampingan, yakni: (1) visualisasi *bounding box* hasil deteksi secara spasial pada citra, dan (2) panel rekapitulasi

teks yang menghitung jumlah setiap kelas APD yang berhasil terdeteksi. Pendekatan antarmuka ini memudahkan evaluasi kepatuhan Keselamatan dan Kesehatan Kerja (K3) secara komprehensif dan *real-time*.



Gambar 21. User Interface

#### IV. SIMPULAN

Penelitian ini berhasil mengimplementasikan *YOLOv5* untuk deteksi APD di area IPAL dengan nilai mAP sebesar 89%. Sistem ini terbukti efektif dalam meningkatkan pengawasan K3 secara otomatis. Penelitian ini memiliki keterbatasan pada jumlah dataset yang digunakan, yaitu sebanyak 500 citra. Jumlah data yang relatif terbatas ini berpotensi mempengaruhi kemampuan generalisasi model dalam mengenali objek pada kondisi yang beragam. Selain itu, keterbatasan variasi data dapat meningkatkan risiko *overfitting*, di mana model cenderung lebih optimal pada data pelatihan namun kurang akurat saat diimplementasikan pada data baru. Dampaknya, performa deteksi objek dalam skenario nyata belum sepenuhnya optimal dan masih memerlukan pengembangan lebih lanjut dengan penambahan dataset yang lebih representatif. Untuk meningkatkan kinerja model, penelitian selanjutnya disarankan menggunakan dataset dengan jumlah yang lebih besar dan variasi yang lebih beragam, baik dari segi kondisi pencahayaan, sudut pengambilan gambar, maupun variasi objek. Selain itu, penerapan teknik augmentasi data dan *fine-tuning* model juga dapat dilakukan untuk mengurangi risiko *overfitting* serta meningkatkan kemampuan generalisasi model. Pengujian pada data real-time juga diperlukan untuk mengevaluasi performa sistem secara lebih komprehensif dalam kondisi nyata. Oleh karena itu, pengembangan selanjutnya disarankan untuk menambah variasi data dari lokasi industri yang berbeda atau menggunakan pendekatan *transfer learning* guna memperkuat robustitas model.

#### UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Universitas Muhammadiyah Sidoarjo atas dukungan fasilitas laboratorium komputer untuk menunjang pelaksanaan penelitian ini. Ucapan terima kasih juga disampaikan kepada bagian administrasi kampus atas bantuan dan dukungan administratif selama proses penelitian berlangsung..

#### REFERENSI

- [1] M. I. Iskandar, M. T. N. Situmorang, and K. Kholil, "Analisis kepatuhan karyawan terhadap penggunaan APD di laboratorium kimia industri farmasi," *EKOMA*, vol. 4, no. 3, pp. 5975–5981, 2025.
- [2] R. Zou *et al.*, "When microbial electrochemistry meets UV: The applicability to high-strength real pharmaceutical industry wastewater," *Journal of Hazardous Materials*, vol. 423, p. 127151, 2022.

- [3] I. W. A. A. Wiguna, R. R. Huizen, and G. A. Pradipta, "Optimization of Vehicle Detection at Intersections Using the YOLOv5 Model," *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika (JITEKI)*, vol. 10, no. 4, pp. 885-896, 2024.
- [4] L. Susanti, N. K. Daulay, and B. Intan, "Sistem Absensi Mahasiswa Berbasis Pengenalan Wajah Menggunakan Algoritma YOLOv5," *JURIKOM (Jurnal Riset Komputer)*, vol. 10, no. 2, pp. 640-647, 2023.
- [5] N. Z. A. A. Rahmah, R. Indarti, Z. M. A. Putra, E. Setiawan, and A. Z. Arfianto, "Implementasi Deteksi Kelengkapan APD pada Hazardous Area menggunakan Metode YoloV5," *Jurnal Elektronika dan Otomasi Industri*, vol. 11, no. 3, 2024.
- [6] A. Khairunnisa and N. A. K. DP, "Deteksi Penggunaan Safety Helmet Menggunakan YOLOv5," *JIEET (Journal of Information Engineering and Educational Technology)*, vol. 7, no. 2, pp. 74-77, 2023.
- [7] L. Suroiyah, Y. Rahmawati, and R. Dijaya, "Facemask Detection Using YOLO V5," *Jurnal Teknik Informatika (JUTIF)*, vol. 4, no. 6, pp. 1277-1286, 2023.
- [8] R. Rosalina, F. Bimantoro, and I. G. P. S. Wijaya, "Student Focus Detection Using You Only Look Once V5 (YOLOV5) Algorithm," *Jurnal Teknik Informatika (JUTIF)*, vol. 5, no. 5, pp. 1203-1211, 2024.
- [9] K. R. R. Wardani, N. Chrisandy, I. Martina, and H. Heryanto, "You Only Look Once v5 and Long Short-Term Memory Implementation for Crowd Anomaly Detection," *Jurnal Teknik Informatika (JUTIF)*, vol. 6, no. 2, pp. 951-964, 2025.
- [10] F. Afrialdy, R. S. Perdana, and C. Dewi, "Deteksi Objek Pada Framework Yolov5 dengan Penanganan Kesilauan Cahaya Menggunakan Gabungan Arsitektur U-Net dan Inpaint," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 12, no. 3, pp. 601-608, 2025.
- [11] H. N. Syifa and A. Nugroho, "Performance of the Yolov5 Algorithm to Detect Humans in the Rear Excavator Area," *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 10, no. 1, pp. 197-207, 2024.
- [12] J. Jonathan and D. Hermanto, "Penentuan Epochs Hasil Model Terbaik: Studi Kasus Algoritma YOLOv8," *Digital Transformation Technology (Digitech)*, vol. 4, no. 2, pp. 792-798, [Tahun Terbit Tidak Tertera].
- [13] M. Maulidiansyah and I. Abdillah, "Klasifikasi Jenis Jagung Berdasarkan Bentuk Biji Menggunakan Metode You Only Look Once (YOLO)," *JEECOM J. Electr. Eng. Comput.*, vol. 5, no. 2, pp. 215-226, 2023.
- [14] S. Saepudin, N. Sujana, M. M. Mutoffar, and A. A. Haryanto, "Analisis Kinerja YOLOv8 Optimalisasi Roboflow untuk Deteksi Ekspresi Wajah Emosional dengan Machine Learning," *Naratif: Jurnal Nasional Riset, Aplikasi dan Teknik Informatika*, vol. 6, no. 2, pp. 115-124, 2024.
- [15] R. Andarsyah and A. Yanuar, "Sentimen Analisis Aplikasi Posaja Pada Google Playstore Untuk Peningkatan Pospay Superapp Menggunakan Support Vector Meachine," *Jurnal Teknik Informatika*, vol. 16, no. 2, pp. 1-7, 2024.
- [16] U. Nepal and H. Eslamiat, "Comparing YOLOv3, YOLOv4 and YOLOv5 for autonomous landing spot detection in faulty UAVs," *Sensors*, vol. 22, no. 2, p. 464, 2022.
- [17] A. N. Tazkia, "Evaluasi Manajemen Alat Pelindung Diri (APD) Pada Area Produksi Sirup Sebagai Upaya Perlindungan Pekerja di Perusahaan Farmasi Sidoarjo," Doctoral dissertation, Universitas Airlangga, 2024.
- [18] K. Wilianto, "Evaluation Metrics pada Computer Vision dari Klasifikasi hingga Deteksi Objek," *Medium*, 2021. [Online]. Available: <https://medium.com/data-folks-indonesia/evaluation-metrics-pada-computer-vision-dari-klasifikasi-hingga-deteksi-objek-5049d3fd90d2>. [Accessed: 13-Mei-2026].

***Conflict of Interest Statement:***

*The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.*