



DETEKSI PEROKOK MENGGUNAKAN ALGORITMA YOU ONLY LOOK ONCE (YOLO) DAN CONVOLUTIONAL NEURAL NETWORK (CNN)

Aprilian Gevindo¹, Syafri Arlis²

^{1,2} Teknik Informatika, Universitas Putra Indonesia YPTK
 Padang, Sumatera Barat, Indonesia 25145
 liando1801@gmail.com, syafri_arlis@upiyptk.ac.id

Abstract

Image processing technology continues to advance and is widely used for visual identification of human activities, including monitoring smoking behavior in no-smoking areas. This study develops an automated smoking activity detection and recognition system based on digital image processing, combining YOLO (You Only Look Once) for object detection and a CNN (Convolutional Neural Network) as an image classifier. YOLO detects and crops human objects, while the CNN classifies smoking and non-smoking activities based on visual features. The preprocessed dataset contains 560 valid images per class (smoking and not smoking). Training results show 96.09% accuracy on the training set and 94.44% on the validation set, with stable loss, while model evaluation yields 94.44% accuracy, 92.55% precision, 96.67% recall, 94.57% F1-score, and Average Precision (AP), indicating excellent classification performance. The model can also detect smoking activities in real-time images and camera feeds, demonstrating the effectiveness of combining YOLO and a CNN for automated detection, with potential applications in no-smoking areas.

Keywords: CNN, Digital Image Processing, Human Activity Recognition, Smoking Activity Detection, YOLO

Abstrak

Teknologi pengolahan citra terus berkembang dan dimanfaatkan untuk identifikasi aktivitas manusia secara visual, termasuk pemantauan aktivitas merokok di kawasan tanpa rokok. Penelitian ini mengembangkan deteksi dan pengenalan aktivitas merokok dengan menggabungkan YOLO (*You Only Look Once*) untuk pendeteksian objek dan CNN (*Convolutional Neural Network*) sebagai pengklasifikasi citra. YOLO melakukan deteksi dan *cropping* objek manusia, sedangkan CNN mengklasifikasikan aktivitas merokok dan tidak merokok berdasarkan ciri visual. *Dataset* berjumlah 3.254 yang telah diproses menghasilkan masing-masing 560 citra *valid* untuk kelas *smoking* dan *not smoking*. Hasil pelatihan menunjukkan akurasi 96,09% pada data latih dan 94,44% pada data validasi, dengan *loss* yang stabil, serta evaluasi model menghasilkan *accuracy* 94,44%, *precision* 92,55%, *recall* 96,67%, *F1-score* 94,57%, dan *Average Precision* (AP) 98,72%, menunjukkan performa klasifikasi yang sangat baik. Model juga mampu mendeteksi aktivitas merokok secara responsif pada citra dan kamera *real-time*, membuktikan efektivitas kombinasi YOLO dan CNN dalam membangun deteksi otomatis dan berpotensi diterapkan di kawasan tanpa rokok.

Kata kunci: CNN, Deteksi Aktivitas Merokok, Pengolahan Citra Digital, Pengenalan Aktivitas Manusia, YOLO

1. PENDAHULUAN

Teknologi pengolahan citra terus berkembang dan menarik perhatian banyak pihak untuk dieksplorasi lebih jauh [1]. Berbagai aplikasi visi komputer telah memanfaatkan deteksi sebagai alat utama untuk mengekstraksi informasi secara otomatis [2]. Salah satu potensi penerapan teknologi ini adalah dalam mengidentifikasi aktivitas manusia secara visual sebagai upaya pemantauan dan pencegahan [3].

Merokok menjadi kebiasaan umum yang masih sering dijumpai dalam kehidupan sehari-hari di berbagai negara,

termasuk Indonesia [4]. Walaupun banyak orang telah memahami dampak buruk dari merokok, perilaku ini tetap melekat kuat dalam budaya masyarakat dan sulit untuk dihilangkan [5]. Selain sebagai kebiasaan, aktivitas merokok juga sering diasosiasikan dengan gaya hidup tertentu [6]. Suatu konsep sistem deteksi menjadi sebuah solusi dalam menangani masalah tersebut [7].

Studi sebelumnya yang dilakukan oleh Wynne dkk. [8], membahas pentingnya penerapan kebijakan kawasan bebas asap rokok sebagai upaya untuk mengurangi paparan asap

rokok bagi masyarakat. Penelitian tersebut menekankan bahwa keberhasilan penerapan kebijakan tersebut sangat bergantung pada tingkat kesadaran masyarakat serta mekanisme penegakan aturan yang efektif. Tingkat kepatuhan yang masih bervariasi menunjukkan bahwa upaya pengawasan dan pemantauan terhadap aktivitas merokok di area tertentu masih perlu ditingkatkan. Kondisi tersebut membuka peluang pemanfaatan teknologi sebagai sarana untuk membantu proses pemantauan secara lebih efektif dan berkelanjutan.

Salah satu bentuk representasi visual dari dunia nyata yaitu citra digital [9]. Citra digital merupakan gambaran representasi visual dunia nyata dalam bentuk digital yang dapat dianalisis dan diproses oleh komputer [10]. Citra dapat dikatakan pula sebagai sebuah gambar, foto yang ditampilkan atau bentuk lain yang memberikan representasi visual tentang sebuah objek atau pemandangan [11]. Bidang pengolahan citra digital menitikberatkan pada pengembangan teknik untuk mengolah dan menganalisis informasi visual dari citra [12]. Beberapa tahun terakhir, teknologi ini menunjukkan peran yang semakin luas dalam mendukung berbagai sektor [13].

Kajian sebelumnya yang dilakukan oleh Cho dkk. [14], mengkaji sistem deteksi aktivitas merokok di dalam ruangan dengan memanfaatkan sensor *Internet of Things* (IoT) untuk mendeteksi gas yang dihasilkan dari asap rokok seperti karbon dioksida (CO_2) dan total *volatile organic compounds* (TVOC). Data yang diperoleh dari sensor tersebut kemudian dianalisis menggunakan pendekatan *machine learning* dan *deep learning* untuk mengklasifikasikan kondisi lingkungan apakah terdapat aktivitas merokok menunjukkan bahwa metode *Support Vector Machine* (SVM) memberikan performa terbaik dengan tingkat akurasi mencapai sekitar 93% dan nilai *F1-score* sebesar 88% dalam proses klasifikasi. Model lain seperti *K-Nearest Neighbors* (KNN) dan *Multilayer Perceptron* (MLP) juga mampu melakukan prediksi dengan cukup baik, namun memiliki keterbatasan dalam hal kecepatan dan efisiensi pemrosesan data. Pendekatan berbasis sensor gas tersebut memiliki kelemahan karena sangat bergantung pada kondisi lingkungan, seperti ventilasi ruangan, konsentrasi gas lain, serta kemungkinan terjadinya *overfitting* pada model apabila data pelatihan tidak cukup beragam.

YOLO (*You Only Look Once*) termasuk metode deteksi objek yang mengandalkan jaringan konvolusional tunggal dalam memprediksi letak objek dalam citra [15]. Melalui pendekatan model terpadu, YOLO memanfaatkan satu jaringan saraf untuk menghasilkan prediksi kotak pembatas dan probabilitas kelas dalam satu proses terhadap keseluruhan gambar [16]. YOLO merupakan deteksi objek tipe *one-stage detector* yang tidak memerlukan tahap pemilihan wilayah secara eksplisit [17]. Mekanisme kerja YOLO melibatkan pemberian beberapa kotak pembatas serta nilai keyakinan guna menentukan keberadaan objek [18].

Penelitian sebelumnya yang dilakukan oleh Guarnido-Lopez dkk. [19], mengkaji penerapan algoritma YOLO untuk mendeteksi perilaku hewan ternak melalui analisis citra *video*. Penelitian tersebut membandingkan performa dua versi algoritma YOLO, yaitu *YOLOv8*, dalam mendeteksi aktivitas makan sapi seperti *biting*, *chewing*, dan *visiting* pada area pakan. Proses pelatihan model dilakukan menggunakan *dataset* citra yang diperoleh dari rekaman *video* di peternakan dan dievaluasi menggunakan beberapa metrik performa seperti *precision*, *recall*, *Average Precision* (AP), serta *F1-score*. Hasil penelitian menunjukkan bahwa model mampu mendeteksi aktivitas dengan akurasi yang cukup tinggi, bahkan mencapai sekitar 91% dalam pengenalan beberapa aktivitas makan pada sapi. Model *YOLOv8* menunjukkan performa yang baik sisi *precision* dan *recall*, serta memiliki konsistensi prediksi yang lebih stabil pada berbagai kondisi pengamatan. Keterbatasan penelitian ini terletak pada kebutuhan *dataset* citra yang cukup besar serta proses pelatihan yang memerlukan sumber daya komputasi yang tinggi. Kondisi lingkungan seperti pencahayaan, sudut kamera, dan pergerakan objek juga dapat mempengaruhi akurasi deteksi sehingga berpotensi menyebabkan kesalahan klasifikasi atau *overfitting* apabila model tidak dilatih dengan data yang beragam.

Algoritma *Convolutional Neural Networks* (CNN) juga termasuk dalam pendekatan yang kuat dalam pengenalan pola pada data citra [20]. Salah satu kekuatan CNN terletak pada kemampuannya mengidentifikasi pola visual yang kompleks dan beragam [21]. Desain CNN terinspirasi dari sistem visual pada otak manusia, di mana fitur citra diekstraksi secara bertingkat dan berurutan [22]. Konvolusi bekerja dengan prinsip *sliding window* dan *weight sharing* [23]. Proses ini menerapkan fungsi *output* sebagai *feature map* dari *input* suatu citra [24].

Penelitian yang dilakukan oleh Uddin dkk. [25], mengkaji deteksi aktivitas merokok menggunakan metode CNN berbasis citra. Model yang dikembangkan dilatih menggunakan *dataset* citra aktivitas merokok dan tidak merokok dengan fungsi *binary cross-entropy* serta optimasi *stochastic gradient descent* untuk proses klasifikasi. Hasil pengujian menunjukkan model mampu mencapai akurasi sebesar 89.51%, namun pendekatan ini memiliki keterbatasan karena memerlukan *dataset* citra yang cukup besar dan berpotensi mengalami *overfitting* apabila variasi data pelatihan tidak beragam.


Berdasarkan uraian permasalahan dan penelitian sebelumnya, penelitian ini bertujuan untuk mengembangkan sistem deteksi aktivitas merokok berbasis pengolahan citra menggunakan algoritma YOLO dan CNN. Sistem yang dikembangkan diharapkan mampu mendeteksi keberadaan objek rokok maupun aktivitas merokok pada citra atau *video* secara otomatis. Pendekatan ini memanfaatkan kemampuan YOLO dalam melakukan deteksi objek secara cepat serta kemampuan CNN dalam

mengenali pola visual pada citra. Hasil dari penelitian ini dapat menjadi salah satu alternatif solusi dalam membantu proses pemantauan aktivitas merokok secara lebih efektif.

Kontribusi penelitian ini terletak pada penerapan kombinasi algoritma YOLO dan CNN untuk mendeteksi aktivitas merokok berbasis citra digital. Pendekatan ini diharapkan mampu meningkatkan kemampuan sistem dalam mengenali objek rokok maupun perilaku merokok secara lebih akurat dibandingkan metode deteksi konvensional. Penelitian ini juga memberikan kontribusi dalam pengembangan sistem pemantauan berbasis visi komputer yang dapat dimanfaatkan sebagai alat bantu dalam mendukung penerapan kawasan bebas asap rokok.

2. METODE PENELITIAN

Metode penelitian ini disusun untuk menggambarkan tahapan-tahapan yang dilakukan dalam proses penelitian, mulai dari pengumpulan data hingga evaluasi hasil [26]. Setiap tahapan dirancang secara sistematis agar tujuan penelitian dapat tercapai dengan baik, seperti yang ditunjukkan pada Gambar 1 berikut:



Gambar 1. Metode Penelitian

Gambar 1 tersebut menunjukkan alur pelaksanaan penelitian yang mencakup langkah-langkah utama yang

ditempuh selama proses penelitian. Mengikuti alur tersebut, diharapkan proses penelitian menjadi lebih terarah. Oleh sebab itu, penelitian ini menggunakan konsep terarah seperti Gambar 1 atas.

2.1 Tahapan Penelitian

2.1.1 Identifikasi Masalah

Aktivitas merokok di ruangan atau area yang telah ditetapkan sebagai Kawasan Tanpa Rokok (KTR) masih sering terjadi dan sulit diawasi secara optimal, terutama di tempat umum seperti kantor, rumah sakit, terminal, atau ruang tertutup lainnya [27]. Pengawasan manual oleh petugas tidak selalu efektif karena keterbatasan waktu, tenaga, dan cakupan area yang luas. Hal ini menimbulkan permasalahan serius, terutama terkait dengan kesehatan publik dan pelanggaran terhadap peraturan daerah atau institusi. Oleh karena itu, dibutuhkan suatu sistem otomatis berbasis teknologi visi komputer yang mampu mendeteksi dan mengenali keberadaan seorang perokok secara *real-time*. Pemanfaatan algoritma YOLO untuk deteksi objek dan CNN untuk klasifikasi gambar menjadi pendekatan yang potensial dalam membangun sistem deteksi pelanggaran merokok di area terlarang secara efektif dan efisien.

2.1.2 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini diperoleh dari sumber *dataset* terbuka di *internet*. *Dataset* yang digunakan yaitu total sebanyak 3.254 gambar dengan ukuran piksel yang beragam. Data bersumber dari *platform Kaggle* pada tautan berikut.

2.1.3 Analisa Data

Analisis data dalam penelitian ini bertujuan untuk mengembangkan sistem deteksi dan pengenalan aktivitas merokok dengan menggabungkan algoritma YOLO untuk mendeteksi objek dan CNN untuk melakukan klasifikasi citra. Proses dimulai dari pengolahan citra *input* melalui tahap pra-pemrosesan, dilanjutkan dengan ekstraksi fitur menggunakan CNN, serta identifikasi objek rokok atau perokok menggunakan YOLO. Seluruh data dianalisis dengan membandingkan pola visual antara kelas *Smoking* dan *Not Smoking* guna membentuk model pembelajaran yang mampu mengenali karakteristik khas dari masing-masing kelas. Analisis ini menjadi dasar dalam membangun arsitektur model dan merancang strategi pelatihan yang sesuai untuk mencapai performa sistem yang optimal.

Proses analisis data juga melibatkan penerapan teknik *data augmentation* pada citra pelatihan. Teknik ini dilakukan dengan menghasilkan variasi citra baru melalui transformasi seperti rotasi, *flipping*, *zoom*, dan perubahan tingkat pencahayaan. Pendekatan ini bertujuan untuk meningkatkan jumlah variasi data pelatihan sehingga model dapat belajar mengenali pola objek dalam berbagai kondisi visual yang berbeda. Penerapan data *augmentation* juga membantu

meningkatkan kemampuan generalisasi model terhadap data baru. Model yang dilatih dengan variasi data yang lebih beragam cenderung memiliki performa yang lebih stabil ketika diterapkan pada kondisi nyata.

1) Algoritma YOLO

YOLO merupakan deteksi objek tipe *one-stage detector* yang tidak memerlukan tahap pemilihan wilayah secara eksplisit [28]. *Confidence score* menunjukkan kemungkinan keberadaan objek dalam *grid* tertentu, sedangkan koordinat dan ukuran menggambarkan posisi serta dimensi dari objek yang terdeteksi. Berikut persamaan rumus dari YOLO [29]:

a. Confidence Score

Confidence Score digunakan untuk menentukan tingkat keyakinan model terhadap keberadaan objek dan kelasnya yang dapat dihitung dengan Persamaan (1):

$$Confidence = P(object) \times P(Class) \dots \dots \dots (1)$$

Dimana:

$P(object)$ = Probabilitas adanya objek.

$P(Class)$ = Probabilitas kelas.

b. Bounding Box Area

Perhitungan luas *bounding box* digunakan untuk menentukan ukuran area objek yang terdeteksi melalui Persamaan (2):

$$Area = (x_2 - x_1) \times (y_2 - y_1) \dots \dots \dots (2)$$

Dimana:

x_1, y_1 = Koordinat kiri atas *bounding box*.

x_2, y_2 = Koordinat kanan bawah *bounding box*.

c. Rasio Luas Objek terhadap Citra

Rasio luas objek digunakan untuk menyaring objek yang terlalu kecil dalam gambar melalui Persamaan (3):

$$Ratio = \frac{Area_{Object}}{Area_{image}} \dots \dots \dots (3)$$

Dimana:

$Area_{object}$ = Luas *bounding box* objek.

$Area_{area}$ = Luas keseluruhan citra.

d. Laplacian Variance

Metode *laplacian variance* digunakan untuk mengukur tingkat ketajaman citra melalui Persamaan (4):

$$\delta^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \dots \dots \dots (4)$$

Dimana:

δ^2 = Variansi citra.

x_i = Nilai piksel ke-i setelah operasi Laplacian.

μ = Rata-rata nilai piksel.

N = Jumlah piksel.

e. Resize

Resize digunakan untuk menyeragamkan ukuran citra sebelum diproses lebih lanjut melalui Persamaan (5):

$$x^l = x \times \frac{W_{new}}{W_{old}}, y^l = y \times \frac{H_{new}}{H_{old}} \dots \dots \dots (5)$$

Dimana:

x, y = Koordinat awal.

x^l, y^l = Koordinat setelah *resize*.

W_{old}, H_{old} = Ukuran awal citra.

W_{new}, H_{new} = Ukuran citra setelah *resize*.

f. Intersection over Union

Intersection over Union (IoU) digunakan untuk mengukur tingkat *overlap* antara dua *bounding box* melalui Persamaan (6):

$$IoU = \frac{Area_{Overlap}}{Area_{Union}} \dots \dots \dots (6)$$

Dimana:

$Area_{Overlap}$ = Luas irisan dua *box*.

$Area_{Union}$ = Luas gabungan dua *box*.

g. Non-Max Suppression

Non-Max Suppression (NMS) digunakan untuk menghapus *bounding box* duplikat berdasarkan nilai IoU melalui Persamaan (7):

$$IoU(box_i, box_j) > threshold \rightarrow remove\ box_j \dots \dots (7)$$

Dimana:

box_i = Box dengan *confidence* tertinggi.

box_j = Box lain.

$threshold$ = Batas IoU.

Penelitian ini menggunakan algoritma YOLO versi YOLOv8 dengan model dasar YOLOv8n (*nano*). Model ini dipilih karena memiliki ukuran yang lebih ringan dan mampu melakukan proses deteksi objek dengan kecepatan tinggi. YOLO digunakan untuk mendeteksi objek manusia dan rokok pada citra sebelum dilakukan proses klasifikasi menggunakan CNN.

Proses deteksi dilakukan dengan menentukan *bounding box* pada area yang diprediksi mengandung objek target pada ukuran 224x224 piksel. Nilai *confidence threshold* sebesar 0.2 serta *padding* ukuran 0.15 digunakan untuk menentukan tingkat keyakinan deteksi objek. Area objek yang berhasil terdeteksi kemudian dipotong (*cropping*) untuk digunakan sebagai *input* pada proses klasifikasi menggunakan CNN.

2) Algoritma CNN

Convolutional Neural Network (CNN) dikategorikan dalam *deep learning* karena aplikasinya yang luas dalam memproses data gambar [30]. CNN memiliki desain beberapa arsitektur yang dapat dipelajari. *Feature map* adalah keluaran yang digunakan sebagai *input* dan *output* dari setiap langkah. Berikut konsep dari metode CNN [23]:

a. Convolutional Layer

Lapisan *Convolutional* merupakan tahap awal dalam arsitektur CNN yang berfungsi untuk menerima *input* berupa gambar. Lapisan ini melakukan proses konvolusi terhadap citra menggunakan *filter* atau *kernel* guna mengekstraksi fitur penting dari gambar tersebut. Perhitungan konvolusi secara matematis ditunjukkan pada persamaan (8):

$$a \cdot b = \sum_{i=1}^n a_i b_i \dots\dots\dots (8)$$

Dimana:

a, b = Vektor.

b. Activation Function

Fungsi aktivasi adalah fungsi *non-linear* yang diterapkan setelah proses konvolusi. Fungsinya untuk memperkenalkan *non-linearitas* pada jaringan, sehingga CNN dapat mempelajari. Fungsi ini biasanya ditempatkan setelah *convolutional layer*. Jaringan saraf berbagai fungsi aktivasi sering digunakan, antara lain:

a) Rectified Linear

ReLU adalah fungsi aktivasi yang umum digunakan karena kesederhanaan dan efektivitasnya. Rumus ukuran *output* dari proses konvolusi ditunjukkan oleh persamaan (9):

$$n_{out} = \left\lceil \frac{n_{in} + 2p - k}{s} \right\rceil + 1 \dots\dots\dots (9)$$

Dimana:

n_{in} = Input.

p = Padding.

k = Kernel.

s = Stride.

b) Softmax

Fungsi *Softmax* digunakan pada bagian akhir jaringan untuk melakukan klasifikasi. Fungsi ini mengubah skor *output* menjadi probabilitas, sehingga nilai total semua kelas adalah 1. *Softmax* sangat berguna ketika klasifikasi mencakup banyak kelas target. Persamaannya ditunjukkan dalam Persamaan (10):

$$\text{softmax}(Z_i) = \frac{\exp(Z_i)}{\sum_j \exp(Z_j)} \dots\dots\dots (10)$$

Dimana:

Z_i = Skor kelas ke-i.

c. Pooling Layer

Lapisan *Pooling* digunakan untuk mengurangi dimensi spasial dari fitur hasil konvolusi. Ini membantu mengurangi jumlah parameter dan komputasi, serta mencegah *overfitting*. Jenis *pooling* yang paling umum adalah *Max Pooling*, yaitu memilih nilai tertinggi dari area tertentu. Perhitungannya dijelaskan dalam Persamaan (11):

$$\text{Pool}_{xy} = \text{Max}(\text{Conv}_{x+1,y}, \text{Conv}_{x,y+1}, \text{Conv}_{x+1,y+1}) \dots\dots\dots (11)$$

Dimana:

Conv = nilai hasil konvolusi.

d. Flatten

Proses *Flattening* mengubah data dari bentuk *matriks* (multidimensi) menjadi vektor satu dimensi. Langkah ini penting karena *layer* berikutnya, yaitu *Fully Connected Layer*, hanya dapat menerima *input* dalam bentuk vektor.

e. Fully Connected Layer

Lapisan *Fully Connected* merupakan bagian dari jaringan syaraf tiruan yang setiap *neuron* dihubungkan dengan semua neuron pada layer sebelumnya. Lapisan ini terdiri dari neuron tersembunyi (*hidden layer*), fungsi aktivasi, dan *layer* keluaran. FC Layer bertugas untuk melakukan klasifikasi berdasarkan fitur yang telah diekstraksi dari proses sebelumnya, dan menentukan *output* akhir.

Model *Convolutional Neural Network* (CNN) yang digunakan dalam penelitian ini menerima input citra dengan ukuran 224x224 piksel. Arsitektur CNN terdiri dari beberapa lapisan utama yaitu *convolutional layer*, *activation layer*, *pooling layer*, *flatten layer*, dan *fully connected layer*. Lapisan *convolutional* berfungsi untuk mengekstraksi fitur visual dari citra menggunakan kernel tertentu.

Fungsi aktivasi *Rectified Linear Unit* (ReLU) digunakan setelah proses konvolusi untuk memperkenalkan sifat *non-linear* pada jaringan. Lapisan *max pooling* digunakan untuk mengurangi dimensi fitur serta mengurangi kompleksitas komputasi. Proses klasifikasi dilakukan pada lapisan *fully connected* dengan fungsi aktivasi *Softmax* untuk menentukan probabilitas kelas *Smoking* dan *Not Smoking*.

Model dilatih menggunakan *optimizer Adam* dengan *learning rate* sebesar 0.001 dan *batch size* sebesar 16. Proses pelatihan dilakukan selama 26 *epoch* dengan penerapan teknik *early stopping* untuk mencegah terjadinya *overfitting* selama proses pelatihan. Evaluasi model melalui tahapan berikut [31]:

a. Accuracy

Accuracy digunakan untuk mengukur seberapa banyak prediksi yang benar dari seluruh data melalui Persamaan (12):

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots (12)$$

Dimana:

TP = True Positive (prediksi benar positif).

TN = True Negative (prediksi benar negatif).

FP = False Positive (prediksi salah positif).

FN = False Negative (prediksi salah negatif).

b. Precision

Precision digunakan untuk mengukur seberapa akurat prediksi positif yang dihasilkan model melalui Persamaan (13):

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots (13)$$

Dimana:

TP = True Positive (prediksi benar positif).

FP = False Positive (prediksi salah positif).

c. Recall

Recall digunakan untuk mengukur kemampuan model dalam menemukan semua data positif melalui Persamaan (14):

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots (14)$$

Dimana:

TP = True Positive (prediksi benar positif).

FN = False Negative (prediksi salah negatif).

d. F1-Score

F1-Score digunakan untuk menggabungkan *Precision* dan *Recall* menjadi satu nilai keseimbangan melalui Persamaan (15):

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \dots\dots\dots (15)$$

Dimana:

Precision = Akurasi prediksi positif.

Recall = Kemampuan menemukan data positif.

e. Average Precision

AP (Average Precision) digunakan untuk mengukur performa deteksi objek secara keseluruhan berdasarkan kurva *precision* dan *recall* melalui Persamaan (16):

$$AP = \int_0^1 Precision(Recall) dRecall \dots\dots\dots (16)$$

Dimana:

AP = Average Precision untuk satu kelas.

2.1.4 Implementasi dan Pengujian Model

Implementasi model dalam penelitian ini dilakukan dengan menggunakan bahasa pemrograman *Python*, serta memanfaatkan pustaka seperti *TensorFlow* dan *Keras* untuk membangun arsitektur CNN dan mengintegrasikannya dengan algoritma YOLO Model CNN digunakan untuk mengklasifikasikan citra ke dalam dua kategori, yaitu *Smoking* dan *Not Smoking*, sedangkan YOLO digunakan untuk mendeteksi objek manusia dan rokok dalam gambar atau *video*. Data citra yang telah dipra-proses kemudian digunakan dalam proses pelatihan model CNN, sedangkan YOLO diterapkan untuk melakukan deteksi objek secara *real-time*. Seluruh proses implementasi mencakup pemodelan, kompilasi, pelatihan, validasi, serta pengujian model menggunakan data yang telah dibagi sebelumnya.

Pengujian model dilakukan untuk mengevaluasi kinerja sistem dalam mendeteksi dan mengenali aktivitas merokok berdasarkan citra yang belum pernah dilihat sebelumnya oleh model. Data uji yang digunakan berasal dari bagian data yang telah dipisahkan sebelumnya dan tidak dilibatkan dalam proses pelatihan. Model CNN digunakan untuk mengklasifikasikan gambar ke dalam kelas *Smoking* atau *Not Smoking*, sedangkan YOLO digunakan untuk mendeteksi keberadaan objek perokok dan rokok dalam gambar atau *video*. Pengujian ini bertujuan untuk mengukur sejauh mana model mampu menggeneralisasi pola yang telah dipelajari dan memastikan bahwa sistem dapat bekerja secara efektif dalam situasi nyata, khususnya di area yang merupakan kawasan tanpa rokok.


2.1.5 Hasil dan Pembahasan

Bagian ini menjelaskan hasil penelitian serta pembahasan yang diperoleh dari proses pengujian dan validasi model menggunakan data yang tidak terlibat dalam pelatihan. Hasil yang diperoleh kemudian dibandingkan dengan penelitian sebelumnya yang relevan sebagai acuan untuk menilai peningkatan performa dan kontribusi metode yang digunakan. Selain itu, faktor-faktor yang mempengaruhi hasil, seperti kualitas *dataset*, proses pra-pemrosesan, serta arsitektur model, turut dianalisis untuk memberikan pemahaman yang lebih komprehensif terhadap kinerja sistem yang dikembangkan.

3. HASIL DAN PEMBAHASAN


3.1 Hasil Algoritma YOLO

Tahap ini dilakukan menggunakan algoritma YOLO untuk mendeteksi dan melakukan *cropping* pada objek manusia yang relevan dengan aktivitas merokok dan tidak merokok. Proses ini bertujuan untuk memastikan bahwa data yang digunakan pada tahap pelatihan hanya berisi area penting sehingga dapat meningkatkan akurasi model. Berdasarkan hasil pemrosesan, total sebanyak 3.254 gambar telah diproses, yang terdiri dari 1.978 gambar kategori *smoking* dan 1.276 gambar kategori *not smoking*. Hal ini, tidak seluruh gambar dapat digunakan karena dilakukan proses seleksi kualitas data, seperti penghapusan gambar duplikat, gambar buram (*blur*), objek manusia yang terlalu kecil, serta gambar yang tidak terdeteksi objek manusia seperti Gambar 2 berikut:



Gambar 2. Hasil Proses Algoritma YOLO

Gambar 2 menunjukkan hasil dari proses menggunakan YOLO, di mana hanya data yang memenuhi kriteria kualitas yang digunakan untuk tahap selanjutnya. Proses tersebut, masing-masing kategori *smoking* dan *not smoking* menghasilkan 560 gambar yang *valid* dan siap digunakan. Sementara itu, sejumlah data dieliminasi dengan rincian antara lain gambar duplikat yang cukup dominan, objek manusia yang tidak terdeteksi, serta kualitas citra yang rendah seperti *blur* dan kegagalan pembacaan *file*. Hasil ini menunjukkan bahwa proses pra-pemrosesan sangat berperan penting dalam meningkatkan kualitas *dataset* sebelum masuk ke tahap pelatihan model seperti Gambar 3 berikut:




Gambar 3. Hasil Distribusi Pra-Pemrosesan Data

Gambar 3 menampilkan distribusi *dataset* dalam bentuk visualisasi grafik, yang memperlihatkan pembagian data ke dalam tiga bagian utama yaitu *training*, *validation*, dan


testing. Data *training* terdapat masing-masing 358 citra untuk kelas *smoking* dan 358 citra untuk kelas *not smoking* dengan proporsi sebesar 64% dari total *dataset*. Data *validation* terdapat masing-masing 90 citra untuk kedua kelas dengan proporsi sebesar 16%, sedangkan pada data *testing* terdapat masing-masing 112 citra untuk kelas *smoking* dan *not smoking* dengan proporsi sebesar 20%. Distribusi ini menunjukkan bahwa jumlah data pada setiap kelas seimbang serta pembagian *dataset* telah dilakukan secara terstruktur, sehingga dapat mendukung proses pembelajaran model secara optimal serta menjaga keseimbangan dalam tahap evaluasi dan pengujian.

3.2 Hasil Algoritma CNN

Proses pelatihan model CNN dengan proses pemotongan gambar dari algoritma YOLO dilakukan selama 26 *epoch* menggunakan data citra yang telah melalui tahap pra-pemrosesan. Setiap *epoch* menghasilkan nilai akurasi, *loss*, *val_accuracy*, dan *val_loss* yang menjadi indikator kinerja model selama pelatihan dan validasi. Visualisasi tersebut ditunjukkan pada Gambar 4 berikut:



(a) Accuracy Selama Proses Pelatihan




(b) Loss Selama Proses Pelatihan

Gambar 4. Visualisasi Hasil Pelatihan

Gambar 4 menunjukkan bahwa perbedaan antara nilai akurasi pelatihan dan akurasi validasi relatif kecil, sehingga tidak terdapat indikasi *overfitting* yang signifikan pada model. Nilai akurasi pelatihan mencapai 96,09% dan

akurasi validasi sebesar 94,44%, yang menunjukkan bahwa model mampu mempelajari pola pada data latih sekaligus melakukan generalisasi dengan baik terhadap data validasi. Nilai *loss* pelatihan sebesar 17,21% dan *loss* validasi sebesar 20,7% juga menunjukkan kestabilan proses pembelajaran tanpa fluktuasi yang berlebihan.

Pengujian model dilakukan menggunakan data validasi yang terdiri dari 224 citra yang sebelumnya tidak digunakan dalam proses pelatihan model. Pendekatan ini digunakan untuk memastikan bahwa model tidak hanya mampu mempelajari pola pada data pelatihan, tetapi juga mampu mengenali pola pada data baru. Hasil evaluasi dari proses pengujian ini kemudian dianalisis menggunakan beberapa metrik evaluasi klasifikasi. Hasilnya seperti pada Gambar 5 berikut:



Gambar 5. Evaluasi Hasil Pelatihan

Gambar 5 menampilkan evaluasi performa model menggunakan beberapa metrik klasifikasi, yaitu *accuracy*, *precision*, *recall*, *F1-score*, serta *Average Precision* (AP). Model yang dihasilkan menunjukkan performa yang sangat baik dengan nilai *accuracy* sebesar 94,44%, yang mengindikasikan bahwa sebagian besar data pada proses pengujian berhasil diklasifikasikan dengan benar. Nilai *precision* sebesar 92,55% menunjukkan tingkat ketepatan model dalam memprediksi kelas *Smoking*, sedangkan nilai *recall* sebesar 96,67% mengindikasikan kemampuan model yang sangat baik dalam mendeteksi seluruh data yang benar-benar termasuk dalam kelas tersebut. Selain itu, nilai *F1-score* sebesar 94,57% menunjukkan keseimbangan yang baik antara *precision* dan *recall*. Nilai AP yang mencapai 98,72% semakin memperkuat bahwa model memiliki performa klasifikasi yang sangat optimal.

3.3 Hasil Implementasi dan Pengujian Model

3.3.1 Deteksi Gambar

Pengujian sistem secara *real-time* dilakukan menggunakan kamera untuk mengetahui kemampuan sistem dalam mendeteksi aktivitas merokok secara langsung. Sistem memproses setiap *frame* citra yang diperoleh dari kamera

untuk mendeteksi objek menggunakan algoritma YOLO dan melakukan klasifikasi menggunakan CNN. Proses deteksi dilakukan secara berurutan mulai dari pendeteksian objek manusia hingga klasifikasi aktivitas merokok pada area yang terdeteksi. Kondisi tersebut secara *real-time* seperti Gambar 6 dan 7 berikut:



Gambar 6. Deteksi Gambar *Not Smoking*

Gambar 6 menampilkan dua gambar orang yang tidak sedang merokok. Hasil deteksi menunjukkan bahwa sistem tidak menemukan keberadaan objek rokok dalam citra, dan mengklasifikasikan seluruh gambar ke dalam kelas *Not Smoking*. Hal ini menunjukkan bahwa sistem mampu mengenali situasi normal tanpa adanya aktivitas merokok, serta tidak menghasilkan prediksi positif palsu pada gambar yang seharusnya tidak terdeteksi.



Gambar 7. Deteksi Gambar *Smoking*

Sementara pada Gambar 7, ditampilkan dua gambar orang yang sedang merokok dengan berbagai posisi dan sudut pengambilan gambar. Sistem berhasil mendeteksi keberadaan rokok dan wajah perokok serta mengklasifikasikan seluruh gambar tersebut ke dalam kelas

Smoking. Deteksi berlangsung secara cepat dan responsif, menandakan bahwa sistem mampu mengenali ciri visual perokok meskipun terdapat variasi posisi dan ekspresi.

Hasil pengujian menunjukkan bahwa sistem mampu mendeteksi aktivitas merokok secara responsif pada berbagai posisi pengguna di depan kamera. Sistem juga mampu membedakan kondisi pengguna yang sedang merokok dan tidak merokok berdasarkan ciri visual yang terdeteksi. Pengujian ini menunjukkan bahwa integrasi antara YOLO dan CNN dapat digunakan sebagai pendekatan dalam membangun sistem deteksi aktivitas merokok secara otomatis.

3.3.2 Deteksi Kamera

Pengujian deteksi kamera dilakukan untuk menilai kemampuan sistem dalam mengenali aktivitas merokok secara langsung melalui citra yang diambil dengan kamera. Pengujian ini digunakan dua *grid*, di mana masing-masing *grid* berisi dua gambar. Tujuan dari pengujian ini adalah untuk mengevaluasi konsistensi dan akurasi sistem dalam membedakan kedua kondisi tersebut dalam lingkungan nyata seperti Gambar 8 dan 9 berikut:



Gambar 8. Deteksi Kamera Non Smoking

Gambar 8 menunjukkan individu yang tidak sedang merokok. Sistem tidak mendeteksi keberadaan objek rokok dalam citra, dan hasil klasifikasi menyatakan keduanya sebagai *Not Smoking*. Hal ini menunjukkan bahwa sistem mampu mengidentifikasi kondisi normal tanpa menghasilkan deteksi yang salah, serta tidak memberikan prediksi positif palsu terhadap gambar tanpa aktivitas merokok.



Gambar 9. Deteksi Kamera Smoking

Sementara itu, pada Gambar 9, dua gambar menampilkan individu yang sedang merokok dalam posisi dan sudut yang berbeda. Sistem berhasil mendeteksi keberadaan rokok dan mengklasifikasi sebagai *Smoking*. Kedua gambar dikenali dengan benar, membuktikan bahwa sistem mampu mengenali ciri-ciri visual khas aktivitas merokok, meskipun terdapat variasi pada ekspresi wajah dan arah pandangan kamera.

3.4 Pembahasan

Hasil penelitian ini menunjukkan bahwa pendekatan yang digunakan mampu mendeteksi aktivitas merokok dengan tingkat akurasi sebesar 94,44%. Nilai ini cukup tinggi dibandingkan beberapa penelitian sebelumnya yang menggunakan pendekatan CNN dalam deteksi perokok pada *dataset* yang lebih besar dan variasi data yang lebih

beragam. Penelitian yang dilakukan oleh Uddin dkk. [25], melaporkan akurasi sebesar 89.51% dalam mendeteksi aktivitas merokok menggunakan CNN berbasis citra.

Perbedaan hasil tersebut dapat dipengaruhi oleh jumlah *dataset*, variasi kondisi citra, serta arsitektur model yang digunakan dalam proses pelatihan. Penggunaan *dataset* yang lebih besar serta penerapan teknik regularisasi tambahan berpotensi meningkatkan performa model pada penelitian selanjutnya.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem deteksi dan klasifikasi aktivitas merokok dengan mengintegrasikan algoritma YOLO sebagai pendeteksi objek dan CNN sebagai pengklasifikasi citra. Proses pra-pemrosesan mampu menyaring data secara efektif sehingga diperoleh *dataset* berkualitas dengan masing-masing 560 citra *valid* pada kategori *smoking* dan *not smoking*. Pelatihan model selama 26 *epoch* menghasilkan performa yang stabil dengan akurasi pelatihan sebesar 96,09% dan akurasi validasi sebesar 94,44% tanpa indikasi *overfitting* yang signifikan. Evaluasi model menunjukkan hasil yang sangat baik dengan nilai *accuracy* 94,44%, *precision* 92,55%, *recall* 96,67%, *F1-score* 94,57%, serta AP 98,72%. Pengujian secara *real-time* melalui kamera juga menunjukkan bahwa sistem mampu mendeteksi dan mengklasifikasikan aktivitas merokok dengan baik pada berbagai kondisi, sehingga sistem dinilai efektif sebagai solusi deteksi otomatis berbasis citra.

Penelitian selanjutnya disarankan untuk melakukan pengujian pada lingkungan yang lebih beragam dengan variasi pencahayaan, latar belakang, dan jumlah objek yang lebih kompleks agar model menjadi lebih *robust*. Pengembangan metode juga dapat dilakukan dengan menambahkan teknik augmentasi data, penggunaan arsitektur model yang lebih ringan untuk implementasi *real-time* yang lebih efisien, serta integrasi dengan sistem notifikasi atau *monitoring* berbasis *Internet of Things* (IoT) guna mendukung penerapan pada kawasan tanpa rokok secara lebih optimal.

DAFTAR PUSTAKA

- [1] T. Hidayat, "Identifikasi Morfologi Citra Daging Menggunakan Teknik Pengolahan Citra Digital," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 1, pp. 1580–1586, 2025, doi: <https://doi.org/10.36040/jati.v9i1.12285>.
- [2] M. R. Pratama and I. F. Hanif, "Implementasi Metode Canny dalam Deteksi Tepi Pada Aplikasi Omr (Optical Mark Recognition) Menggunakan Pengembangan Sistem Waterfall," *Edunity Kajian Ilmu Sosial dan Pendidikan*, vol. 2, no. 2, pp. 267–283, 2023, doi: <https://doi.org/10.51178/edunity.v2i2.1194>.
- [3] N. Siagian, "Perancangan Aplikasi Pengolahan Citra Digital Untuk Penajaman Sisi Citra Hasil Fingerprint Menggunakan Metode Fourier Phase Only Synthesis," *Jurnal Ilmu Komputer, Teknologi Dan Informasi*, vol. 1, no. 2, pp. 66–75, 2023, doi: <https://doi.org/10.62866/jurikti.v1i2.41>.
- [4] N. A. Gunarsih, S. Wiyono, and D. I. Af'idah, "Aplikasi Deteksi Pelanggaran Merokok di Tempat Larangan Merokok," *Jurnal Informatika Polinema*, vol. 10, no. 3, pp. 351–358, 2024, doi: <https://doi.org/10.33795/jip.v10i3.1558>.
- [5] A. Usman, "Makna Merokok bagi Wanita: Studi Fenomenologi pada Mahasiswi Perokok," *RESIPROKAL: Jurnal Riset Sosiologi Progresif Aktual*, vol. 6, no. 1, pp. 38–51, 2024, doi: <https://doi.org/10.35508/resiprokal.v6i1.14481>.
- [6] A. D. Qanitha, C. Winata, E. Husnita, T. S. A. Zahra, A. Alrefi, and A. Akbari, "Konsep Diri Perokok Studi Kasus Pada Mahasiswa X Di Sumatra Selatan," *Jurnal Ilmiah Penelitian Mahasiswa*, vol. 2, no. 6, pp. 49–56, 2024, doi: <https://doi.org/10.21776/ub.jipm.2024.002.06.07>.
- [7] M. A. Kamil and Y. M. Djaksana, "Perbandingan Algoritma Convolutional Neural Network (CNN) Dan Algoritma You Only Look Once (YOLO) Untuk Deteksi Wajah," *Jurnal Intelek Insan Cendikia*, vol. 1, no. 9, pp. 4866–4876, 2024, doi: <https://doi.org/10.37373/jintel.v1i9.1124>.
- [8] O. Wynne *et al.*, "Signs, Fines and Compliance Officers: A Systematic Review of Strategies for Enforcing Smoke-Free Policy," *Int. J. Environ. Res. Public Health*, vol. 15, p. 1386, Jul. 2018, doi: <https://doi.org/10.3390/ijerph15071386>.
- [9] R. Dijaya and H. Setiawan, "Buku Ajar Pengolahan Citra Digital," *Umsida Press*, pp. 1–85, 2023, doi: <https://doi.org/10.21070/2023/978-623-464-061-0>.
- [10] Y. Yuhandri, A. Ramadhanu, and H. Syahputra, "Pengenalan Teknologi Pengolahan Citra Digital (Digital Image Processing) Untuk Santri Di Rahmatan Lil'Alamin International Islamic Boarding School," *Community Development Journal: Jurnal Pengabdian Masyarakat*, vol. 3, no. 2, pp. 1239–1244, 2022, doi: <https://doi.org/10.31004/cdj.v3i2.4933>.
- [11] M. Muhtadii and H. A. Tawakal, "Pengembangan Aplikasi Android Untuk Pengenalan Citra Nomor Sertifikat Halal Mui Dengan Library Tesseract Optical Character Recognition (Ocr)," *Jurnal Informatika Terpadu*, vol. 2, no. 2, 2016, doi: <https://doi.org/10.15408/jtit.v2i2.3115>.

- [12] A. Chairi and R. Mukhaiyar, "Sistem Kontrol Color Sorting Machine Dengan Pengolahan Citra Digital," *JTEIN: Jurnal Teknik Elektro Indonesia*, vol. 4, no. 1, pp. 387–396, 2023, doi: <https://doi.org/10.24036/jtein.v4i1.353>.
- [13] A. Wijaya, B. R. Daryono, R. Toyib, and Y. Apridiansyah, "Analisis Pengenalan Pola Pada Citra Digital Untuk Prediksi Berat Buah Sawit," *Decode: Jurnal Pendidikan Teknologi Informasi*, vol. 4, no. 3, pp. 713–724, 2024, doi: <https://doi.org/10.33510/decode.v4i3.364>.
- [14] J. H. Cho, "Detection of smoking in indoor environment using machine learning," *Applied Sciences (Switzerland)*, vol. 10, no. 24, pp. 1–17, Dec. 2020, doi: <https://doi.org/10.3390/app10248912>.
- [15] F. Ramadhani, A. Satria, and S. Dewi, "Identifikasi kendaraan bermotor pada dashcam mobil menggunakan algoritma YOLO," *Hello World Jurnal Ilmu Komputer*, vol. 2, no. 4, pp. 199–206, 2024, doi: <https://doi.org/10.53697/hw.v2i4.1032>.
- [16] I. M. D. Maleh, R. Teguh, A. S. Sahay, S. Okta, and M. P. Pratama, "Implementasi Algoritma You Only Look Once (YOLO) Untuk Object Detection Sarang Orang Utan," *Jurnal Informatika*, vol. 10, no. 1, 2023, doi: <https://doi.org/10.30865/jurikom.v10i1.5583>.
- [17] M. Y. A. Thoriq, I. A. Siradjuddin, and K. E. Permana, "Deteksi Wajah Manusia Berbasis One Stage Detector Menggunakan Metode You Only Look Once (YOLO)," *Jurnal Teknoinfo*, vol. 17, no. 1, pp. 66–73, 2023, doi: <https://doi.org/10.33365/jti.v17i1.2335>.
- [18] M. D. Alwi, I. S. Pradjojowaty, and T. Arifianto, "Penerapan Algoritma You Only Look Once (YOLO) Untuk Mendeteksi Sarana Perkeretaapian," *SPIRIT*, vol. 16, no. 2, 2024, doi: <https://doi.org/10.31294/spirit.v16i2.23847>.
- [19] P. Guarnido-Lopez, J. F. Ramirez-Agudelo, E. Denimal, and M. Benaouda, "Programming and Setting Up the Object Detection Algorithm YOLO to Determine Feeding Activities of Beef Cattle: A Comparison between YOLOv8m and YOLOv10m," *Animals*, vol. 14, no. 19, Oct. 2024, doi: <https://doi.org/10.3390/ani14192821>.
- [20] R. A. Mas'ud and J. Zeniarja, "Optimasi Convolutional Neural Networks untuk Deteksi Kanker Payudara menggunakan Arsitektur DenseNet," *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 1, pp. 310–318, 2024, doi: <https://doi.org/10.29408/edumatic.v8i1.25199>.
- [21] I. Wirabowo and I. Susilawati, "Implementasi Convolution Neural Network (CNN) untuk Deteksi Penyakit pada Daun Jagung Berbasis Citra Digital," *Jurnal Pustaka Data (Pusat Akses Kajian Database, Analisa Teknologi, dan Arsitektur Komputer)*, vol. 5, no. 1, pp. 233–241, 2025, doi: <https://doi.org/10.46961/pustakadata.v5i1.1278>.
- [22] D. Y. Armanto, S. A. Hudjimartsu, and E. Hermawan, "Identifikasi Perhitungan Pohon Kelapa Sawit Otomatis Dengan Menggunakan Metode Convolutional Neural Network (CNN)," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 3, pp. 2648–2654, 2024, doi: <https://doi.org/10.36040/jati.v8i3.10058>.
- [23] A. N. Mianah and F. A. Fiolana, "Klasifikasi Helm Keselamatan Menggunakan Metode Convolutional Neural Network (CNN)," *Journal Zetroem*, vol. 5, no. 2, pp. 94–102, 2023, doi: <https://doi.org/10.36526/ztr.v5i2.3023>.
- [24] A. A. Santosa, R. Y. N. Fu'adah, and S. Rizal, "Deteksi Penyakit pada Tanaman Padi Menggunakan Pengolahan Citra Digital dengan Metode Convolutional Neural Network," *Journal Of Electrical And System Control Engineering*, vol. 6, no. 2, pp. 98–108, Feb. 2023, doi: <https://doi.org/10.31289/jesce.v6i2.7930>.
- [25] M. S. Uddin, "CigaretteCNN: A Convolutional Neural Network for Detecting Cigarette Smoking Activity," in *International Conference on Engineering, Applied Sciences and System Modeling*, Singapore: Springer, 2017, pp. 259–274, doi: https://doi.org/10.1007/978-981-99-8438-1_19.
- [26] A. Gevindo and B. Hendrik, "Penerapan Machine Learning Untuk Mendeteksi Serangan Anomali Dalam Jaringan Komputer: Systematic Literature Review," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 3, pp. 4659–4664, 2025, doi: <https://doi.org/10.36040/jati.v9i3.13746>.
- [27] Y. D. P. Rangga *et al.*, "Edukasi Bahaya Merokok Pada Tingkat Pengetahuan Masyarakat Di Dusun Lewomudat Desa Waipaar," *PAKDEMAs: Jurnal Pengabdian Kepada Masyarakat*, vol. 4, no. 1, pp. 21–24, 2024, doi: <https://doi.org/10.58222/pakdemas.v4i1.272>.
- [28] D. I. Mulyana and R. F. Putra, "Optimasi deteksi objek dengan segmentasi dan data augmentasi pada hewan siput beracun menggunakan algoritma YOLO," *Jurnal JTik (Jurnal Teknologi Informasi dan Komunikasi)*, vol. 8, no. 1, 2024, doi: <https://doi.org/10.35870/jtik.v8i1.1391>.

- [29] W. H. S. Pesik, S. Mamuaya, A. N. Putra, and E. Mulyaman, "Implementasi YOLOv8 untuk Deteksi dan Hitung Objek Manusia dengan Convolutional Neural Network," *Buffer Informatika*, vol. 11, no. 1, pp. 16–26, 2025, doi: <https://doi.org/10.25134/buffer.v11i1.356>.
- [30] Q. A'yuni and B. Hendrik, "Literature Review: Analisis Komparatif Algoritma CNN, KNN, dan SVM untuk Klasifikasi Penyakit Kelapa Sawit," *Journal of Education Research*, vol. 5, no. 4, pp. 6589–6596, 2024, doi: <https://doi.org/10.37985/jer.v5i4.1983>.
- [31] F. T. Hidayat and A. K. Whardana, "Deteksi Pelanggaran Sepeda Motor Menggunakan Algoritma YOLO Dan Mean Average Precision," *Jurnal SISKOM-KB (Sistem Komputer dan Kecerdasan Buatan)*, vol. 8, no. 1, pp. 71–79, 2024, doi: <https://doi.org/10.47970/siskom-kb.v8i1.401>.