

## Implementasi Model YOLO11 untuk Deteksi Alat Pelindung Diri Berbasis Citra Statis

<sup>1</sup>Tjoargen Christoper Redja, <sup>2</sup>Rini Mayasari, <sup>3</sup>Riza Ibnu Adam

<sup>1</sup>Program Studi Informatika, Universitas Singaperbangsa Karawang, Karawang

<sup>2</sup>Program Studi Informatika, Universitas Singaperbangsa Karawang, Karawang

<sup>3</sup>Program Studi Informatika, Universitas Singaperbangsa Karawang, Karawang

E-mail: <sup>1</sup>tjoargenchristoperredja653@gmail.com, <sup>2</sup>rini.mayasari@staff.unsika.ac.id, <sup>3</sup>riza.adam@staff.unsika.ac.id

### ABSTRAK

Penggunaan Alat Pelindung Diri (APD) merupakan kewajiban utama dalam menjamin keselamatan kerja, khususnya di lingkungan industri kimia seperti PT Mustika Dipa Lestari. Namun, sistem pengawasan APD yang masih dilakukan secara manual memiliki keterbatasan signifikan dalam konsistensi, efisiensi, dan jangkauan area kerja yang luas. Penelitian ini bertujuan untuk mengembangkan sistem deteksi otomatis menggunakan model YOLO11 (You Only Look Once versi 11) berbasis citra statis untuk mendeteksi penggunaan APD pada pekerja di lingkungan industri. Dataset terdiri dari 406 citra yang dikumpulkan langsung dari PT Mustika Dipa Lestari dengan objek APD mencakup bouffant cap, jas laboratorium, masker, dan sarung tangan. Data dibagi dengan rasio 70:20:10 untuk training, validation, dan testing. Anotasi dilakukan menggunakan platform Roboflow dan model dilatih menggunakan framework PyTorch dengan optimizer Adam selama 150 epoch. Evaluasi menggunakan metrik Mean Average Precision (mAP@50), mAP@0.5:0.95, precision, recall, dan F1-score. Hasil penelitian menunjukkan bahwa model YOLO11 mencapai performa optimal dengan mAP@50 sebesar 96,91%, mAP@0.5:0.95 sebesar 86,68%, precision sebesar 98,30%, recall sebesar 97,05%, dan F1-score sebesar 97,67%, melampaui target bisnis minimum 85%. Perbandingan dengan YOLOv4 (mAP@50 = 66,47%) dan YOLOv5 (mAP@50 = 95,75%) membuktikan keunggulan YOLO11 pada dataset domain spesifik industri kimia.

**Kata kunci :** YOLO11, Alat Pelindung Diri, Deteksi Objek, Computer Vision, Keselamatan Kerja, Deep Learning

### ABSTRACT

*The use of Personal Protective Equipment (PPE) is a fundamental requirement in ensuring workplace safety, especially in chemical industry environments such as PT Mustika Dipa Lestari. However, manual PPE monitoring systems have significant limitations in consistency, efficiency, and coverage of large work areas. This research aims to develop an automatic detection system using the YOLO11 (You Only Look Once version 11) model based on static images to detect PPE usage among workers in industrial environments. The dataset consists of 406 images collected directly from PT Mustika Dipa Lestari with PPE objects including bouffant caps, laboratory coats, masks, and gloves. Data is divided with a 70:20:10 ratio for training, validation, and testing. Annotation was conducted using the Roboflow platform and the model was trained using the PyTorch framework with Adam optimizer over 150 epochs. Evaluation uses Mean Average Precision (mAP@50), mAP@0.5:0.95, precision, recall, and F1-score metrics. Results show that YOLO11 achieves optimal performance with mAP@50 of 96.91%, mAP@0.5:0.95 of 86.68%,*

*precision of 98.30%, recall of 97.05%, and F1-score of 97.67%, surpassing the minimum business target of 85%. Comparison with YOLOv4 (mAP@50 = 66.47%) and YOLOv5 (mAP@50 = 95.75%) demonstrates YOLO11's superiority on a specialized chemical industry domain dataset.*

**Keyword :** YOLO11, Personal Protective Equipment, Object Detection, Computer Vision, Workplace Safety, Deep Learning

## 1. PENDAHULUAN

PT Mustika Dipa Lestari merupakan perusahaan yang bergerak di bidang industri bahan baku kimia dan distribusi yang berlokasi di Karawang, Jawa Barat. Aktivitas operasional perusahaan ini melibatkan penanganan senyawa-senyawa kimia berbahaya seperti bahan korosif, toksik, dan mudah terbakar, sehingga memiliki tingkat risiko kerja yang cukup tinggi. Berdasarkan pengamatan dan wawancara dengan bagian Health, Safety, and Environment (HSE), sistem pengawasan APD saat ini masih mengandalkan mekanisme patroli manual yang dilakukan oleh seorang petugas dengan frekuensi sekitar dua hingga tiga kali per shift kerja.

Pengawasan manual memiliki keterbatasan signifikan dalam hal jangkauan, konsistensi, dan dokumentasi data. Dengan hanya satu pengawas untuk seluruh area produksi yang luas, terdapat celah waktu di mana pelanggaran penggunaan APD tidak terdeteksi. Data pelanggaran yang dicatat secara manual pun rentan terhadap underreporting. Berdasarkan laporan BPJS Ketenagakerjaan, kasus kecelakaan kerja di Indonesia meningkat dari 221.740 kasus pada tahun 2020 menjadi 265.334 kasus pada tahun 2022. Kondisi ini memperkuat urgensi penerapan sistem pengawasan berbasis teknologi.

Perkembangan teknologi computer vision, khususnya algoritma deteksi objek real-time seperti YOLO, menawarkan peluang untuk pengembangan sistem

otomatis yang dapat mendeteksi penggunaan APD secara kontinu dan akurat. YOLO11, sebagai generasi terbaru keluarga algoritma YOLO yang dikembangkan oleh Ultralytics, mengintegrasikan teknik-teknik inovatif seperti blok C3K2, SPPF, dan mekanisme perhatian C2PSA, yang membuatnya sangat sesuai untuk aplikasi real-time dengan efisiensi komputasi tinggi (Ultralytics, 2025).

Perkembangan teknologi computer vision, khususnya algoritma deteksi objek real-time seperti YOLO, menawarkan peluang untuk pengembangan sistem otomatis yang dapat mendeteksi penggunaan APD secara kontinu dan akurat. YOLO11, sebagai generasi terbaru keluarga algoritma YOLO yang dikembangkan oleh Ultralytics, mengintegrasikan teknik-teknik inovatif seperti blok C3K2, SPPF, dan mekanisme perhatian C2PSA, yang membuatnya sangat sesuai untuk aplikasi real-time dengan efisiensi komputasi tinggi (Ultralytics, 2025).

## 2. LANDASAN TEORI

### Alat Pelindung Diri (APD)

Menurut WHO, Alat Pelindung Diri atau Personal Protective Equipment merupakan peralatan yang digunakan untuk melindungi pekerja dari bahaya biologis, kimia, listrik, mekanis, dan lain-lain. Berdasarkan PERMENAKER No. 8 Tahun 2010, jenis APD yang diakui meliputi pelindung kepala, pelindung mata dan muka, pelindung telinga, pelindung pernapasan, pelindung tangan,

pelindung kaki, dan pakaian pelindung. Dalam penelitian ini, APD yang menjadi fokus adalah bouffant cap, jas laboratorium, masker, dan sarung tangan, sebagaimana digunakan secara wajib oleh pekerja di lingkungan produksi kimia PT Mustika Dipa Lestari.

### Citra Digital dan Preprocessing

Menurut Gonzalez dan Woods (2018), citra dapat didefinisikan sebagai fungsi dua dimensi  $f(x, y)$  di mana  $x$  dan  $y$  adalah koordinat spasial, dan amplitudo  $f$  pada setiap titik koordinat disebut intensitas atau gray level dari citra tersebut. Citra digital terdiri dari elemen diskret yang disebut piksel, di mana setiap piksel memiliki nilai intensitas pada rentang 0 sampai 255 untuk citra 8-bit. Preprocessing citra dalam penelitian ini mencakup standarisasi format JPG dengan model warna RGB, serta resize otomatis ke resolusi 640×640 piksel sesuai standar input YOLO11.

### Model YOLO11

YOLO11 (You Only Look Once versi 11) adalah model deteksi objek real-time yang dikembangkan oleh Ultralytics sebagai bagian dari keluarga algoritma YOLO. Model ini menggunakan pendekatan one-stage detector yang melakukan deteksi objek secara langsung dalam satu proses inferensi. YOLO11 memiliki arsitektur yang ditingkatkan dengan komponen blok C3K2 untuk ekstraksi fitur multi-skala, SPPF (Spatial Pyramid Pooling Fast) untuk agregasi konteks fitur, dan mekanisme perhatian C2PSA (Cross-Stage Parcel with Position Sensitive Attention) yang meningkatkan kemampuan deteksi objek kecil (Ultralytics, 2025). Berbeda dari YOLOv4 dan YOLOv5 yang bersifat anchor-based, YOLO11 mengadopsi paradigma anchor-free yang lebih adaptif terhadap variasi ukuran dan posisi objek.

### CRISP-DM

CRISP-DM (Cross Industry Standard Process for Data Mining) adalah metodologi standar untuk proyek data mining yang terdiri dari enam fase: business understanding, data understanding, data preparation, modeling, evaluation, dan deployment. Metodologi ini dipilih dalam penelitian ini karena memberikan alur kerja yang sistematis, fleksibel, dan dapat diterapkan secara iteratif untuk membangun dan mengevaluasi model machine learning (Dicoding, 2024).

### Deep Learning dan Metrik Evaluasi

Menurut IBM (2024), Deep Learning merupakan cabang dari Machine Learning yang menggunakan beberapa lapisan deep neural networks untuk mensimulasikan cara manusia berpikir. Metrik evaluasi yang digunakan dalam penelitian ini meliputi:

- Precision =  $TP/(TP+FP)$ , yang mengukur proporsi prediksi positif yang benar
- Recall =  $TP/(TP+FN)$ , yang mengukur kemampuan model menemukan seluruh objek positif
- F1-Score sebagai harmonic mean antara precision dan recall
- Intersection over Union (IoU) yang mengukur tingkat overlapping antara bounding box prediksi dan ground truth
- mAP@0.5 dan mAP@0.5:0.95 sebagai metrik utama evaluasi deteksi objek (Padilla et al., 2021; Lin et al., 2014).

### Penelitian Sebelumnya

Tabel 1. Perbandingan Penelitian Sebelumnya di Bidang Deteksi APD

| No | Peneliti               | Metode | Hasil                                             |
|----|------------------------|--------|---------------------------------------------------|
|    | Sukriadi et al. (2025) | YOLOv3 | Akurasi 97%, sensitif terhadap pencahayaan rendah |

|  |                               |                  |                                 |
|--|-------------------------------|------------------|---------------------------------|
|  | Nababan & Armono (2025)       | CNN (TensorFlow) | Akurasi 88%, hanya 2 kelas APD  |
|  | Pusparina & Rahmade wi (2025) | YOLOv8           | mAP 85–87%, dataset publik      |
|  | Samperante et al. (2025)      | YOLOv8 Streamlit | mAP50 = 77,9%                   |
|  | Swandaru (2025)               | YOLOv8 + TF.js   | Akurasi tinggi berbasis browser |

### 3. METODOLOGI

Penelitian ini menggunakan metodologi CRISP-DM dan berfokus pada pengembangan model deteksi APD berbasis algoritma YOLO11. Objek penelitian adalah model pendeteksi APD berbasis computer vision menggunakan citra statis yang dikumpulkan dari lingkungan produksi PT Mustika Dipa Lestari. Kelas APD yang dideteksi dibatasi pada: bouffant cap, jas laboratorium, masker, dan sarung tangan.

#### Business Understanding

Pada tahap ini, dilakukan identifikasi permasalahan pengawasan APD yang masih manual dengan frekuensi hanya 2–3 kali per shift. Target keberhasilan ditetapkan berdasarkan dua dimensi: secara teknis, model harus mencapai mAP@50 minimal 85%; secara bisnis, model harus mampu mendeteksi keempat jenis APD yang relevan secara akurat. Target 85% dipilih berdasarkan analisis penelitian sebelumnya yang menunjukkan rentang performa 77%–97% untuk sistem deteksi APD berbasis deep learning.

#### Data Understanding

Dataset awal terdiri dari 415 citra yang dikumpulkan menggunakan smartphone Xiaomi Redmi Note 10 Pro (108 MP) selama satu minggu di bulan Maret 2026. Setelah melalui proses penyaringan kualitas, diperoleh 406 citra yang layak digunakan, mengandung total

1.806 objek APD. Distribusi per kelas adalah: bouffant cap 388 objek (21,48%), jas laboratorium 409 objek (22,65%), masker 361 objek (19,99%), dan sarung tangan 648 objek (35,88%). Distribusi yang relatif merata mengindikasikan tidak adanya class imbalance yang signifikan.

#### Data Preparation

Seluruh citra distandarisasi ke dalam format JPG dengan model warna RGB. Anotasi dilakukan secara manual menggunakan platform Roboflow dengan membuat bounding box pada setiap objek APD. Dataset kemudian dibagi dengan rasio 70:20:10 menjadi 284 citra data latih (1.262 objek), 81 citra data validasi (362 objek), dan 41 citra data uji (182 objek). Pemilihan rasio ini didasarkan pada penelitian Vrskova et al. (2023) yang membuktikan efektivitasnya dalam meminimalkan risiko overfitting dan data leakage bias.

#### Modelling

Model dikembangkan menggunakan framework Ultralytics YOLO11 berbasis PyTorch melalui Google Colab dengan akselerasi GPU NVIDIA T4. Varian YOLO11 nano (yolo11n.pt) dipilih untuk efisiensi komputasi. Parameter pelatihan disajikan pada Tabel 2.

Tabel 2. Konfigurasi Hyperparameter Pelatihan

| Parameter                 | Nilai                                      |
|---------------------------|--------------------------------------------|
| Varian Model              | yolo11n.pt (Nano)                          |
| Epochs                    | 150                                        |
| Batch Size                | 4                                          |
| Optimizer                 | Adam                                       |
| Learning Rate Awal (lr0)  | 0.001                                      |
| Learning Rate Akhir (lrf) | 0.01                                       |
| Weight Decay              | 0.0005                                     |
| Early Stop Patience       | 30 epoch                                   |
| Ukuran Input              | 640 × 640 piksel                           |
| Augmentasi                | Mosaic, FlipLR, HSV, Rotasi ±5°, Scale 0.3 |
| Device                    | GPU NVIDIA T4 (Google Colab)               |

Optimizer Adam dipilih karena karakteristik citra APD industri memiliki tingkat kerapatan gradien yang bervariasi, dan Adam secara adaptif menghitung laju pembelajaran individual untuk setiap parameter dengan mengombinasikan prinsip Momentum dan RMSProp (Kingma & Ba, 2015). Augmentasi dilakukan secara on-the-fly oleh Ultralytics, menghasilkan total  $284 \times 150 = 42.600$  sampel augmentasi unik sepanjang pelatihan. Mekanisme early stopping dengan patience 30 epoch diterapkan untuk mencegah overfitting. Sebagai model pembandingan, YOLOv4 dan YOLOv5 juga dilatih pada dataset yang identik selama 150 epoch. YOLOv4 menggunakan framework Darknet dengan ukuran input  $416 \times 416$  piksel dan optimizer SGD, sedangkan YOLOv5 menggunakan Ultralytics/PyTorch dengan ukuran input  $640 \times 640$  piksel dan optimizer Adam.

### Evaluation

Evaluasi dilakukan pada data uji (41 citra, 182 objek) menggunakan model terbaik (best.pt) dengan confidence threshold 0,25 dan IoU threshold 0,45. Metrik yang digunakan meliputi mAP@50, mAP@50:95, Precision, Recall, dan F1-Score. Precision dipilih karena tingkat false positive yang tinggi dapat mengurangi kepercayaan operator sistem, sedangkan Recall penting karena false negative berpotensi menimbulkan bahaya langsung di lingkungan kerja kimia.

## 4. HASIL DAN PEMBAHASAN

Kurva pelatihan YOLO11 menunjukkan konvergensi yang cepat dan stabil. Nilai mAP@0.5 pada data validasi sudah melampaui 0,90 pada epoch ke-5 dan terus meningkat hingga mendekati 0,96 pada akhir epoch ke-150. Box Loss, Classification Loss, dan DFL Loss untuk data latih maupun validasi menunjukkan penurunan yang konsisten tanpa divergensi, mengindikasikan tidak adanya

overfitting meskipun menggunakan dataset berukuran kecil (406 citra).

YOLOv4 menunjukkan karakteristik pelatihan yang tidak stabil dengan validation loss yang sempat melonjak hingga 2,1 pada epoch ke-12 hingga ke-17. Precision model YOLOv4 sangat fluktuatif antara 0,05 hingga 0,49, dan nilai mAP@0.5 hanya mencapai 0,67 di akhir 150 epoch. Ketidakstabilan ini disebabkan oleh konfigurasi anchor box yang masih menggunakan standar COCO dan tidak disesuaikan dengan proporsi objek APD dalam dataset penelitian. Sebaliknya, YOLOv5 menampilkan perilaku pelatihan yang jauh lebih stabil, dengan mAP@0.5 mencapai 0,95 pada akhir pelatihan, namun memerlukan sekitar 70–80 epoch untuk mencapai plateau.

### Hasil Evaluasi Model YOLO11

Tabel 3. Hasil Evaluasi Keseluruhan Model YOLO11 pada Data Uji

| Metrik Evaluasi | Hasil  |
|-----------------|--------|
| mAP@50          | 96,91% |
| mAP@50:95       | 86,68% |
| Precision       | 98,30% |
| Recall          | 97,05% |
| F1-Score        | 97,67% |

Model YOLO11 berhasil mencapai mAP@50 sebesar 96,91%, melampaui target penelitian 85% sebesar 11,91 poin persentase. Precision 98,30% menunjukkan tingkat false positive yang sangat rendah, sementara Recall 97,05% menunjukkan kemampuan model yang sangat baik dalam menemukan hampir seluruh objek APD dalam citra. F1-Score 97,67% mengindikasikan keseimbangan yang sangat baik antara precision dan recall.

Tabel 4. Hasil AP@50 Per Kelas APD

| Kelas APD        | AP@50  |
|------------------|--------|
| Bouffant Cap     | 99,50% |
| Jas Laboratorium | 99,50% |
| Masker           | 97,24% |
| Sarung Tangan    | 91,39% |

|                    |        |
|--------------------|--------|
| Rata-rata (mAP@50) | 96,91% |
| F1-Score           | 97,67% |

Analisis AP@50 Per Kelas menunjukkan bouffant cap dan jas laboratorium mencapai AP@50 99,50% berkat karakteristik visual yang khas dan konsisten (warna dan bentuk yang mudah dibedakan dari latar belakang). Masker memiliki AP@50 97,24%, sedikit lebih rendah akibat ukurannya yang relatif kecil dalam citra dan posisinya yang berdekatan dengan fitur wajah lain. Sarung tangan memiliki AP@50 terendah (91,39%) karena variasi posisi dan orientasi gerakan tangan yang dinamis, serta efek dua bounding box per pekerja yang meningkatkan kompleksitas deteksi.

### Perbandingan Ketiga Model

Tabel 5. Perbandingan Metrik Final Ketiga Model pada Dataset APD

| Metrik       | YOL<br>Ov4 | YOL<br>Ov5 | YOL<br>O11 | Selisi<br>h<br>(v11<br>deng<br>an<br>v4) | Selisi<br>h<br>(v11<br>deng<br>an<br>v5) |
|--------------|------------|------------|------------|------------------------------------------|------------------------------------------|
| Precision    | 28,3<br>8% | 97,8<br>7% | 96,2<br>5% | +67,<br>87%                              | -1,6<br>2%                               |
| Recall       | 71,6<br>8% | 92,9<br>6% | 94,1<br>2% | +22,<br>44%                              | +1,1<br>6%                               |
| mAP@0.5      | 66,4<br>7% | 95,7<br>5% | 96,0<br>1% | +29,<br>54%                              | +0,2<br>6%                               |
| mAP@0.5:0.95 | 34,2<br>7% | 76,8<br>6% | 84,5<br>9% | +50,<br>32%                              | +7,7<br>3%                               |

Perbandingan kuantitatif mengkonfirmasi bahwa YOLOv4 menunjukkan performa paling rendah, khususnya pada Precision (hanya 28,38%), yang disebabkan oleh ketergantungannya pada pendekatan *anchor-based* yang kurang optimal untuk distribusi objek APD pada dataset ini. YOLO11 mengungguli YOLOv5 terutama pada mAP@0.5:0.95 (+7,73 poin), mengindikasikan presisi lokalisasi bounding box yang secara geometris lebih akurat. Selain itu, YOLO11 mencapai mAP@0.5 di atas 0,90 hanya dalam 5 epoch pertama, tiga hingga empat kali lebih cepat dibandingkan YOLOv5 yang membutuhkan 70–80 epoch.

### Perbandingan dengan Penelitian Sebelumnya

Tabel 6. Perbandingan Hasil dengan Penelitian Sebelumnya

| Peneliti                     | Metode       | Jenis APD       | Performa Terbaik | Keterbatasan                |
|------------------------------|--------------|-----------------|------------------|-----------------------------|
| Sukriadi et al. (2025)       | YOLOv3       | Masker          | Akurasi 97%      | Sensitif pencahayaan rendah |
| Nababan & Armono (2025)      | CNN          | Pakaian safety  | Akurasi 88%      | 2 kelas, tanpa mAP          |
| Puspawati & Rahmadewi (2025) | YOLOv8       | APD konstruksi  | mAP 85–87%       | Dataset publik              |
| Sampe et al. (2025)          | YOLOv8       | APD konstruksi  | mAP 50,77,9%     | Terbatas helm               |
| Swandaru (2025)              | YOLOv8+TF.js | 8 jenis APD     | Akurasi tinggi   | Tanpa rincian mAP           |
| Penelitian ini               | YOLO11n      | 4 jenis APD lab | mAP@50 = 96,91%  | 1 lokasi, 406 citra         |

Penelitian ini menghasilkan nilai mAP@50 tertinggi (96,91%) dibandingkan seluruh penelitian yang dibandingkan. Keunggulan ini didukung oleh penggunaan YOLO11 yang memanfaatkan teknik *anchor-free detection*, blok C3K2 untuk ekstraksi fitur multi-skala, dan mekanisme C2PSA yang meningkatkan sensitivitas terhadap objek APD berukuran kecil. Namun, perlu dicatat bahwa setiap penelitian menggunakan dataset yang berbeda, sehingga perbandingan langsung memiliki keterbatasan dan cenderung tidak konsisten.

## 5. KESIMPULAN

Penelitian ini berhasil mengembangkan model deteksi APD berbasis YOLO11 nano (yolo11n) menggunakan dataset non-publik 406 citra dari PT Mustika Dipa Lestari dengan metodologi CRISP-DM. Model mencapai mAP@50 sebesar 96,91%, precision 98,30%,

recall 97,05%, dan F1-Score 97,67%, melampaui target minimum 85% sebesar 11,91 poin persentase. Secara per kelas, bouffant cap dan jas laboratorium mencapai AP@50 99,50%, diikuti masker (97,24%) dan sarung tangan (91,39%).

Perbandingan dengan YOLOv4 (mAP@50 = 66,47%) dan YOLOv5 (mAP@50 = 95,75%) membuktikan keunggulan YOLO11 pada dataset domain spesifik industri kimia, baik dari segi akurasi maupun kecepatan konvergensi. YOLO11 mencapai plateau stabil pada epoch ke-5 hingga ke-20, tiga hingga empat kali lebih cepat dibandingkan YOLOv5. Penelitian selanjutnya disarankan untuk memperluas dataset (minimal 1.000–2.000 citra per kelas), menambah variasi kelas APD, mengeksplorasi varian YOLO11 yang lebih besar, dan mengintegrasikan model ke dalam sistem video real-time berbasis CCTV untuk implementasi pengawasan keselamatan kerja yang komprehensif.

## 6. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada PT Mustika Dipa Lestari atas izin pengumpulan data dan dukungan selama penelitian berlangsung, kepada Ibu Lia bagian purchasing selaku penanggungjawab lokasi produksi yang telah memberikan akses dan wawasan mengenai sistem pengawasan APD, serta kepada Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Singaperbangsa Karawang atas dukungan akademis yang diberikan.

## DAFTAR PUSTAKA

- Dicoding. (2024). Pengenalan CRISP-DM. Dicoding Academy.
- Gonzalez, R. C., & Woods, R. E. (2018). Digital Image Processing. Pearson.
- IBM. (2024). What is Deep Learning? IBM. <https://www.ibm.com/topics/deep-learning>.
- Jocher, G., et al. (2023). YOLO11 Documentation. Ultralytics. <https://docs.ultralytics.com/>.
- Kadir, A., & Susanto, A. (2013). Teori dan Aplikasi Pengolahan Citra. Yogyakarta: Penerbit Andi.
- Kementerian Tenaga Kerja dan Transmigrasi Republik Indonesia. (2010). Peraturan Menteri Tenaga Kerja dan Transmigrasi No. PER.08/MEN/VII/2010 Tentang Alat Pelindung Diri.
- Kingma, D. P., & Ba, J. L. (2015). Adam: A Method for Stochastic Optimization. Proceedings of ICLR. <https://arxiv.org/abs/1412.6980>.
- Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). Microsoft COCO: Common Objects in Context. Lecture Notes in Computer Science, 8693, 740–755. Springer. [https://doi.org/10.1007/978-3-319-10602-1\\_48](https://doi.org/10.1007/978-3-319-10602-1_48).
- Nababan, D. C., & Armono, S. A. (2025). Penerapan klasifikasi citra pada identifikasi objek dengan pakaian safety menggunakan CNN di PT Jayatama Safetindo. Jurnal Comasie.
- Padilla, R., Passos, W. L., Dias, T. L. B., Netto, S. L., & da Silva, E. A. B. (2021). A comparative analysis of object detection metrics with a companion open-source toolkit. Electronics, 10(3), 279. <https://doi.org/10.3390/electronics10030279>.
- Pusparina, R., & Rahmadewi, R. (2025). Deteksi Objek Berbasis YOLOv8 untuk Mendukung Keselamatan Kerja di Lokasi Konstruksi. Jurnal Mahasiswa Teknik Informatika (JATI), 9(2).

- Rezatofighi, H., Tsoi, N., Gwak, J., Sadeghian, A., Reid, I., & Savarese, S. (2019). Generalized intersection over union. *Proceedings of CVPR 2019*. <https://doi.org/10.48550/arXiv.1902.09630>.
- Samperante, J., Putra, I. M. A. W., & Permana, P. A. G. (2025). Implementasi arsitektur YOLO v8 dalam mendeteksi APD di sektor konstruksi dan industri. *Prosiding SPINTER, Vol. 1, STIKOM Bali*.
- Sukriadi, H., Gani, H., & Yuyun. (2025). Deteksi pengguna masker berbasis pengolahan citra menggunakan algoritma YOLO. *Jurnal Ilmiah Sistem Informasi dan Teknik Informatika (JISTI)*, 8(1).
- Swandaru, A. (2025). Deteksi Penggunaan Alat Pelindung Diri (APD) Pada Pekerja Berbasis Web Browser Menggunakan YOLOv8 dan TensorFlow.js.
- Ultralytics. (2025). YOLO11. <https://docs.ultralytics.com/models/yolo11>. Diakses Juli 2026.
- Ultralytics. (2025). YOLOv5 vs YOLO11 Comparison. <https://docs.ultralytics.com/comparison/yolov5-vs-yolo11>. Diakses Juli 2026.
- Vrskova, R., Kamencay, P., Hudec, R., & Sykora, P. (2023). A New Deep-Learning Method for Human Activity Recognition. *Sensors*, 23, 2816. <https://doi.org/10.3390/s23052816>.
- World Health Organization. (2020). *Personal Protective Equipment (Laboratory Biosafety Manual, 4th ed.)*. WHO.
- Yamany, M. S., Ghozi, M. F., Khallaf, R., & Mohamed, H. A. E. (2025). Comparative Evaluation of YOLO Models for Real-Time Detection of Multiple Construction Resources. *Buildings*, 16(13), 2565. <https://doi.org/10.3390/buildings16132565>.