

**PENDETEKSI AKTIVITAS MEROKOK MENGGUNAKAN METODE
SINGLE SHOT DETECTOR PADA ZONA LARANGAN MEROKOK DI
KAMPUS**

LAPORAN TUGAS AKHIR

Proposal ini disusun untuk memenuhi salah satu syarat memperoleh gelar
Sarjana Strata 1 (S1) pada Program Studi Teknik Informatika
Fakultas Teknologi Industri Universitas Islam Sultan Agung Semarang



DISUSUN OLEH:

AHMAD TRI YULIANTO

NIM 32602100014

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM SULTAN AGUNG
SEMARANG
2025**

FINAL PROJECT

***DETECTION OF SMOKING ACTIVITY USING THE SINGLE SHOT
DETECTOR METHOD IN NO-SMOKING ZONES ON CAMPUS***

*Proposed to complete the requirement to obtain a bachelor's degree (S-1)
at Informatics Engineering Departement of Industrial Technology Faculty
Sultan Agung Islamic University*



ARRANGED BY:

AHMAD TRI YULIANTO

NIM 32602100014

**MAJORING OF INFORMATICS ENGINEERING
INDUSTRIAL TECHNOLOGY FACULTY
SULTAN AGUNG ISLAMIC UNIVERSITY
SEMARANG
2025**

**LEMBAR PENGESAHAN
TUGAS AKHIR**

**PENDETEKSI AKTIVITAS MEROKOK MENGGUNAKAN METODE
SINGLE SHOT DETECTOR PADA ZONA LARANGAN MEROKOK DI
KAMPUS**

**AHMAD TRI YULIANTO
NIM 32602100014**

Telah dipertahankan di depan tim penguji ujian sarjana tugas akhir
Program Studi Teknik Informatika
Universitas Islam Sultan Agung
Pada tanggal :

TIM PENGUJI UJIAN SARJANA :

Bagus SWP, S.Kom, M.Cs
NIK. 210616051
(Ketua Penguji)



19 / 05 / 2025

Moch. Taufik, S.T., M.IT
NIK. 210604034
(Anggota Penguji)




19 / 05 / 2025

Andi Riansyah, S.T., M.Kom
NIK. 210616053
(Pembimbing)

19 / 05 / 2025

Semarang, 20 Mei 2025

Mengetahui,
Kaprodi Teknik Informatika
Universitas Islam Sultan Agung



Moch. Taufik, S.T., M.IT
NIK. 210604034

SURAT PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan di bawah ini:

Nama : Ahmad Tri Yulianto

NIM : 32602100014

Judul Tugas Akhir : Pendeteksi Aktivitas Merokok Menggunakan Metode *Single Shot Detector* Pada Zona Larangan Merokok di Kampus

Bahwa dengan ini saya menyatakan bahwa judul dan isi Tugas Akhir yang saya buat dalam rangka menyelesaikan Pendidikan Strata Satu (S1) Teknik Informatika tersebut adalah asli dan belum pernah diangkat, ditulis ataupun dipublikasikan oleh siapapun baik keseluruhan maupun sebagian, kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka, dan apabila di kemudian hari ternyata terbukti bahwa judul Tugas Akhir tersebut pernah diangkat, ditulis ataupun dipublikasikan, maka saya bersedia dikenakan sanksi akademis. Demikian surat pernyataan ini saya buat dengan sadar dan penuh tanggung jawab.

Semarang, 20 Mei 2025

Yang menyatakan,



Ahmad Tri Yulianto

PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH

Saya yang bertanda tangan di bawah ini:

Nama : Ahmad Tri Yulianto

NIM : 32602100014

Program Studi : Teknik Informatika

Fakultas : Teknologi Industri

Alamat Asal : Rembang

Dengan ini menyatakan karya ilmiah berupa tugas akhir dengan judul : Pendeteksi Aktivitas Merokok Menggunakan Metode *Single Shot Detector* Pada Zona Larangan Merokok di Kampus.

Menyetujui menjadi hak milik Universitas Islam Sultan Agung serta memberikan hak bebas royalti Non-Eksklusif untuk disimpan, dialihmediakan, dikelola dan pangkalan data dan dipublikasikan di internet dan media lain untuk kepentingan akademis selama tetap menyantumkan nama penulis sebagai pemilik hak cipta. Pernyataan ini saya buat dengan sungguh-sungguh. Apabila di kemudian hari terbukti ada pelanggaran Hak Cipta/Plagiarisme dalam karya ilmiah ini, maka segala bentuk tuntutan hukum yang timbul akan saya tanggung secara pribadi tanpa melibatkan Universitas Islam Sultan Agung.

Semarang, 20 Mei 2025

Yang menyatakan,



Ahmad Tri Yulianto

KATA PENGANTAR

Dengan mengucapkan syukur alhamdulillah atas kehadiran ALLAH SWT yang telah memberikan rahmat dan karunia-Nya kepada penulis, sehingga dapat menyelesaikan Tugas Akhir dengan judul “Pendeteksi Aktivitas Merokok Menggunakan Metode *Single Shot Detector* pada Zona Larangan Merokok di Kampus” dengan baik.

Tugas akhir ini disusun dan dibuat dengan adanya bantuan dari berbagai pihak, berupa materi maupun teknis, oleh karena itu saya selaku penulis mengucapkan terima kasih kepada:

1. Rektor Universitas Islam Sultan Agung Bapak Prof. Dr. H. Gunarto, S.H., M.H yang mengizinkan penulis menimba ilmu di kampus ini.
2. Dekan Fakultas Teknologi Industri Ibu Dr. Ir. Hj. Novi Marlyana, S.T., M.T., IPU., ASEAN Eng
3. Dosen pembimbing penulis Bapak Andi Riansyah, S.T., M.Kom yang telah meluangkan waktu dan memberi ilmu dalam penyusunan tugas akhir.
4. Orang tua penulis Bapak Jari dan Ibu Sri Mukti yang telah memberikan doa serta dorongan baik moral maupun material.
5. Saudara penulis Ahmad Choirul Amin sekeluarga, Ahmad Agung Gumilar sekeluarga, dan Ahmad Zainal Abidin yang telah memberikan dukungan selama masa studi.
6. Saudari Farikhatul Fikriyah yang telah memberikan semangat kepada penulis dalam menyelesaikan tugas akhir.
7. Teman seperjuangan yang telah memberikan dukungan moral, motivasi, serta semangat dalam proses penyelesaian tugas akhir.
8. Dan kepada semua pihak yang tidak dapat disebutkan satu persatu.


Semarang, Mei 2025

Penulis

DAFTAR ISI

HALAMAN JUDUL.....	i
LEMBAR PENGESAHAN TUGAS AKHIR.....	ii
SURAT PERNYATAAN KEASLIAN TUGAS AKHIR.....	iii
PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH.....	iv
KATA PENGANTAR.....	v
DAFTAR ISI	vi
DAFTAR TABEL.....	viii
DAFTAR GAMBAR	ix
ABSTRAK	x
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Batasan Masalah.....	3
1.4 Tujuan Penelitian.....	4
1.5 Manfaat	4
1.6 Sistematika Penelitian	5
BAB II TINJAUAN PUSTAKA DAN DASAR TEORI	6
2.1 Tinjauan Pustaka	6
2.2 Dasar Teori	9
2.2.1 Rokok.....	9
2.2.2 Zona Larangan Merokok.....	9
2.2.3 <i>Computer Vision</i>	10
2.2.4 <i>OpenCV</i>	10
2.2.5 <i>Machine Learning</i>	11
2.2.6 <i>Deep Learning</i>	11
2.2.7 <i>Python</i>	12
2.2.8 <i>Single Shot Detector</i>	12
BAB III METODE PENELITIAN.....	17
3.1 Studi Literatur	17
3.2 Persiapan <i>Dataset</i>	18

3.3	<i>Preprocessing Data</i>	18
3.3.1	<i>Image Augmentation</i>	19
3.4	Pembuatan Model.....	20
3.4.1	<i>Training dan Validation</i>	21
3.5	Pengujian.....	21
3.6	Evaluasi	22
3.7	<i>Software</i>	23
3.8	<i>Hardware</i>	25
BAB IV HASIL DAN ANALISIS PENELITIAN.....		26
4.1	Hasil	26
4.2	Analisa.....	30
BAB V KESIMPULAN DAN SARAN.....		42
5.1	Kesimpulan	42
5.2	Saran.....	42
DAFTAR PUSTAKA.....		



DAFTAR TABEL

Tabel 1. 1 Sistematika penulisan	5
Tabel 3. 1 <i>Confusion matrix</i>	23
Tabel 4. 1 <i>Hyperparameter</i>	30
Tabel 4. 2 Hasil pengujian.....	31
Tabel 4. 3 Hasil evaluasi	40



DAFTAR GAMBAR

Gambar 2. 1 Rokok	9
Gambar 2. 2 (a) <i>Area of Overlap</i> ; (b) <i>Area of Union</i>	13
Gambar 2. 3 Arsitektur <i>SSD</i>	14
Gambar 3. 1 Alur penelitian	17
Gambar 3. 2 <i>Dataset</i>	18
Gambar 3. 3 Alur pengujian	22
Gambar 4. 1 <i>Folder</i> awal	26
Gambar 4. 2 Gambar dan anotasi dalam satu folder	26
Gambar 4. 3 <i>Folder</i> baru	27
Gambar 4. 4 <i>Label mapping</i>	27
Gambar 4. 5 Hasil augmentasi	28
Gambar 4. 6 Grafik <i>loss</i>	29
Gambar 4. 7 Tampilan ketika mendeteksi rokok	29



ABSTRAK

Rokok adalah produk konsumsi berbahaya yang mengandung lebih dari 7.000 bahan kimia, termasuk setidaknya 60 karsinogen yang diketahui. Paparan karsinogen dapat mengakibatkan peningkatan imunoterapi dan imonegenesis. Upaya pembatasan merokok pada area tertentu telah diterapkan oleh pemerintah Indonesia. Salah satunya dengan disahkannya Undang-Undang Republik Indonesia Nomor 17 tahun 2023 tentang kesehatan pada pasal 151 ayat (1) mengenai area kawasan tanpa rokok. Yayasan Badan Wakaf Sultan Agung juga mengeluarkan surat edaran nomor 930/YBW-SA/IX/2024 terkait sosialisasi peraturan larangan merokok dan disusul surat edaran Universitas Islam Sultan Agung nomor 9243/J/SA/IX/2024 tentang larangan merokok di kampus. Namun, penegakan hukum yang terbatas menyebabkan seringnya terjadi pelanggaran. Oleh karena itu, kamera pengawas yang mampu mendeteksi aktivitas merokok sangat penting untuk mendukung aturan tersebut. Pada penelitian ini, model pendeteksi rokok dikembangkan dengan menggunakan metode Single Shot Detector (SSD) dengan VGG16 sebagai pengekstrak fitur. Hasil pengujian menunjukkan bahwa pada *threshold* 0.5, model mencapai akurasi 97,5%, presisi 97,4%, *recall* 100%, dan *F1-score* 98,7%. Meskipun kinerjanya sedikit menurun pada *threshold* yang lebih tinggi, model tetap mempertahankan konsistensi *recall* dan deteksi objek yang kuat di berbagai kondisi. Kesimpulannya, model pendeteksian merokok berbasis SSD dengan VGG16 telah terbukti efektif dan akurat dalam mengidentifikasi asap rokok.

Kata Kunci: Deteksi objek, *OpenCV*, Merokok, SSD

ABSTRACT

Cigarettes are hazardous consumer products that contain more than 7,000 chemicals, including at least 60 known carcinogens. Exposure to carcinogens can result in increased immunotherapy and immonegenicity. Efforts to restrict smoking in certain areas have been implemented by the Indonesian government. One of them is the enactment of the Law of the Republic of Indonesia Number 17 of 2023 concerning health in article 151 paragraph (1) regarding non-smoking areas. The Sultan Agung Waqf Board Foundation also issued circular number 930/YBW-SA/IX/2024 regarding the socialization of smoking ban regulations and followed by Sultan Agung Islamic University circular number 9243/J/SA/IX/2024 regarding smoking ban on campus. However, limited law enforcement leads to frequent violations. Therefore, surveillance cameras capable of detecting smoking activities are essential to support the regulation. In this study, a cigarette detection model was developed using the Single Shot Detector (SSD) method with VGG16 as the feature extractor. The test results showed that at a threshold of 0.5, the model achieved 97.5% accuracy, 97.4% precision, 100% recall, and 98.7% F1-score. Although the performance degrades slightly at higher thresholds, the model still maintains strong recall and object detection consistency across various conditions. In conclusion, the SSD-based smoking detection model with VGG16 has proven to be effective and accurate in identifying cigarette smoke.

Keywords: Object detection, *OpenCV*, Smoking, SSD

BAB I

PENDAHULUAN

1.1 Latar Belakang

Rokok adalah salah satu produk konsumsi yang sangat berbahaya bagi kesehatan. Terlepas dari kesalahpahaman bahwa merokok dapat mengatur suasana hati yang cemas, bukti menunjukkan bahwa berhenti merokok dikaitkan dengan peningkatan kesehatan mental seseorang (Simonavičius dkk., 2025). Rokok mengandung lebih dari 7.000 bahan kimia dan lebih dari 60 di antaranya adalah karsinogen, yang merupakan sifat dari suatu senyawa yang dapat menginduksi perubahan genetik dan menyebabkan kanker (Appolon dkk., 2024; Y. Li & Hecht, 2022). Penelitian sebelumnya menemukan lebih dari 200 N-Nitrosamin karsinogenik yang terbentuk melalui reaksi alkaloid tembakau dengan nitrit selama pemrosesan tembakau (Hecht & Hatsukami, 2022). Paparan karsinogen, sebagaimana tercermin dari peningkatan Tumor Mutational Burden (TMB), mengakibatkan peningkatan imunoterapi (pengobatan yang memanfaatkan sistem kekebalan tubuh) dan imunogenisitas kanker (Huang dkk., 2023).

Upaya pembatasan merokok pada area tertentu telah diterapkan oleh pemerintah Indonesia. Salah satunya dengan disahkannya Undang-Undang Republik Indonesia Nomor 17 tahun 2023 tentang kesehatan dimana pada pasal 151 ayat (1) menyebutkan area yang termasuk kawasan tanpa rokok. Salah satu area yang disebutkan adalah tempat proses belajar mengajar, itu artinya dari sekolah kanak-kanak hingga kampus perkuliahan harus steril dari aktivitas ini. Sehubungan dengan berlakunya Undang-Undang tersebut, Yayasan Badan Wakaf Sultan Agung (YBWSA) mengeluarkan surat edaran bernomor 930/YBW-SA/IX/2024 yang berisi perintah sosialisasi peraturan larangan merokok di lingkungan masing-masing dari semua unit yang ada di bawah naungan YBWSA. Menindaklanjuti kedua hal tersebut (Undang-Undang dan edaran YBWSA), Universitas Islam Sultan Agung mengeluarkan

surat edaran bernomor 9243/J/SA/IX/2024 berisi larangan merokok di lingkungan kampus.

Namun, fakta di lapangan menunjukkan bahwa masih banyak yang melanggar aturan karena kurangnya pengawasan. Keterbatasan pihak berwenang dalam mengawasi lingkungan kampus supaya bebas asap rokok membuat kebijakan ini sulit diterapkan. Dibutuhkan kamera yang dapat memantau aktivitas di suatu tempat untuk memastikan tidak adanya pelanggaran terhadap aktivitas merokok.

Perkembangan teknologi semakin canggih, salah satunya adalah *deep learning*. *Deep learning* adalah jaringan saraf tiruan yang terdiri dari beberapa lapisan yang dirancang untuk mempelajari dan menghasilkan representasi dari data masukan (Chaturvedi dkk., 2025). *Deep learning* mengeksplorasi lebih banyak fitur dan arsitektur yang lebih kompleks daripada metode klasik dan dapat mencapai kinerja yang lebih baik (Wang dkk., 2025). Kemampuan *deep learning* ini juga dimanfaatkan oleh *computer vision*. *Computer vision* adalah komputer yang memiliki kemampuan deteksi objek seperti mensimulasikan objek langsung, melihat, menganalisis karakteristik target (Marwanto, 2024; Saqib dkk., 2025), lokalisasi visual (S. C. Magalhães dkk., 2023), dan mengklasifikasikan (Riansyah, 2025). Perkembangan teknologi yang pesat berpengaruh terhadap penggunaan komputer di masa depan yang mana mampu mendominasi pekerjaan manusia (Riansyah, 2021).

Teknik *computer vision* mencakup ekstraksi, analisis, dan interpretasi informasi visual dari dunia fisik melalui analisis yang cepat, akurat, dan tidak merusak. Dengan memanfaatkan teknik pemrosesan gambar, algoritma canggih, dan kecerdasan buatan, *computer vision* dapat meniru sebagian persepsi manusia dan mendeteksi cacat yang halus sekalipun (Lysova dkk., 2025). Pada penelitian ini, metode *Single Shot Detector* digunakan untuk mendeteksi secara *real-time* suatu kejadian. Penelitian terkait pengujian akurasi pada metode *Single Shot Detector* untuk deteksi objek diperoleh nilai *mean Average Precision* (mAP) sebesar 77,5% (Bai dkk., 2022).

1.2 Rumusan Masalah

1. Bagaimana hasil metode *Single Shot Detector* dalam mendeteksi aktivitas merokok?
2. Seberapa akurat dan efisien metode *Single Shot Detector* dalam mendeteksi aktivitas merokok?
3. Apa saja kendala yang dihadapi dalam penerapan metode *Single Shot Detector* pada sistem deteksi aktivitas merokok dan bagaimana solusinya?

1.3 Batasan Masalah

1. Jenis deteksi aktivitas yang dilakukan oleh algoritma *Single Shot Detector* dibatasi pada aktivitas yang jelas menunjukkan tindakan merokok, seperti memegang atau menghisap rokok.
2. Deteksi aktivitas merokok melakukan deteksi pada visual rokok yang dipegang atau dihisap, bukan dari asap yang muncul dari rokok.
3. Pod dan vape tidak termasuk objek yang akan dideteksi oleh model.
4. Kualitas gambar dan resolusi kamera algoritma akan diuji menggunakan dari kamera laptop yang memiliki kualitas resolusi standar (480p hingga 1080p).
5. Akurasi deteksi di kondisi pencahayaan tertentu, sistem hanya akan diuji dalam kondisi pencahayaan normal atau siang hari. Pengujian dalam kondisi minim cahaya, seperti malam hari atau cuaca buruk, tidak menjadi bagian dari penelitian ini.
6. Jenis *hardware* yang digunakan akan dibatasi pada penggunaan *hardware* laptop dan *webcam*.
7. Deteksi aktivitas merokok dibatasi hanya sampai maksimal 2 meter jarak antara objek dengan kamera atau *webcam*.

1.4 Tujuan Penelitian

1. Mengimplementasikan metode *Single Shot Detector* pada sistem deteksi aktivitas merokok pada zona larangan merokok di kampus.
2. Menguji performa model deteksi aktivitas merokok berbasis *Single Shot Detector*.
3. Mengidentifikasi kendala teknis dan operasional yang dihadapi selama proses pengembangan dan implementasi sistem, serta memberikan rekomendasi untuk perbaikan lebih lanjut.
4. Menyediakan solusi berbasis teknologi untuk meningkatkan disiplin mahasiswa terhadap aturan zona larangan merokok di kampus.

1.5 Manfaat

1. Penelitian ini diharapkan dapat menjadi referensi dalam literatur tentang bidang *computer vision* yang fokus model deteksi perilaku atau aktivitas manusia, khususnya menggunakan metode *Single Shot Detector*.
2. Menunjukkan pentingnya integrasi teknologi berbasis AI dan *computer vision* dalam mendukung kebijakan institusi.
3. Menjadi inovasi yang bisa digunakan oleh pihak kampus dalam menegakkan aturan.
4. Mendorong terciptanya lingkungan kampus yang sehat dan bebas asap rokok.

1.6 Sistematika Penelitian

Sistematika penulisan yang akan digunakan oleh penulis dalam sebuah pembuatan laporan tugas akhir adalah sebagai berikut:

Tabel 1. 1 Sistematika penulisan

BAB I	PENDAHULUAN
	Bab ini berisi latar belakang pemilihan judul, rumusan masalah, batasan masalah, tujuan penelitian, manfaat, serta sistematika penulisan.
BAB II	TINJAUAN PUSTAKA DAN DASAR TEORI
	Bab ini memuat penelitian-penelitian sebelumnya dan dasar teori untuk membantu penulis memahami bagaimana teori yang berhubungan dengan <i>Single Shot Detector</i> dan pengimplementasian menggunakan <i>webcam</i> .
BAB III	METODE PENELITIAN
	Bab ini mengungkapkan proses tahapan-tahapan penelitian dimulai dari mendapatkan data hingga proses pengolahan data yang ada.
BAB IV	HASIL DAN ANALISIS PENELITIAN
	Bab ini penulis mengungkapkan hasil penelitian seperti pengumpulan data, pengolahan data, pengujian model deteksi aktivitas merokok, dan juga perhitungan akurasi dari evaluasi model yang diterapkan
BAB V	KESIMPULAN DAN SARAN
	Bab ini penulis memaparkan kesimpulan proses penelitian dari awal hingga akhir serta saran untuk penelitian selanjutnya.

BAB II

TINJAUAN PUSTAKA DAN DASAR TEORI

2.1 Tinjauan Pustaka

Dalam penelitian sebelumnya mengenai penerapan *Single Shot Detector (SSD)* pada deteksi isolator dalam citra udara yang dilakukan oleh (Miao dkk., 2019), diperoleh hasil bahwa *SSD* mampu mengimplementasikan pembelajaran fitur otomatis secara efektif dibandingkan dengan metode berbasis ekstraksi fitur buatan tangan yang kurang efisien. Penelitian tersebut juga memperkenalkan strategi *fine-tuning* dua tahap, yaitu dengan memanfaatkan model COCO dan *dataset* isolator dasar pada tahap pertama, serta menyempurnakan parameter model menggunakan *dataset* isolator spesifik pada tahap kedua. Hasil evaluasi menunjukkan bahwa *SSD* dapat mendeteksi isolator porselen dan komposit dengan akurasi tinggi, masing-masing mencapai AP 94,12% dan 86,70% pada citra berlatar belakang hutan, serta 90,51% dan 87,29% pada latar belakang bangunan yang kompleks.

Dalam penelitian yang dilakukan oleh (S. A. Magalhães dkk., 2021) mengenai pengembangan solusi robotik untuk pertanian, khususnya pada proses pemanenan tomat di rumah kaca, diperoleh hasil bahwa sistem persepsi visual harus mampu mendeteksi tomat pada setiap tahap siklus hidupnya, mulai dari bunga hingga tomat matang. Penelitian ini berkontribusi dengan menyediakan *dataset* visual beranotasi yang mencakup tomat hijau dan kemerahan, yang sebelumnya jarang tersedia untuk keperluan penelitian. Model dilatih dan diuji untuk mendeteksi tomat hijau dan kemerahan yang tumbuh di rumah kaca. Berdasarkan spesifikasi platform robotik yang digunakan, hanya arsitektur *Single Shot Detector (SSD)* dan *YOLO* yang dipertimbangkan. Hasil penelitian menunjukkan bahwa *SSD MobileNet v2* memberikan performa terbaik dengan *F1-score* sebesar 66,15% dan *mAP* 51,46%, serta waktu inferensi 16,44 ms menggunakan platform *NVIDIA Tesla T4* dengan memori 12 GB. *YOLOv4 Tiny* juga menunjukkan hasil yang mengesankan, khususnya dalam hal waktu inferensi yang sangat cepat sekitar

5 ms. Dari hasil ini dapat disimpulkan bahwa sistem yang dikembangkan mampu mendeteksi tomat hijau dan kemerahan, bahkan yang tertutup oleh daun.

Penelitian sebelumnya mengenai sistem deteksi gerbang untuk aplikasi balap *drone* otonom (ADR) yang dilakukan oleh (Latin & Transactions, 2019), peneliti memanfaatkan arsitektur *SSD5* yang dimodifikasi dari *SSD7* untuk memprediksi *output bounding box* melalui kamera *drone*. Sistem ini dievaluasi dalam tiga skenario berbeda, yaitu simulasi, lingkungan dalam ruangan, dan luar ruangan. Hasil penelitian menunjukkan bahwa sistem deteksi ini mampu mencapai tingkat kepercayaan sebesar 96,18% pada simulasi, 94,56% di luar ruangan, dan 94,46% di luar ruangan dengan *Intel Computer Stick*, serta memiliki kecepatan prediksi yang lebih tinggi dan waktu rata-rata yang lebih rendah dibandingkan arsitektur *deep learning* lainnya. Meskipun kecepatan saat digunakan pada komputer terpasang hanya mencapai 2,36 fps, *SSD5* tetap memberikan prediksi *bounding box* dengan tingkat kepercayaan yang tinggi dalam mendeteksi gerbang.

Dalam penelitian sebelumnya tentang perbandingan metode *OpenCV Haar Cascade*, *OpenCV Single Shot Detector*, dan *DLib CNN* dalam sistem deteksi wajah yang dilakukan oleh (Lia Farokhah, 2021), diperoleh hasil analisis perbandingan yang menunjukkan kinerja dari masing-masing metode. Dari ketiga metode ditemukan bahwasanya yang memiliki persentase kinerja terbaik adalah *OpenCV Single Shot Detector* dan *DLib CNN* yang mana masing-masing menunjukkan angka kinerja 80% sedangkan untuk *OpenCV Haar Cascade* hanya memiliki persentase kinerja 20%.

Penelitian terdahulu mengenai sistem penghitungan jumlah pengunjung di sebuah restoran dengan menggunakan kamera berbasis *Single Shot Detector (SSD)* telah dilakukan oleh (Admaja Yosia Pradeska, 2021). Penelitian ini menghasilkan tingkat akurasi sebesar 100% untuk kondisi objek berjalan pelan, akurasi 90% untuk kondisi objek berjalan cepat, dan akurasi 50% dengan kondisi objek sedang berlari.

Penelitian sebelumnya oleh (Takao dkk., 2021) terkait *Deep Learning Single Shot Detector* untuk deteksi otak otomatis dengan gambar CT kombinasi kontras yang ditingkatkan dan tidak ditingkatkan diperoleh hasil sensitivitasnya sebesar 88,7% untuk model yang menggunakan gambar CT dengan kontras ditingkatkan dan tidak ditingkatkan dengan *Positive Predictive Value (PPV)* sebesar 44%. Model yang hanya menggunakan gambar CT dengan kontras memperoleh sensitivitas sebesar 87,6% dan nilai *Positive Predictive Value (PPV)* sebesar 37,2%. Akurasi yang didapatkan tersebut merupakan hasil pemindaian 116 CT dari 116 pasien yang menghasilkan total 659 metastasis. Data yang digunakan dalam training dan validasi sebanyak 428 data dan sisanya digunakan untuk data testing.

Penelitian terbaru yang menggunakan metode *SSD* dengan arsitektur ringan *MobileNet* menghasilkan angka akurasi 100% dengan waktu yang diperlukan untuk mendeteksi dan mengenali setiap tanda 0,317 detik. Penelitian yang dilakukan oleh (Dhaif & El Abbadi, 2024) menjadikan rambu-rambu jalan sebagai objek deteksi. Total dataset yang digunakan adalah 43.000 gambar rambu jalan yang terdiri dari 43 kelas (masing-masing kelas 1.000 gambar).

Penelitian sebelumnya terkait pendeteksi wajah penumpang bus menggunakan metode *Single Shot Detector* berbasis *webcam* yang dilakukan oleh (Wasista dkk., 2024) memperoleh hasil rata-rata akurasi 77,5%. Penelitian ini melibatkan 16 penumpang untuk dijadikan objek deteksi, akan tetapi hanya mampu mendeteksi 12 hingga 13 penumpang, hal ini merupakan pengaruh dari penempatan *webcam* yang tidak bisa melihat dengan jelas ke arah objek dan juga aktivitas pada penumpang yang berlebihan. Untuk meningkatkan akurasi dari sistem yang dibuat, peneliti memberikan saran untuk tempat peletakan *webcam* dapat dipertimbangkan lebih jauh.

Metode *Single Shot Detector* juga pernah digunakan oleh (Shi dkk., 2022) dalam penelitiannya mengenai alat deteksi siklon ekstratropis di belahan bumi utara. Dalam penelitian ini menggunakan tiga kelas dengan total 2.920 gambar yang diambil dari rentang tahun 2017 hingga 2019 dengan

ketentuan gambar dengan selang waktu enam jam untuk setiap pengambilannya. Hasil penelitian menunjukkan mean *Average Precision* (mAP) 86,64% untuk tahap matang dan secara keseluruhan dalam mendeteksi ketiga kelas adalah 79,34%.

2.2 Dasar Teori

2.2.1 Rokok



Gambar 2. 1 Rokok

Rokok merupakan salah satu produk yang berasal dari olahan daun tembakau kering yang dilinting dengan kertas untuk dinikmati dengan cara dibakar dan diisap atau dihirup asapnya. Produk ini menjadi berbahaya karena asap yang muncul dari pembakarannya mengandung 1015 radikal bebas dalam fase gas, 1014 radikal bebas dalam fase tar, serta 4700 senyawa kimia yang kompleks, diantaranya adalah nikotin, tar, dan karbon monoksida (Sampurna dkk., 2023).

Aktivitas merokok sudah mulai dilakukan oleh anak-anak di Indonesia bahkan sebelum berusia 10 tahun. Pengendali Tembakau di ASEAN menyampaikan bahwasannya jumlah tersebut lebih dari 30%, yang artinya mencapai sekitar 20 juta anak mengacu data dari KPAI pada tahun 2017 (Sukarta dkk., 2023).

2.2.2 Zona Larangan Merokok

Zona larangan merokok adalah ruangan atau area yang dinyatakan dilarang untuk kegiatan merokok atau kegiatan memproduksi, menjual, mengiklankan dan/atau mempromosikan produk tembakau (Syafe' dkk., 2021). Dengan diberlakukannya zona larangan merokok, maka area tersebut

bebas dari asap rokok dan produk tembakau lainnya. Tujuan dari penetapan kebijakan ini adalah untuk melindungi kesehatan dari dampak buruk asap rokok, menciptakan lingkungan yang bersih dan sehat, serta mendorong gaya hidup lebih sehat. Zona larangan merokok pada umumnya mencakup berbagai tempat seperti sekolah/kampus, rumah sakit, transportasi umum, restoran, tempat ibadah dan fasilitas umum lainnya.

2.2.3 *Computer Vision*

Computer vision adalah cabang ilmu komputer yang membekali mesin dengan kemampuan "melihat" dan "memahami" gambar serta video. Dengan memanfaatkan algoritma canggih, komputer dapat mengenali wajah, objek, dan bahkan menafsirkan adegan kompleks seperti manusia. Penerapan *computer vision* sangat luas, mulai dari keamanan, otomotif, lingkungan, hingga medis. Singkatnya, *computer vision* memungkinkan mesin untuk memperoleh informasi berharga dari dunia visual dan mengambil tindakan berdasarkan pemahaman tersebut (Sutisna dkk., 2024).

2.2.4 *OpenCV*

Open Source Computer Vision Library atau yang lebih dikenal dengan *OpenCV* adalah perpustakaan sumber terbuka yang dibuat pertama kali oleh Intel pada tahun 1999 dan dikenal sangat populer untuk pemrosesan gambar dan penglihatan komputer. Kemudahan dan ketersediaan banyak fitur dalam *OpenCV* menjadikannya salah satu alat penting yang diperlukan dalam pengembangan aplikasi penglihatan komputer. Berikut adalah beberapa fitur utama *OpenCV*:

- a. Pemrosesan gambar: Memungkinkan memanipulasi gambar seperti pemotongan, pemosisian, dan transformasi.
- b. Pengenalan Pola dan Deteksi Objek: Mendukung pengenalan wajah, deteksi objek, dan pengenalan pola.
- c. Pengolahan Citra: Menyediakan algoritma untuk filterisasi, segmentasi, dan ekstraksi fitur citra.
- d. Kalibrasi Kamera: Memungkinkan kalibrasi kamera dan geometri stereo.
- e. Pemrosesan Video: Dapat memancarkan gambar dengan lebih baik.

OpenCV sudah tersedia dalam berbagai bahasa pemrograman, seperti C++, *Python*, *Java*, dan *MATLAB*, yang membuatnya lebih mudah untuk diintegrasikan ke berbagai platform dan digunakan dalam berbagai aplikasi (Maulana dkk., 2024).

2.2.5 *Machine Learning*

Machine learning adalah bagian dari kecerdasan buatan (Zhuang dkk., 2025) yang mengajarkan komputer untuk mempelajari informasi dari kumpulan data dan membuat prediksi atau tindakan berdasarkan interpretasi data tersebut (Chyan, Arni, dkk., 2024). Dengan kata lain, *machine learning* adalah pemrograman komputer yang menggunakan data masa lalu untuk mempelajari model, sehingga komputer dapat belajar dan memiliki performa terbaiknya (Darmawan Sidik dkk., 2022). Model *machine learning* dapat menggeneralisasi data baru dan beroperasi dengan sangat baik untuk diagnosis gangguan waktu nyata (Pohakar dkk., 2025). Istilah *machine learning* pertama kali dikemukakan oleh beberapa ilmuwan matematika seperti Adrien Marie Legendre, Thomas Bayes dan Andrey Markov pada tahun 1920 dengan mengemukakan dasar-dasar *machine learning* dan konsepnya. Sejak saat itu *machine learning* banyak yang mengembangkan. Salah satu contoh dari penerapan *machine learning* yang cukup terkenal adalah *Deep Blue* yang dibuat oleh IBM pada tahun 1996. Saat ini, algoritma pembelajaran mesin semakin banyak digunakan dalam banyak aspek kehidupan kita, seperti robotika, visi komputer, asisten bahasa, dan sebagainya (Trofimov dkk., 2025).

2.2.6 *Deep Learning*

Deep learning atau pembelajaran mendalam adalah cabang dari *machine learning* yang mana memiliki metode pembelajaran dengan menggunakan jaringan syaraf tiruan *multi-layer*. Jaringan saraf tiruan ini dirancang menyerupai otak manusia, dengan masing-masing *neuron* dihubungkan bersama membentuk jaringan saraf yang sangat kompleks (Claudia Rossi dkk., 2024). *Deep learning* tidak hanya meniru bagaimana

otak manusia bekerja, namun juga berusaha menciptakan jaringan saraf tiruan itu sendiri (Zamachsari & Puspitasari, 2021).

2.2.7 *Python*

Python merupakan bahasa pemrograman interpretatif tujuan umum dengan menekankan keterbacaan kode supaya *sintaks* lebih mudah untuk dipahami. Hal ini yang membuatnya mudah untuk dipelajari baik pemula maupun yang telah menguasai bahasa pemrograman lain. Bahasa ini dirancang oleh Guido van Rossum pada tahun 1991. Hingga saat ini, *python* dikembangkan oleh *Python Software Foundation*. Bahasa ini mendukung hampir semua sistem operasi (Ridho & Niani, 2022). Nama *python* sendiri berasal dari Monty Python. Ketika Guido van Rossum membuatnya, dia juga sedang membaca skrip Sirkus Terbang Monty Python BBC. Menurutnya nama itu singkat dan sedikit misterius. Karena itulah, Guido van Rossum memilih menggunakan nama tersebut untuk bahasa pemrograman yang dibuatnya.


2.2.8 *Single Shot Detector*

Single Shot Detector (SSD) adalah sebuah teknik canggih dalam bidang penglihatan komputer yang memungkinkan komputer untuk mengidentifikasi berbagai objek dalam satu gambar secara bersamaan melalui jaringan saraf tiruan tunggal (Sukusvieri, 2020). Metode ini umumnya menunjukkan kinerja deteksi tinggi dengan efisiensi waktu yang tinggi (Amemiya dkk., 2021).

Jaringan *Single Shot Detector* konvensional terdiri dari jaringan dasar dan jaringan pendeteksi objek, tetapi jaringan ini memiliki masalah degradasi yang serius (Haldorai dkk., 2024). Dalam penelitian ini, metode yang akan digunakan adalah *Single Shot Detector* dengan VGG16 sebagai pengekstrak fitur. Ekstraktor fitur mengambil informasi penting dari gambar dan kemudian dilatih oleh model untuk digunakan dalam pemecahan masalah (Das dkk., 2023). *Single Shot Detector* adalah jenis algoritma satu tahap yang didasarkan pada jaringan syaraf tiruan untuk memprediksi kategori dan posisi objek dalam gambar yang diterima (Chyan, Saptadi, dkk., 2024). Ini adalah salah satu pendekatan yang paling populer di antara *You Look Only Once*

(YOLO) dan *Region-based Convolutional Neural Network* (R-CNN). YOLO dapat memberikan hasil prediksi yang cepat tetapi tidak seakurat R-CNN. Begitu juga dengan RCNN yang memiliki kemampuan untuk memberikan hasil yang akurat namun prosesnya lama jika dibandingkan dengan YOLO. Sedangkan *SSD* dapat memberikan hasil yang lebih akurat (batas deteksi objek yang kecil) dibandingkan algoritma YOLO dan memberikan hasil yang lebih cepat dibandingkan R-CNN (A. Li dkk., 2021).


Dalam mendeteksi objek, *Single Shot Detector* menandai area *bounding box* yang diprediksi kepada koleksi *default bounding box* melalui berbagai skala dan rasio untuk setiap lokasi *feature map*. *SSD* membandingkan objek dengan *default bounding box* dengan berbagai rasio selama masa *training*. Setiap *default box* dengan $\text{IoU} > 0.5$ akan dikategorikan cocok (Ramadan & Laksono, 2023). Adapun pada gambar nomor 2.2 menunjukkan kondisi di mana kotak *default* dan *ground truth* berpotongan.



Gambar 2. 2 (a) *Area of Overlap*; (b) *Area of Union*

Single Shot Detector tersusun dari beberapa proses konvolusi, bagian awal *SSD* menggunakan arsitektur VGG16 (*Visual Geometry Group*). Arsitektur VGG16 merupakan salah satu klasifikasi citra berkualitas tinggi yang memiliki 3 fitur utama yaitu *Multiscale Feature maps*, *Convolutional Predictor*, *Default Box and Aspect Ratio*. Fitur *Multiscale Feature Maps* mengacu pada penggunaan peta fitur dari beberapa tingkat resolusi yang memungkinkan model mendeteksi objek berbagai ukuran. Setiap objek yang sudah terdeteksi akan dikelola oleh fitur *Convolutional Predictor* yang memungkinkan model menghasilkan prediksi langsung dari peta fitur pada setiap lapisan. Sedangkan untuk fitur *Default Box and Aspect Ratio* merupakan sekumpulan kotak pembatas dengan posisi, ukuran, dan rasio

aspek yang telah ditentukan. Model akan memprediksi pergeseran lokasi dan skala dari *default box* untuk menyesuaikan ukuran objek yang terdeteksi, dengan demikian akan memungkinkan model lebih cepat dalam mendeteksi. Pada gambar 6.4 di bawah menunjukkan susunan lapisan dari jaringan pada metode *Single Shot Detector*.



Gambar 2. 3 Arsitektur SSD

Gambar nomor 2,3 menunjukkan arsitektur model yang digunakan untuk mendeteksi objek dalam gambar dengan pendekatan multi-skala. Gambar input pertama kali diproses melalui tulang punggung VGG16, di mana lapisan Conv4_3 bertindak sebagai pengekstrak fitur awal. Lapisan ini mempertahankan resolusi spasial yang cukup tinggi, sehingga sangat efektif untuk mendeteksi objek kecil. Dengan mempertahankan detail spasial, fitur-fitur Conv4_3 memungkinkan model untuk mengidentifikasi karakteristik objek kecil dengan lebih akurat. Memanfaatkan peta fitur dari lapisan ini merupakan salah satu kunci dalam meningkatkan sensitivitas deteksi pada skala kecil.

Setelah melewati lapisan VGG16, citra kemudian diproses lebih lanjut melalui beberapa lapisan konvolusi tambahan, mulai dari Conv7 hingga Conv11_2. Masing-masing lapisan konvolusi tambahan ini menghasilkan peta fitur dengan resolusi yang semakin kecil, seiring dengan bertambahnya kedalaman jaringan. Penurunan resolusi ini dirancang untuk meningkatkan efektivitas dalam mendeteksi objek yang lebih besar, sekaligus memperluas

bidang reseptif jaringan. Output dari setiap peta fitur pada berbagai skala kemudian digunakan dalam lapisan prediksi untuk menghasilkan prediksi lokasi dan kelas objek. Pendekatan ini memungkinkan model untuk melakukan deteksi objek dengan lebih kuat terhadap variasi ukuran dan posisi objek dalam gambar. Adapun rumus operasi konvolusi ditunjukkan pada rumus nomor 1.

$$F_{out} = (F_{in} * W) + b \quad (1)$$

Keterangan:

- F_{in} : *Input feature map*
- W : Kernel (*filter*) konvolusi
- b : Bias

Kemudian SSD akan memprediksi *bounding box* menggunakan rumus nomor 2 dan juga memprediksi kelas dengan menggunakan rumus nomor 3. dengan menggunakan rumus:

$$\begin{aligned} \hat{g}_x &= \frac{g_x - d_x}{d_w} \\ \hat{g}_y &= \frac{g_y - d_y}{d_h} \\ \hat{g}_w &= \log\left(\frac{g_w}{d_w}\right) \\ \hat{g}_h &= \log\left(\frac{g_h}{d_h}\right) \end{aligned} \quad (2)$$

Keterangan:

- g_x, g_y, g_w, g_h : *Ground truth*
- d_x, d_y, d_w, d_h : *Default box*

$$\hat{c}_i = \text{Softmax}(z_i) \quad (3)$$

Keterangan:

- $\hat{c}_i$: *Output mentah dari model (logit)*
- $\hat{z}_i$: Probabilitas kelas

Selanjutnya gambar akan dihitung IoU (*Intersection over Union*) untuk melihat kesesuaian antara *default box* dengan *ground truth*. $IoU > 0.5$ menunjukkan kesesuaian antara prediksi dengan label sebenarnya. Semakin besar nilainya, maka akan dianggap semakin baik hasil prediksinya.


$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}} \quad (4)$$



BAB III

METODE PENELITIAN

Dalam penelitian ini, sistem deteksi aktivitas merokok akan menggunakan metode *Single Shot Detector* dalam pembuatan modelnya.



Gambar 3.1 Alur penelitian


Pada gambar 3.1 menunjukkan alur dari penelitian yang akan dilakukan oleh peneliti, mulai dari studi literatur, dilanjutkan mempersiapkan *dataset* dan dilakukan *preprocessing* pada data yang diperoleh. Setelah data sudah siap, maka akan digunakan dalam pelatihan model untuk memperoleh

3.1 Studi Literatur

Peneliti mengumpulkan beberapa *e-book*, artikel, jurnal, tesis dan disertasi hasil penelitian yang telah dilakukan oleh peneliti sebelumnya, dan juga beberapa laman di internet sebagai media untuk peneliti mempelajari terkait *Machine Learning*, *Deep Learning*, *Computer Vision*, *OpenCV*, *Python*, dan *Single Shot Detector* untuk membantu peneliti menyelesaikan penelitian.

3.2 Persiapan *Dataset*

Dataset yang digunakan dalam penelitian ini didapat dari sumber *Roboflow* dengan jenis data Pascal VOC (*Visual Object Classes*) sejumlah 5658 data. Informasi yang terdapat pada gambar berupa anotasi, label, dan ukuran, dalam *dataset* ini disimpan dalam file xml. *Dataset* akan diproses untuk digunakan dalam tahapan *training* dan *validation* dengan perbandingan jumlah gambar *training* 85:15 *validation*.



Gambar 3. 2 *Dataset*

Pada gambar 3.2 merupakan contoh dari gambar yang ada di dalam *dataset* yang akan digunakan. Setelah diperoleh, *dataset* akan dilakukan *preprocessing* data untuk menyesuaikan gambar yang dibutuhkan dalam pembuatan model deteksi ini.

3.3 *Preprocessing Data*

Preprocessing dataset merupakan serangkaian tindakan yang dilakukan untuk mempersiapkan *dataset* supaya sesuai dengan yang dibutuhkan model dalam pembelajarannya. Tahapan *preprocessing* ini meliputi pemeriksaan *bounding box* dan label yang sudah ada untuk disesuaikan dengan kebutuhan dalam pembuatan model. Gambar yang dirasa tidak sesuai akan disaring untuk dimasukkan ke dalam daftar abai. Kemudian, *dataset* yang sudah

dipisahkan akan dilakukan augmentasi untuk memperkaya keragaman gambar melalui transformasi yang diberikan. Hal ini dilakukan untuk meningkatkan kualitas data serta memastikan konsistensi data sehingga model dapat belajar dengan baik. Selain itu, dengan melakukan *preprocessing* bisa mengurangi potensi *overfitting* dan membuat model lebih *robust* terhadap variasi gambar berupa rotasi, pencahayaan, maupun skala yang berbeda-beda.

3.3.1 Image Augmentation

Augmentasi gambar merupakan cara yang digunakan untuk mengubah dan memodifikasi gambar sesuai dengan ketentuan yang kita inginkan. Tujuan dari penerapan teknik ini adalah untuk meningkatkan kemampuan model dalam mengenali pola dan mengurangi potensi terjadinya *overfitting*. *Overfitting* dalam kecerdasan buatan adalah masalah umum yang terjadi karena model belajar terlalu detail terhadap data latih, sehingga memiliki kinerja yang baik pada saat data latih tetapi buruk ketika mengenali data baru.

Augmentasi gambar bekerja dengan cara menghasilkan variasi gambar yang berbeda dari gambar asli. Variasi ini dihasilkan dari berbagai transformasi yang diterapkan. Pada umumnya transformasi terbagi ke dalam macam-macam kategorinya, seperti transformasi geometris, warna, *noise*, *blurring*, dan pixel, dimana masing-masing kategori transformasi memiliki jenis yang berbeda-beda seperti flipping, rotation, scaling, brightness, contrast, gaussian noise, motion blur, normalization, dan standardization. Pada penelitian ini, transformasi yang digunakan adalah *horizontal flip*, *shift scale rotate*, *CLAHE*, *brightnesscontrast*, *saturations*, *gaussnoise*, dan *resize*.

1. *Horizontal flip*, membalikkan gambar secara horizontal dengan tujuan untuk menambah variasi orientasi objek tanpa mengubah strukturnya.
2. *Shift scale rotate*, merupakan transformasi berupa perubahan gambar asli yang digeser, diperbesar/diperkecil, dan diputar gambarnya dengan batas rotasi tertentu. Hal ini membantu model mengenali objek meskipun posisinya berubah.

3. *CLAHE*, meningkatkan kontras gambar dengan menyesuaikan histogram secara adaptif pada area kecil dalam gambar. Ini digunakan untuk memperjelas detail di area dengan pencahayaan rendah atau tidak merata.
4. *Brightnesscontrast*, transformasi yang dilakukan dengan cara mengubah tingkat kecerahan dan kontras gambar secara acak. Tujuannya adalah mensimulasikan kondisi pencahayaan berbeda dalam dunia nyata.
5. *HueSaturationValue (saturations)*, mengubah warna dasar (*hue*), intensitas warna (*saturasi*), dan tingkat kecerahan (*value*) gambar. Digunakan untuk menambahkan variasi warna sehingga model bisa menyesuaikan banyak kondisi (*robust*) terhadap perubahan warna.
6. *Gaussnoise*, menambahkan *noise* (bintik acak) pada gambar. Transformasi ini mensimulasikan *noise* sensor kamera untuk meningkatkan ketahanan model terhadap data berkualitas rendah yang diberikan.
7. *RandomResizedCrop*, digunakan untuk memotong bagian acak dari gambar dengan ukuran tertentu kemudian mengubah ukuran hasil potongan tersebut ke dimensi yang diinginkan. Transformasi ini membantu model belajar dari berbagai bagian gambar dengan memperkenalkan variasi ke dalam dataset.

3.4 Pembuatan Model


Dalam pembuatan model yang digunakan untuk deteksi aktivitas merokok, peneliti menggunakan *Google Colaboratory* sebagai media untuk menuliskan sintaks dari bahasa pemrograman *python*. Model yang dibuat ini akan menggunakan metode *Single Shot Detector* dalam membantu sistem mendeteksi objek. *Single Shot Detector* dipilih karena memiliki kemampuan menggunakan satu kali bidikan dalam satu *frame* untuk bisa mendeteksi objek yang ada pada gambar atau video. Gambar atau video yang nantinya masuk pada model akan melalui beberapa tahapan lapisan untuk bisa dideteksi.

3.4.1 *Training dan Validation*

Tahapan *training* adalah tahapan ketika model yang sudah dibuat pada *google colab* akan dilatih diauji untuk menilai performa dari model yang sudah dilatih sebelumnya. Data *training* mendapatkan lebih banyak data karena kebutuhan sistem untuk melatih model. Pada data yang digunakan ini sudah terdapat *bounding box* pada setiap gambarnya yang tentunya memudahkan peneliti untuk melatih model mengenali objek yang akan dijadikan kelas. Tahapan *training* ini meliputi penyesuaian jumlah *epoch* yang nantinya akan mempengaruhi performa model yang dihasilkan. Apabila *epoch* terlalu banyak, model akan cenderung mempelajari data terlalu detail, akibatnya akan kehilangan kemampuan generalisasi. Tujuan dari tahapan ini adalah untuk menilai performa dari model yang sudah dilatih sebelumnya.

3.5 Pengujian

Model yang telah dilatih dengan gambar-gambar yang menunjukkan kondisi merokok dan tidak merokok ini akan digunakan dalam pengujian. Model ini memungkinkan kita untuk melihat hasil deteksi terhadap gambar atau kondisi baru yang belum pernah dipelajari sebelumnya. *Library cv2 (OpenCV)* akan digunakan untuk mengakses kamera *webcam* secara *real-time*. Ketika program berjalan, kamera akan terhubung dan terbuka serta melakukan deteksi aktivitas yang ada di dalam bingkai kamera. Proses dari langkah pengujian ini dapat kita lihat pada gambar 3.5 sebagai berikut.



Gambar 3. 3 Alur pengujian

3.6 Evaluasi

Pada tahapan evaluasi model, peneliti akan menggunakan beberapa matrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *f1-score*. Untuk rumus dari masing-masing metrik adalah sebagai berikut:

- Accuracy* merupakan proses untuk mengukur seberapa sering model membuat prediksi yang benar dibandingkan dengan seluruh prediksi yang dilakukan.

$$\frac{TP+TN}{Total} \quad (5)$$

- Precision* adalah persentase deteksi positif yang benar (benar terdeteksi sebagai aktivitas merokok) dibandingkan dengan semua deteksi positif.

$$\frac{TP}{TP+FP} \quad (6)$$

- c. *Recall* merupakan persentase aktivitas merokok yang berhasil terdeteksi dibandingkan dengan semua aktivitas merokok yang ada dalam *dataset*.

$$\frac{TP}{TP+FN} \quad (7)$$

- d. *F1-Score* merupakan metrik yang mengukur keseimbangan antara *precision* dan *recall* dalam satu nilai. Semakin tinggi nilainya, maka semakin baik performa model secara keseluruhan dalam mendeteksi dan tidak salah deteksi.

$$\frac{2}{\frac{1}{Precision} + \frac{1}{Recall}} \quad (8)$$

Matrik evaluasi ini diperoleh dari hasil *confusion matrix*, adalah sebuah tabel yang menunjukkan jumlah klasifikasi dari hasil data uji benar dan salah.

Tabel 3. 1 *Confusion matrix*

	Prediksi Positif	Prediksi Negatif
Positif	TP	FN
Negatif	FP	TN

Keterangan:

TP: *True Positive*

TN: *True Negative*

FP: *False Positive*

FN: *False Negatives*

3.7 *Software*

Dalam penelitian ini menggunakan beberapa *software* yang akan digunakan untuk mengolah data, pembuatan model serta evaluasi hasil. Berikut daftar *software* yang akan digunakan :

1. *Pandas*

Pustaka ini digunakan dalam proses manipulasi dan analisis data dalam bentuk *DataFrame*. *Pandas* digunakan pada tahapan *preprocessing* untuk mengelola informasi anotasi atau metrik evaluasi model.

2. *NumPy*

Pustaka ini digunakan untuk komputasi numerik karena memiliki fungsi matematika yang cepat dan efisien. Kemampuannya digunakan untuk mengatur koordinat *bounding box* dan transformasi data dalam pembuatan model deteksi.

3. *Matplotlib/Seaborn*

Matplotlib digunakan untuk membuat grafik dasar seperti plot garis, scatter plot, dan histogram, sementara *Seaborn* menyediakan tampilan yang lebih menarik dan mendukung analisis statistik. Keduanya berguna dalam menampilkan metrik hasil training seperti loss dan akurasi. Dalam konteks proyek, mereka juga bisa digunakan untuk memvisualisasikan gambar beserta *bounding box* hasil prediksi model.

4. *Torch (PyTorch)*

Torch atau *PyTorch* merupakan *framework deep learning open-source* yang fleksibel dan banyak digunakan dalam riset dan produksi. *PyTorch* menyediakan alat untuk membuat dan melatih model *neural network*, terutama CNN untuk deteksi objek. *Torch* digunakan untuk membuat arsitektur *SSD* dan melatih model deteksi aktivitas merokok.

5. *Albumentations*

Albumentations merupakan pustaka augmentasi gambar yang cepat dan fleksibel. Pustaka ini menyediakan berbagai transformasi seperti *flipping*, *rotation*, *blur*, *brightness*, dan lain-lain, yang berguna untuk meningkatkan keberagaman *dataset*. *Albumentations* lebih cepat dan lebih mudah dikonfigurasi dibanding pustaka transformasi lainnya.

6. *Pycocotools*

Pycocotools digunakan ketika mengkonversi atau mengevaluasi *dataset* menggunakan metrik standar COCO seperti mAP. *Pycocotools* sudah banyak digunakan dalam evaluasi model *object detection*.

7. *Google Colaboratory*

Google Colab salah satu platform berbasis *cloud* yang serupa dengan *Jupyter Notebook* dengan menawarkan keunggulan berupa akses gratis ke GPU dan TPU (*Tensor Processing Unit*). Ini sangat berguna ketika *dataset* besar digunakan atau ketika pelatihan model *deep learning* memerlukan waktu komputasi yang lama.

3.8 **Hardware**

1. Kamera


Kamera merupakan suatu set alat yang terintegrasi, digunakan untuk menghasilkan tampilan gambar dan juga untuk merakam sebuah video (Desipriani dkk., 2022). Dengan memanfaatkan lensa untuk mengumpulkan cahaya, kamera memfokuskan cahaya tersebut ke sensor atau film sehingga menghasilkan citra yang dapat dilihat. Sebagai alat yang sangat serbaguna, kamera memiliki banyak fungsi, mulai dari mengabadikan momen berharga dalam kehidupan sehari-hari hingga digunakan dalam bidang profesional seperti fotografi, videografi, dan jurnalistik.

BAB IV


HASIL DAN ANALISIS PENELITIAN

4.1 Hasil

Data yang terkumpul pada penelitian ini sejumlah 5658 gambar yang bersumber dari website *roboflow* pada link berikut: https://universe.roboflow.com/visionwork/smoking_person/dataset/3 dimana data terbagi untuk tahapan *train*, *valid*, dan *test* dengan perbandingan 94:5:1. Data yang diperoleh sudah memiliki *bounding box* yang tersimpan dalam *file* tipe *.xml* dengan kelas “cigarette”, “smoke”, “vape”, “nonsmoke”, dan “person”. Pada gambar 4.1 dan 4.2 menunjukkan kondisi awal dari *dataset* yang diperoleh dari roboflow.



Gambar 4. 1 Folder awal



Gambar 4. 2 Gambar dan anotasi dalam satu folder

Dalam pembuatan model, kita akan menggunakan dataset dengan komposisi 85:15 untuk *train* dan *valid*, artinya data yang kita peroleh akan disatukan semua. Data tersebut disatukan dalam satu *folder* dengan *subfolder* *annotation* yang berisi *file* anotasi dan *images* yang menyimpan seluruh *file* gambar seperti pada gambar 4.3 untuk digunakan dalam tahapan pembuatan model. Struktur *folder* ini sangat penting untuk memastikan bahwa *pipeline*

pemrosesan data, pelatihan, dan evaluasi model dapat berjalan dengan baik tanpa *error*. Dengan menyatukan data ke dalam struktur *folder* yang rapi, proses augmentasi, pembacaan *file*, serta pemetaan gambar dengan anotasinya akan lebih efisien dan minim kesalahan saat dieksekusi dalam kode.




Gambar 4. 3 *Folder* baru

Sebelum dilakukan *split* data, data akan dilakukan *label mapping* yang bertujuan untuk menyederhanakan dan menyatukan berbagai variasi label yang ada di dataset agar menjadi seragam dan mudah diproses oleh model. Pada pembuatan model deteksi aktivitas merokok terdapat label seperti “cigarette”, “smoke”, dan “vape” yang semuanya sebenarnya menunjukkan satu kategori, yaitu “merokok”. Dengan *label mapping*, semua variasi ini dapat dipetakan menjadi satu label umum seperti “merokok” atau angka representatif seperti angka 1.

```
label_mapping = {
    "cigarette": 1, # Ubah cigarette jadi "merokok"
    "smoke": 1, # Ubah smoke jadi "merokok"
    "vape": 1, # Ubah smoke jadi "merokok"
    "person": 0, # Ubah person jadi "tidak merokok"
    "nonsmoke": 0 # Ubah nonsmoke jadi "tidak merokok"
}
```

Gambar 4. 4 *Label mapping*

Data tersebut kemudian dilakukan augmentasi untuk memperkaya keragaman data menggunakan berbagai transformasi dengan hasil seperti gambar 4.5.




Gambar 4. 5 Hasil augmentasi

Hasil pembuatan model yang dilakukan dengan tahapan *training* dan *validation* menggunakan dataset yang ada menghasilkan grafik loss seperti gambar 4.6. Grafik tersebut menunjukkan hasil pelatihan model selama 60 *epoch*, di mana nilai *training loss* (garis biru) dan *validation loss* (garis merah) mengalami penurunan secara konsisten. Pada awal pelatihan, kedua nilai *loss* tercatat cukup tinggi, namun mengalami penurunan signifikan hingga sekitar *epoch* ke-30. Setelahnya, tren penurunan cenderung melandai dan stabil hingga akhir *epoch*, yang terlihat dari grafik yang tidak menunjukkan fluktuasi tajam. Data ini menunjukkan bahwa model berhasil mengurangi *error* pada data pelatihan maupun validasi sepanjang proses *training*.


Selain itu, hasil grafik memperlihatkan bahwa nilai *training loss* cenderung sedikit lebih tinggi dibandingkan *validation loss* pada sebagian besar *epoch*. Pola ini menunjukkan bahwa model mampu mempertahankan performa yang stabil pada data validasi meskipun terus belajar dari data pelatihan. Berdasarkan hasil ini, dapat disimpulkan bahwa model tidak

mengalami *overfitting* secara signifikan, dan generalisasi terhadap data validasi berjalan dengan baik. Dengan demikian, hasil penelitian menunjukkan bahwa proses pelatihan model berjalan secara efektif dan menghasilkan performa yang baik.



Gambar 4. 6 Grafik *loss*

Model kemudian diunduh dalam bentuk .pth dan dilakukan pengujian menggunakan *jupyter notebook*. Adapun cara menjalankannya, pertama memastikan model yang sudah dilatih sebelumnya melalui tahapan proses *taining* dan *validation*, serta memastikan *file* model berada pada tempat yang sama dengan *file* kode program sistem deteksi aktivitas merokok. Apabila sudah dipastikan dalam posisi yang sesuai, maka program bisa dijalankan.



Gambar 4. 7 Tampilan ketika mendeteksi rokok

Gambar 4.7 menunjukkan hasil pengujian dari sistem deteksi aktivitas merokok yang telah dikembangkan, di mana sistem mampu mengenali keberadaan seseorang yang sedang merokok dengan cukup akurat. Pada tampilan hasil tersebut, rokok yang sedang dipegang oleh seseorang dalam gambar berhasil terdeteksi dan secara otomatis diberi penanda berupa kotak (*bounding box*) pada area yang mengindikasikan objek rokok. Selain kotak deteksi, *output* sistem juga menampilkan label berupa tulisan "rokok" yang menunjukkan klasifikasi objek, serta dilengkapi dengan nilai *confidence score* yang merepresentasikan tingkat keyakinan model terhadap deteksi tersebut. Nilai *confidence score* ini berfungsi sebagai indikator sejauh mana model yakin bahwa objek yang terdeteksi memang merupakan rokok, sehingga mendukung validitas hasil deteksi yang ditampilkan pada layar.

4.2 Analisa

Pada model deteksi aktivitas merokok ini dibuat dengan beberapa parameter yang sebelumnya sudah ditentukan nilainya, seperti pada tabel 4.1 berikut:

Tabel 4. 1 *Hyperparameter*


Parameter	Nilai
Batch Size	4
Epoch	60
Learning Rate	0.00003
Optimizer	Adam


Tabel 4.1 menampilkan konfigurasi *hyperparameter* yang digunakan dalam proses pelatihan model deteksi aktivitas merokok. *Batch size* ditetapkan sebesar 4, yang berarti model memproses empat gambar sekaligus dalam satu iterasi selama pelatihan, membantu dalam stabilisasi pembaruan bobot meskipun dengan sumber daya terbatas. Proses pelatihan dilakukan selama 40 *epoch*, di mana satu *epoch* merepresentasikan satu kali siklus penuh melalui seluruh dataset pelatihan, memberikan model kesempatan yang cukup untuk belajar dari data. *Learning rate* yang digunakan adalah


sebesar 0.00003, nilai yang kecil ini bertujuan agar proses pembaruan bobot berlangsung secara perlahan dan stabil, sehingga dapat menghindari risiko overshooting atau ketidakkonvergenan. Adapun algoritma optimisasi yang digunakan adalah Adam (*Adaptive Moment Estimation*), yang merupakan optimizer populer karena kemampuannya menyesuaikan *learning rate* selama pelatihan secara adaptif berdasarkan momen pertama dan kedua dari gradien, sehingga mempercepat dan menstabilkan proses konvergensi model.




Dengan menggunakan parameter dengan nilai tersebut, diperoleh hasil pengujian sebagaimana dalam tabel 4.2 di bawah ini:



Tabel 4. 2 Hasil pengujian


No	Hasil	Pred	Act	Conf. Score	Threshold				
					0.5	0.6	0.7	0.8	0.9
1		Rokok	Rokok	0.89	TP	TP	TP	TP	FN
2		Rokok	Rokok	0.53	TP	FN	FN	FN	FN
3		Rokok	Rokok	0.73	TP	TP	TP	FN	FN


4		Rokok	Rokok	0.70	TP	TP	TP	FN	FN
5		Rokok	Rokok	0.81	TP	TP	TP	TP	FN
6		Rokok	Rokok	0.83	TP	TP	TP	TP	FN
7		Rokok	Rokok	0.77	TP	TP	TP	FN	FN
8		Rokok	Rokok	0.83	TP	TP	TP	TP	FN
9		Rokok	Rokok	0.83	TP	TP	TP	TP	FN


10		Rokok	Rokok	0.51	TP	FN	FN	FN	FN
11		Rokok	Rokok	0.74	TP	TP	TP	FN	FN
12		Rokok	Rokok	0.87	TP	TP	TP	TP	FN
13		Rokok	Rokok	0.72	TP	TP	TP	FN	FN
14		Rokok	Rokok	0.90	TP	TP	TP	TP	TP
15		Rokok	Rokok	0.91	TP	TP	TP	TP	TP

16		Rokok	Rokok	0.58	TP	FN	FN	FN	FN
17		Rokok	Rokok	0.78	TP	TP	TP	FN	FN
18		Rokok	Rokok	0.70	TP	TP	TP	FN	FN
19		Rokok	Rokok	0.93	TP	TP	TP	TP	TP
20		Rokok	Rokok	0.71	TP	TP	TP	FN	FN
21		Rokok	Rokok	0.95	TP	TP	TP	TP	TP

22		Rokok	Rokok	0.82	TP	TP	TP	TP	FN
23		Rokok	Rokok	0.69	TP	TP	FN	FN	FN
24		Rokok	Rokok	0.53	TP	FN	FN	FN	FN
25		Rokok	Rokok	0.75	TP	TP	TP	FN	FN
26		Tidak	Rokok	0.62	TP	TP	FN	FN	FN
27		Rokok	Rokok	0.71	TP	TP	TP	FN	FN

28		Rokok	Rokok	0.62	TP	TP	FN	FN	FN
29		Rokok	Rokok	0.82	TP	TP	TP	TP	FN
30		Rokok	Rokok	0.75	TP	TP	TP	FN	FN
31		Rokok	Rokok	0.93	TP	TP	TP	TP	TP
32		Rokok	Rokok	0.90	TP	TP	TP	TP	TP
33		Rokok	Rokok	0.81	TP	TP	TP	TP	FN

34		Rokok	Rokok	0.59	TP	FN	FN	FN	FN
35		Rokok	Rokok	0.75	TP	TP	TP	FN	FN
36		Rokok	Rokok	0.77	TP	TP	TP	FN	FN
37		Rokok	Rokok	0.87	TP	TP	TP	TP	FN
38		Rokok	Rokok	0.77	TP	TP	TP	FN	FN
39		Tidak	Tidak	0.0	TN	TN	TN	TN	TN

40		Rokok	Tidak	0.83	FP	FP	FP	FP	TN
----	---	-------	-------	------	----	----	----	----	----

Evaluasi model ini dilakukan dengan menggunakan beberapa metrik penting, yaitu *accuracy*, *precision*, *recall*, dan *f1-score*. Metrik *accuracy* dihitung menggunakan rumus nomor 5 dan berfungsi untuk mengukur seberapa besar proporsi prediksi yang benar dibandingkan dengan seluruh data yang diuji. Semakin tinggi nilai *accuracy* yang diperoleh, maka semakin baik pula kinerja model secara keseluruhan karena menunjukkan kemampuan model dalam mengenali pola secara umum. *Precision* dihitung menggunakan rumus nomor 6 dan digunakan untuk melihat seberapa akurat model saat memprediksi kelas positif, yaitu berapa banyak prediksi positif yang benar dibandingkan seluruh prediksi positif. Semakin tinggi nilai *precision*, maka semakin sedikit prediksi positif yang salah dilakukan oleh model, sehingga tingkat kesalahan dalam mendeteksi kelas positif dapat diminimalkan. *Recall*, yang dihitung menggunakan rumus nomor 7, digunakan untuk mengukur seberapa banyak data positif yang berhasil terdeteksi oleh model dibandingkan dengan seluruh data positif yang ada. Nilai *recall* yang tinggi menunjukkan bahwa semakin sedikit data positif yang terlewatkan atau tidak terdeteksi oleh model.

Selain itu, *f1-score* yang dihitung dengan rumus nomor 8 merupakan metrik penting yang memberikan gambaran kinerja model secara lebih menyeluruh. *F1-score* menghitung rata-rata harmonis antara *precision* dan *recall* sehingga memberikan keseimbangan antara kedua metrik tersebut. Nilai *f1-score* yang tinggi menunjukkan bahwa model mampu menjaga keseimbangan antara kemampuan mendeteksi data positif (*recall*) dan ketepatan dalam melakukan prediksi positif (*precision*), sehingga kinerjanya dapat dinilai lebih stabil dan andal dalam menghadapi data yang tidak

seimbang atau imbalanced dataset. Berdasarkan hasil pengujian yang telah dilakukan, diperoleh nilai dari masing-masing metrik ini yang mencerminkan performa model dalam memproses data uji. Hasil evaluasi ini menjadi landasan penting untuk menilai apakah model sudah layak digunakan pada aplikasi nyata atau masih memerlukan perbaikan lebih lanjut, baik dari sisi arsitektur, data latih, maupun parameter training yang digunakan. Adapun dari hasil pengujian yang dilakukan diperoleh hasil sebagai berikut:

1. Pada nilai *threshold* 0.5 menghasilkan sebanyak 38 *true positive*, 1 *false positive*, 1 *true negative*, dan 0 *false negative*. Sehingga diperoleh nilai *accuracy* sebesar 97,5%, *precision* sebesar 97,4%, *recall* sebesar 100%, dan *f1-score* sebesar 98,7%.
2. Pada nilai *threshold* 0.6 menghasilkan sebanyak 33 *true positive*, 1 *false positive*, 1 *true negative*, dan 5 *false negative*. Sehingga diperoleh nilai *accuracy* sebesar 85%, *precision* sebesar 97%, *recall* sebesar 86,8%, dan *f1-score* sebesar 91,6%.
3. Pada nilai *threshold* 0.7 menghasilkan sebanyak 30 *true positive*, 1 *false positive*, 1 *true negative*, dan 8 *false negative*. Sehingga diperoleh nilai *accuracy* sebesar 77,5%, *precision* sebesar 96,7%, *recall* sebesar 78,9%, dan *f1-score* sebesar 86,9%.
4. Pada nilai *threshold* 0.8 menghasilkan sebanyak 16 *true positive*, 1 *false positive*, 1 *true negative*, dan 22 *false negative*. Sehingga diperoleh nilai *accuracy* sebesar 42,5%, *precision* sebesar 94,1%, *recall* sebesar 42,1%, dan *f1-score* sebesar 58,1%.
5. Pada nilai *threshold* 0.9 menghasilkan sebanyak 6 *true positive*, 0 *false positive*, 2 *true negative*, 32 *false negative*. Sehingga diperoleh nilai *accuracy* sebesar 20%, *precision* sebesar 100%, *recall* sebesar 15,7%, dan *f1-score* sebesar 27,1%.

Tabel 4. 3 Hasil evaluasi

Nilai	Threshold				
	0.5	0.6	0.7	0.8	0.9
<i>True Positive</i>	38	33	30	16	6
<i>False Positive</i>	1	1	1	1	0
<i>True Negative</i>	1	1	1	1	2
<i>False Negative</i>	0	5	8	22	32
<i>Accuracy</i>	0.975	0.85	0.775	0.425	0.2
<i>Precision</i>	0.974	0.97	0.967	0.941	1
<i>Recall</i>	1	0.868	0.789	0.421	0.157
<i>F1-Score</i>	0.987	0.916	0.869	0.581	0.271

Analisis performa model dilakukan dengan mengamati pengaruh perubahan nilai *threshold* terhadap sejumlah metrik evaluasi, yaitu *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), *False Negative* (FN), *accuracy*, *precision*, *recall*, dan *f1-score*. Berdasarkan hasil yang diperoleh, terlihat bahwa nilai TP menurun secara signifikan seiring meningkatnya *threshold*, dari 38 pada *threshold* 0,5 menjadi hanya 6 pada *threshold* 0,9. Hal ini menunjukkan bahwa model menjadi semakin konservatif dalam memutuskan prediksi positif saat *threshold* dinaikkan, sehingga semakin banyak kasus positif yang tidak dikenali sebagai positif oleh model. Sementara itu, nilai FP tetap stabil pada angka 1 dan bahkan turun menjadi 0 pada *threshold* 0,9, yang menunjukkan bahwa model semakin jarang salah mengklasifikasikan data negatif sebagai positif saat *threshold* diperketat. Nilai FN meningkat tajam dari 0 menjadi 32, yang menggambarkan semakin banyaknya kasus positif yang terlewatkan saat *threshold* naik.

Nilai *accuracy* juga mengalami penurunan drastis, dari 0,975 pada *threshold* 0,5 menjadi hanya 0,2 pada *threshold* 0,9, yang mencerminkan penurunan performa keseluruhan model. *Precision* awalnya cukup tinggi di angka 0,974, sedikit menurun di *threshold* menengah, tetapi mencapai nilai sempurna (1) pada *threshold* tertinggi karena tidak ada FP, meskipun hal ini

terjadi dengan mengorbankan *recall*. *Recall* sendiri turun signifikan dari 1 menjadi 0,157, yang menunjukkan penurunan kemampuan model dalam menangkap kasus positif. Akibat dari turunnya *recall*, nilai *f1-score* juga ikut turun drastis dari 0,987 menjadi hanya 0,271 di *threshold* 0,9. Secara keseluruhan, *threshold* 0,5 memberikan hasil terbaik dengan nilai metrik yang paling seimbang dan tinggi, khususnya dalam hal *accuracy*, *precision*, *recall*, dan *f1-score*. Oleh karena itu, *threshold* 0,5 direkomendasikan sebagai ambang keputusan optimal dalam penerapan model ini.



BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa model deteksi aktivitas merokok berbasis *Single Shot Detector (SSD)* dengan *backbone* VGG16 mampu memberikan performa deteksi yang baik, khususnya pada *threshold* 0,5. Pada nilai *threshold* tersebut, model mencapai nilai akurasi sebesar 97,5%, *precision* sebesar 97,4%, *recall* sempurna sebesar 100%, dan *F1-score* sebesar 98,7%, yang menunjukkan keseimbangan antara kemampuan model dalam mengenali objek merokok dan meminimalkan kesalahan prediksi. Peningkatan *threshold* secara bertahap terbukti menurunkan *recall* dan *F1-score* secara signifikan, meskipun *precision* sempat meningkat. Hal ini mengindikasikan bahwa model menjadi terlalu selektif dan kehilangan banyak deteksi positif ketika *threshold* terlalu tinggi. Oleh karena itu, *threshold* 0,5 direkomendasikan sebagai nilai optimal dalam implementasi model ini, karena memberikan keseimbangan terbaik antara sensitivitas dan ketepatan dalam mendeteksi aktivitas merokok.


5.2 Saran

Berikut adalah saran yang dapat dipertimbangkan untuk pengembangan dan perbaikan model deteksi aktivitas merokok di masa mendatang. Meskipun model *SSD* dengan *backbone* VGG16 telah menunjukkan performa yang baik pada *threshold* 0,5, masih terdapat beberapa aspek yang dapat ditingkatkan untuk mencapai akurasi dan generalisasi yang lebih baik pada berbagai kondisi nyata. Selain itu, pemilihan *threshold* yang optimal juga perlu disesuaikan dengan kebutuhan aplikasi, apakah lebih mementingkan sensitivitas atau ketepatan.

Beberapa saran pengembangan ke depan adalah sebagai berikut:

1. Mengeksplorasi penggunaan *backbone* lain seperti *ResNet*, *EfficientNet*, atau *MobileNet* untuk meningkatkan akurasi sekaligus efisiensi komputasi.
2. Menambah variasi data latih, terutama dari lingkungan dan sudut pandang yang berbeda, agar model lebih *robust* terhadap variasi nyata di lapangan.
3. Menggunakan teknik augmentasi data yang lebih beragam untuk memperkuat kemampuan generalisasi model.
4. Melakukan evaluasi menggunakan *dataset* eksternal atau video *real-time* untuk menguji performa model dalam situasi sesungguhnya.
5. Menerapkan teknik *hyperparameter tuning* secara sistematis untuk mendapatkan kombinasi parameter yang optimal.
6. Mengembangkan aplikasi berbasis web atau mobile yang dapat memanfaatkan model ini secara langsung untuk kebutuhan pemantauan atau deteksi otomatis.

Dengan mengimplementasikan saran-saran tersebut, diharapkan sistem deteksi ini dapat terus ditingkatkan performanya menjadi lebih baik dan dapat memberikan kebermanfaatan secara luas bagi masyarakat dalam menekan angka pelanggaran aktivitas merokok pada area yang dilarang.



DAFTAR PUSTAKA

- Admaja Yosia Pradeska. (2021). *Sistem Penghitung Jumlah Pengunjung di Restoran Menggunakan Kamera Berbasis Single Shot Detector (SSD)*.
- Amemiya, S., Takao, H., Kato, S., Yamashita, H., Sakamoto, N., & Abe, O. (2021). Automatic detection of brain metastases on contrast-enhanced CT with deep-learning feature-fused single-shot detectors. *European Journal of Radiology*, 136. <https://doi.org/10.1016/j.ejrad.2021.109577>
- Appolon, G., Oren, E., Pulvers, K., Romero, D., Hoh, E., Dodder, N. G., Wong, J., Nynas, K., Tracey, L. R., Lemus, H., & Novotny, T. E. (2024). Nitrosamine and nicotine exposure after switching from filtered to unfiltered cigarette smoking: a crossover clinical trial. *Tobacco Control*. <https://doi.org/10.1136/tc-2024-058765>
- Bai, D., Sun, Y., Tao, B., Tong, X., Xu, M., Jiang, G., Chen, B., Cao, Y., Sun, N., & Li, Z. (2022). Improved single shot multibox detector target detection method based on deep feature fusion. *Concurrency and Computation: Practice and Experience*, 34(4). <https://doi.org/10.1002/cpe.6614>
- Chaturvedi, M., Rashid, M. A., & Paliwal, K. K. (2025). RNA structure prediction using deep learning — A comprehensive review. Dalam *Computers in Biology and Medicine* (Vol. 188). Elsevier Ltd. <https://doi.org/10.1016/j.combiomed.2025.109845>
- Chyan, P., Arni, S., Sofyan, M., Thayf, S., Puspasari, I., Fitri, A., Masruriyah, N., Siregar, A. M., Andisana, S., Widyastuti, R., Akhriza, T. M., Anwar, K., Rahayu, W., Handayani, V. A., & Abdal, N. M. (2024). *Pengantar Machine Learning PT. Mifandi Mandiri Digital*.
- Chyan, P., Saptadi, N. T. S., & Leda, J. M. (2024). Small Object Detection Approach Based on Enhanced Single-Shot Detector for Detection and Recognition of Indonesian Traffic Signs. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 18(4), 2653–2662. <https://doi.org/10.30598/barekengvol18iss4pp2653-2662>
- Claudia Rossi, I., Armanto, & Hasanah Bimastari Aviani, T. (2024). *Penerapan Metode Deep Learning pada Sistem Pendeteksi Gambar Notasi Balok*. 2(12), 86–96. <https://ejournal.warunayama.org/kohesi>
- Darmawan Sidik, A., Ansawarman, A., Kunci, K., Kendaraan Bermotor, J., Regresi, M., & Jalan, F. (2022). Prediksi Jumlah Kendaraan Bermotor Menggunakan Machine Learning. *Formosa Journal of Multidisciplinary Research (FJMR)*, 1(3), 559–568. <https://doi.org/10.55927>

- Das, S., Ayus, I., & Gupta, D. (2023). A comprehensive review of COVID-19 detection with machine learning and deep learning techniques. *Health and Technology*, 13(4), 679–692. <https://doi.org/10.1007/s12553-023-00757-z>
- Desipriani, Suprianingsih, & Fahzurrahman, M. (2022). Pelatihan Beauty Shot Photography dengan Kamera Handphone pada Murid Tatarias Pengantin di LKP Lelly Medan Marelan. *Journal of Community Dedication*, 2, 141–150.
- Dhaif, Z. S., & El Abbadi, N. K. (2024). Road Signs Detection Using SSD MobileNetV2. *Karbala International Journal of Modern Science*, 10(4), 474–484. <https://doi.org/10.33640/2405-609X.3373>
- Haldorai, A., Lincy R, B., M, S., & Balakrishnan, M. (2024). An improved single shot detection method for smart vision-based water garbage cleaning robot. *Cognitive Robotics*, 4, 19–29. <https://doi.org/10.1016/j.cogr.2023.11.002>
- Hecht, S. S., & Hatsukami, D. K. (2022). Smokeless tobacco and cigarette smoking: chemical mechanisms and cancer prevention. Dalam *Nature Reviews Cancer* (Vol. 22, Nomor 3, hlm. 143–155). Nature Research. <https://doi.org/10.1038/s41568-021-00423-4>
- Huang, M., Xia, Y., Li, K., Shao, F., Feng, Z., Li, T., Azin, M., & Demehri, S. (2023). Carcinogen exposure enhances cancer immunogenicity by blocking the development of an immunosuppressive tumor microenvironment. *The Journal of clinical investigation*, 133(20). <https://doi.org/10.1172/JCI166494>
- Latin, I., & Transactions, A. (2019). Gate Detection for Micro Aerial Vehicles Using a Single Shot Detector. Dalam *IEEE Latin America Transactions* (Vol. 17, Nomor 12).
- Li, A., Zhu, X., He, S., & Xia, J. (2021). Water surface object detection using panoramic vision based on improved single-shot multibox detector. *Eurasip Journal on Advances in Signal Processing*, 2021(1). <https://doi.org/10.1186/s13634-021-00831-6>
- Li, Y., & Hecht, S. S. (2022). Metabolic Activation and DNA Interactions of Carcinogenic N-Nitrosamines to Which Humans Are Commonly Exposed. Dalam *International Journal of Molecular Sciences* (Vol. 23, Nomor 9). MDPI. <https://doi.org/10.3390/ijms23094559>
- Lia Farokhah. (2021). Perbandingan Metode Deteksi Wajah Menggunakan OpenCV Haar Cascade, OpenCV Single Shot Multibox Detector (SSD) dan DLib CNN. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(3), 609–614. <https://doi.org/10.29207/resti.v5i3.3125>
- Lysova, N., Solari, F., & Montanari, R. (2025). Investigating Research Trends in Computer Vision for Food Quality Control: A Bibliometric Approach.

Procedia Computer Science, 253, 1923–1932.
<https://doi.org/10.1016/j.procs.2025.01.254>

Magalhães, S. A., Castro, L., Moreira, G., Dos Santos, F. N., Cunha, M., Dias, J., & Moreira, A. P. (2021). Evaluating the single-shot multibox detector and yolo deep learning models for the detection of tomatoes in a greenhouse. *Sensors*, 21(10). <https://doi.org/10.3390/s21103569>

Magalhães, S. C., dos Santos, F. N., Machado, P., Moreira, A. P., & Dias, J. (2023). Benchmarking edge computing devices for grape bunches and trunks detection using accelerated object detection single shot multibox deep learning models. *Engineering Applications of Artificial Intelligence*, 117. <https://doi.org/10.1016/j.engappai.2022.105604>

Marwanto, A. (2024). An Improvement of Apple Leaf Diseases Detection Using Convolutional Neural Network Methods Based on Mobile Systems. *International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*, 440–447. <https://doi.org/10.1109/EECSI63442.2024.10776345>

Maulana, A., Auliatunnajah, F., Rosidin, N., Ramadien Rizki Darmawan, M., & Rosyani, P. (2024). Implementasi OpenCV dengan Metode Image Thresholding pada Gambar. *Jurnal Artificial Inteligent dan Sistem Penunjang Keputusan*, 2(1). <https://jurnalmahasiswa.com/index.php/aidanspk>

Miao, X., Liu, X., Chen, J., Zhuang, S., Fan, J., & Jiang, H. (2019). Insulator detection in aerial images for transmission line inspection using single shot multibox detector. *IEEE Access*, 7, 9945–9956. <https://doi.org/10.1109/ACCESS.2019.2891123>

Pohakar, P., Gandhi, R., Hans, S., Sharma, G., & Bokoro, P. N. (2025). Analysis of Multiple Faults in Induction Motor Using Machine Learning Techniques. *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, 101007. <https://doi.org/10.1016/j.prime.2025.101007>

Ramadan, A. K., & Laksono, S. B. (2023). *Rancang Bangun Aplikasi Deteksi Objek Untuk Menghitung Jumlah Pengunjung Restoran Berbasis Computer Vision*. <https://journals.upi-yai.ac.id/index.php/ikraith-informatika/issue/archive>

Riansyah, A. (2021). Applying fuzzy proportional integral derivative on internet of things for figs greenhouse. *IAES International Journal of Artificial Intelligence*, 10(3), 536–544. <https://doi.org/10.11591/ijai.v10.i3.pp536-544>

Riansyah, A. (2025). Teachers in the Digital Age: Sentiment Analysis of the Merdeka Mengajar Platform in the Indonesian Curriculum Policy. *Journal of Information Systems Engineering and Management*, 10, 137–147. <https://doi.org/10.52783/jisem.v10i15s.2437>

- Ridho, A., & Niani, C. R. (2022). Implementasi Enkripsi Dengan Vigenere Cipher dan Reverse Cipher Menggunakan Bahasa Pemrograman Python. *Jurnal Teknologi Informasi*, 1(1).
- Sampurna, Masyhudi, Pritasari Alteriana M. S., Zulaikhah Siti T., & Pratama Arrizki A. (2023). Peningkatan Kadar Malondialdehid (MDA) Akibat Paparan Asap Rokok. *Jurnal Penelitian Kesehatan Suara Forikes*, 14.
- Saqib, S. M., Iqbal, M., Mazhar, T., Shahzad, T., Ouahada, K., & Hamam, H. (2025). Effectiveness of Teachable Machine, mobile net, and YOLO for object detection: A comparative study on practical applications. *Egyptian Informatics Journal*, 30. <https://doi.org/10.1016/j.eij.2025.100680>
- Shi, M., He, P., & Shi, Y. (2022). Detecting Extratropical Cyclones of the Northern Hemisphere with Single Shot Detector. *Remote Sensing*, 14(2). <https://doi.org/10.3390/rs14020254>
- Simonavičius, E., Perman-Howe, P. R., Robson, D., McNeill, A., Kock, L., Brown, J., & Brose, L. S. (2025). Psychological distress, tobacco smoking and alcohol use: A population survey in Great Britain. *Addictive Behaviors Reports*, 21. <https://doi.org/10.1016/j.abrep.2025.100604>
- Sukarta, I. M., Suriani, B., & Marsuki. (2023). Kejadian Perokok Anak di Kampung Selayar Kota Makassar. *KNOWLEDGE: Jurnal Inovasi Hasil Penelitian dan Pengembangan*, 3(1).
- Sukusvieri, A. (2020). *Implementasi Metode Single Shot Detector (SSD) untuk Pengenalan Wajah*.
- Sutisna, T., Rachmat Raharja, A., Hariyadi, E., & Hafizh Cahaya Putra, V. (2024). Penggunaan Computer Vision untuk Menghitung Jumlah Kendaraan dengan Menggunakan Metode SSD (Single Shoot Detector). *INNOVATIVE: Journal Of Social Science Research*, 4, 6060–6067.
- Syafe', M., Adha, H., Retno, M., Kabupaten Banyuasin, A., & Selatan, S. (2021). *Implementasi Kebijakan Kawasan Tanpa Rokok Guna Menunjang Pola Hidup Sehat di Kecamatan Alang-Alang Lebar Kota Palembang Provinsi Sumatera Selatan*.
- Takao, H., Amemiya, S., Kato, S., Yamashita, H., Sakamoto, N., & Abe, O. (2021). Deep-learning single-shot detector for automatic detection of brain metastases with the combined use of contrast-enhanced and non-enhanced computed tomography images. *European Journal of Radiology*, 144. <https://doi.org/10.1016/j.ejrad.2021.110015>
- Trofimov, I., Korotaev, P., Ivanov, I., Malginov, A., Tokhtamyshev, A., Yanilkin, A., & Kruglov, I. (2025). Machine learning assisted design of reactor steels with

high long-term strength and toughness. *Materials & Design*, 114014. <https://doi.org/10.1016/j.matdes.2025.114014>

Wang, R., Xin, Y., Zhang, Y., Perez-Cruz, F., & Raubal, M. (2025). Counterfactual explanations for deep learning-based traffic forecasting. *Communications in Transportation Research*, 5. <https://doi.org/10.1016/j.commtr.2025.100176>

Wasista, S., Nugraha, Z. I., & Setiawardhana. (2024). Webcam-Based Bus Passenger Detection System Using Single Shot Detector Method. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 18(1), 37. <https://doi.org/10.22146/ijccs.87393>

Zamachsari, F., & Puspitasari, N. (2021). Penerapan Deep Learning dalam Deteksi Penipuan Transaksi Keuangan Secara Elektronik. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(2), 203–212. <https://doi.org/10.29207/resti.v5i2.2952>

Zhuang, X., Zhu, P., Yang, A., & Caldas, L. (2025). Machine learning for generative architectural design: Advancements, opportunities, and challenges. Dalam *Automation in Construction* (Vol. 174). Elsevier B.V. <https://doi.org/10.1016/j.autcon.2025.106129>

