

DESMOCAM (DETECTION SMOKING CAMERA): INTEGRATION OF IOT AND MACHINE LEARNING FOR ACTIVE SMOKER DETECTION TO SUPPORT SMART CITIES IN INDONESIA

Annas Abdillah^{*1}, Balqist K. Nayu², Susi Setianingsih³, Galih B. Hidayat⁴, Tuhfa R. Ahmad⁵

^{1,4}Electrical Engineering, Faculty of Engineering, Universitas Jenderal Soedirman, Indonesia

^{2,5}Public Health, Faculty of Health, Universitas Jenderal Soedirman, Indonesia

³Informatics, Faculty of Engineering, Universitas Jenderal Soedirman, Indonesia

Email: ¹annas.abdillah.aa@gmail.com, ²balqistkha.nayu@gmail.com, ³susisetia542@gmail.com,
⁴galihbaskorohidayat@gmail.com, ⁵tuhfaziya@gmail.com

(Article received: May 28, 2024; Revision: June 7, 2024; published: August 01, 2024)

Abstract

Cigarettes are an addictive substance that kills around 8 million people every year, as of 2022 there will be around 8,67 million deaths in the world caused by cigarettes and other tobacco products with resulting economic losses of around 2 trillion USD. Efforts to reduce losses due to smoking in Indonesia have been implemented through various regulations and rules that have been established, such as Law Number 36 of 2009 Article 115 concerning non-smoking areas. The target for non-smoking areas (NSA) regulations in Indonesia will reach 100% by 2023. However, currently, only 86% of regions have NSA regulations and must continue to monitor and evaluate through regulations set by the government. One solution to emphasize non-smoking areas with the latest technology connections to support Smart City is a smoke detection system using IoT. DesMoCam (Detection Smoking Camera) applies the latest machine learning model, InceptionResNet2, which has high accuracy and has the ability to detect smokers precisely in a Non-Smoking Area (NSA). DesMoCam uses a Raspberry Pi with ESP32-CAM to capture situations in a smoking-free room and warnings through the speaker. Machine learning modeling includes data acquisition with smoking and non-smoking images, data preprocessing, two-way modeling with and without a freeze layer, and analysis of model results. The InceptionResnet2 model used for image identification and classification, achieved an accuracy of 92.75%.

Keywords: *IoT, Machine Learning, Smoke Detection.*

DESMOCAM (DETECTION SMOKING CAMERA): IOT DENGAN IMPLEMENTASI MACHINE LEARNING UNTUK DETEKSI PEROKOK AKTIF GUNA MENDUKUNG SMART CITY DI INDONESIA

Abstrak

Rokok, benda adiktif yang membunuh sekitar 8 juta manusia setiap tahunnya, per 2022 tercatat sekitar 8.67 juta kematian dunia yang disebabkan oleh rokok dan produk tembakau lainnya dengan kerugian ekonomi yang dihasilkan sekitar 2 triliun USD. Usaha pengurangan kerugian akibat rokok di Indonesia telah dilaksanakan melalui berbagai regulasi dan peraturan yang telah dibentuk seperti Undang-Undang Nomor 36 Tahun 2009 Pasal 115 mengenai kawasan tanpa rokok. Target aturan Kawasan Tanpa Rokok (KTR) di Indonesia akan mencapai 100% pada tahun 2023, namun saat ini hanya terdapat 86% daerah yang memiliki aturan KTR dan harus terus diperluas, dimonitoring dan dievaluasi melalui regulasi yang telah pemerintah tetapkan. Salah satu upaya solusi untuk mempertegas kawasan tanpa rokok dengan penggabungan teknologi terkini demi mendukung Smart City yaitu dengan sistem deteksi perokok menggunakan IOT. DesMoCam (Detection Smoking Camera) memanfaatkan model *machine learning* terbaru yakni InceptionResNet2 yang memiliki akurasi tinggi untuk mendeteksi perokok secara tepat di kawasan tanpa rokok serta pemanfaatan Raspberry pi dengan ESP32-CAM untuk mengambil gambar kondisi di ruangan kawasan tanpa rokok. Gambar tersebut diproses di Node Red serta peringatan melalui speaker. Pembuatan model *machine learning* dilakukan melalui tahapan *data acquisition* berisi gambar *smoking* dan *non-smoking*, *data preprocessing*, *modelling* sebanyak 2 kali dengan dan tanpa *freeze layer*, hingga analisis hasil model. Hasil akurasi model *machine learning* yang digunakan untuk deteksi dan klasifikasi gambar dengan model InceptionResnet2 sebesar 92,75%.

Kata kunci: *IOT, Machine Learning, Smoke Detection.*

1. PENDAHULUAN

Rokok telah menjadi salah satu benda adiktif yang banyak dikonsumsi oleh manusia selama ribuan tahun dan telah membunuh sekitar 8 juta manusia setiap tahunnya. Tercatat sekitar 1,1 miliar perokok di dunia serta 200 juta lebih pengguna produk sejenis tembakau per 2022 [1]. Hal ini sejalan dengan 8,67 juta kematian dunia yang disebabkan oleh rokok dan produk tembakau lainnya, yaitu sekitar 6,53 juta pria dan 2,14 wanita serta taksiran kerugian ekonomi yang dihasilkan sekitar 2 triliun USD [2]. Tidak hanya perokok aktif yang dirugikan, perokok pasif ikut menanggung kerugian yang dihasilkan. Sekitar 1,2 juta kematian perokok pasif tercatat karena paparan asap rokok [3].

WHO memperkirakan lebih dari 8 juta orang meninggal dini setiap tahunnya akibat penggunaan tembakau. Ini adalah perkiraan WHO terbaru yang tersedia per Agustus 2023. Lebih dari 7 juta kematian disebabkan oleh penggunaan tembakau secara langsung. Sekitar 1,3 juta orang bukan perokok dan meninggal karena terpapar asap rokok. 7,7 juta dari kematian tersebut disebabkan oleh kebiasaan merokok, sementara 1,3 juta lainnya adalah bukan perokok yang meninggal karena terpapar asap rokok. Sebagian besar (71%) dari mereka yang meninggal dini karena merokok adalah laki-laki.

Rokok masih menjadi masalah yang serius di Indonesia. Jumlah perokok di Indonesia meningkat di tiap tahunnya. Badan Pusat Statistik [4] menunjukkan bahwa terjadi peningkatan jumlah perokok yaitu sebanyak 28,69% pada tahun 2020 meningkat menjadi 28,96% pada tahun 2021. Data dari Kemenkes RI [5] selama kurang lebih 10 tahun menunjukkan bahwa jumlah perokok di Indonesia meningkat secara signifikan sebanyak 8,8 juta orang. Secara nasional, sebanyak 21,69% penduduk usia 15 tahun ke atas di perkotaan merokok, sementara di pedesaan 25,35%. Berdasarkan jenis kelaminnya, ada 45,34% penduduk laki-laki usia 15 tahun ke atas yang merokok, sedangkan penduduk perempuan hanya 0,78% per tahun 2022.

Lebih dari 80% dari 1,3 milyar perokok di dunia berasal dari negara berpendapatan menengah ke rendah dengan beban penyakit dan kematian yang disebabkan oleh produk tembakau dan rokok ini terberat [6]. Tak hanya menghasilkan kerugian dari segi kesehatan, rokok ikut andil dalam kemiskinan struktural melalui pengalokasian anggaran rumah tangga dari kebutuhan dasar seperti makanan dan tempat tinggal ke pembelian rokok. Dari segi ekonomi, rokok telah berpartisipasi dalam penurunan produktivitas ekonomi sebesar \$185 miliar untuk biaya kesehatan karena sakit dan kondisi kesehatan yang ditimbulkan oleh rokok [7]. Kematian bayi dan paparan ke perokok pasif juga turut berpartisipasi dalam kerugian ekonomi yang dihasilkan oleh rokok, yaitu sebesar \$180 miliar dan \$7 miliar [8].

Indonesia sebagai salah satu negara berkembang di tingkat ekonomi menengah ke bawah memiliki sebanyak 69,1 juta perokok pada tahun 2021, dan merupakan negara penyumbang perokok pria di dunia yaitu sekitar 51,4% bersamaan dengan China dan India. Hasil ini dilaporkan dari Global Adult Tobacco Survey (GATS) [9] pada tahun 2021 yang menyatakan bahwa terjadi peningkatan jumlah perokok dewasa sebanyak 8,8 juta orang selama 10 tahun terakhir, dari 60,3 juta pada 2011 [10]. Jumlah rata-rata bulanan anggaran yang dibelanjakan untuk rokok sebanyak Rp 382.091,72. Tak hanya itu, kerugian kesehatan yang disebabkan oleh rokok ini tercatat pada hasil survei tahun 2019, yaitu rata-rata biaya pengobatan untuk penyakit akibat rokok mencapai 27,7 triliun rupiah per tahunnya dan biaya ini ditopang oleh Badan Penyelenggara Jaminan Sosial Kesehatan sebanyak 56% hingga 59%. Hal ini tidak sebanding dengan hasil alokasi penerimaan CHT atau Cukai Hasil Tembakau ke biaya kesehatan yang hanya sebesar 7,4 triliun rupiah [11]. Laporan ini menunjukkan bahwa beban yang ditanggung tiga kali lipat lebih banyak dibandingkan yang telah dialokasikan. Rokok terbukti telah menunda terwujudnya pembangunan berkelanjutan atau SDGs (*Sustainable Development Goals*) nomor 3 mengenai penjaminan kehidupan yang sehat dan kesejahteraan untuk seluruh golongan usia, serta nomor 1 mengenai kemiskinan [12] [13].

Usaha pengurangan kerugian akibat rokok di Indonesia telah dilaksanakan melalui berbagai regulasi dan peraturan yang telah dibentuk. Salah satunya adalah Undang-Undang Nomor 36 Tahun 2009 Pasal 115 yang menjelaskan bahwa Pemerintah Daerah wajib menetapkan kawasan tanpa rokok di wilayahnya. Menurut peraturan tersebut, kawasan tanpa rokok antara lain, yaitu fasilitas pelayanan kesehatan, tempat proses belajar mengajar, tempat anak bermain, tempat ibadah, angkutan umum, tempat kerja, dan tempat lainnya yang ditetapkan. Wakil Menteri Kesehatan mengatakan bahwa target aturan Kawasan Tanpa Rokok (KTR) di Indonesia akan mencapai 100% pada tahun 2023. Saat ini sudah terdapat 86% daerah yang memiliki aturan KTR dan akan terus diperluas, *dimonitoring* dan dievaluasi melalui regulasi yang telah pemerintah tetapkan [14]. Kawasan Tanpa Rokok ini sejalan dengan upaya pemerintah dalam penyelesaian masalah yang terjadi pada beberapa daerah, terutama perkotaan yang berwujud Smart City. Smart City menggabungkan unsur teknologi dengan sumber daya yang ada untuk mencari solusi dari masalah-masalah yang ada demi mencapai sebuah efisiensi [15].

Salah satu dari banyak alternatif solusi yang telah ditawarkan demi mengurangi penggunaan rokok dan kerugian akibat rokok adalah konsep deteksi perokok aktif menggunakan alat yang bisa digunakan untuk mendisiplinkan perokok yang

merokok tidak sesuai dengan tempatnya. Perkembangan teknologi yang semakin pesat mendukung penyelesaian rokok, terutama kawasan tanpa rokok ini melalui berbagai metode, salah satunya melalui konsep kecerdasan buatan yang telah diteliti oleh Ali Khan dengan metode Convolutional Neural Network (CNN) dan mendapatkan hasil akurasi sebesar 96.87%. Selain dengan CNN, deteksi rokok bisa dilaksanakan menggunakan metode lain yang terkenal pada konsep *Deep Learning* seperti AlexNet dan ResNet [16]. Model *deep learning* yang telah diterapkan kemudian dapat diimplementasikan pada sebuah alat berupa IoT.

Teknologi IoT telah digunakan untuk mendeteksi rokok pada beberapa penelitian yang telah dilakukan. Salah satu penelitian yang dilakukan oleh Somantri 2020 menghasilkan sistem deteksi asap menggunakan pengenalan wajah dan teknologi kecerdasan buatan, yang dapat mengidentifikasi perokok di kawasan dilarang merokok dan mengirimkan pemberitahuan kepada administrator [17]. Namun, penelitian ini belum menjelaskan model kecerdasan buatan yang digunakan beserta akurasinya. Penelitian lainnya oleh Cho 2020 mengenai deteksi asap di lingkungan dalam ruangan menggunakan *machine learning*, namun tidak menggunakan deteksi gambar tetapi memakai deteksi asap langsung menggunakan *rotary smoking machine* [18].

Penelitian dengan judul “DesMoCam (Detection Smoking Camera): IoT with Machine Learning Integration for Active Smoker Detection to Support Smart Cities in Indonesia” dibuat berdasarkan data yang telah dijelaskan sebelumnya. Selanjutnya, implementasi Undang-Undang terkait KTR di Indonesia yang juga berhubungan dengan target Pembangunan Berkelanjutan (SDG) telah ditetapkan, khususnya dalam upaya meningkatkan kesehatan masyarakat dan mencapai tujuan pembangunan yang berkelanjutan di Indonesia. Dalam konteks pelaksanaan *smart city*, pengintegrasian IOT dengan *Machine Learning*, terkhusus menggunakan jenis *transfer learning* dapat memperkuat deteksi perokok aktif melalui analisis gambar yang diambil dengan kamera dari DesMoCam. Penelitian ini diharapkan mampu berkontribusi pada pencapaian SDG nomor 3, 9, dan 11, serta pembangunan yang lebih efisien di Indonesia.

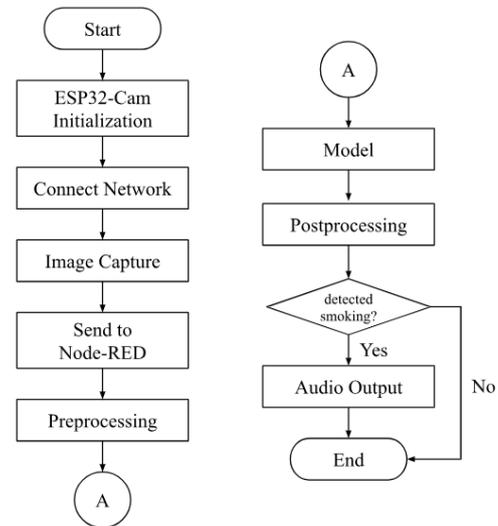
2. METODE PENELITIAN

Metode dalam penelitian ini dapat digambarkan dengan *flowchart* pada Gambar 1 sebagai berikut.

2.1. ESP32-Cam Initialization

Pada bagian ini merupakan proses penginisialisasian ESP32-Cam dengan cara mengkonfigurasi Arduino IDE dengan pustaka ESP32 berupa Camera Web Server dan melakukan

pengaturan pin yang digunakan. Setelah dilakukan proses tersebut, ESP32-Cam dapat digunakan untuk mengambil gambar.



Gambar 1. *Flowchart* Tahap Penelitian

2.2. Connect Network

Pada bagian ini merupakan proses menyambungkan ESP32-Cam dengan jaringan Wi-Fi yang akan digunakan untuk melakukan transfer data berupa hasil tangkapan gambar. Pengaturan untuk menghubungkan dengan jaringan yaitu dengan melakukan konfigurasi terhadap SSID dan *password* WiFi pada kode program.

2.3. Image Capture

Pada bagian ini merupakan proses pengambilan gambar melalui ESP32-Cam. Pengambilan gambar tersebut dilakukan setiap 3 detik sekali, hal ini dilakukan agar pemantauan dapat berlangsung secara teratur dan berkala yang memungkinkan analisis data gambar dalam rentang waktu tertentu.

2.4. Send to Node-RED

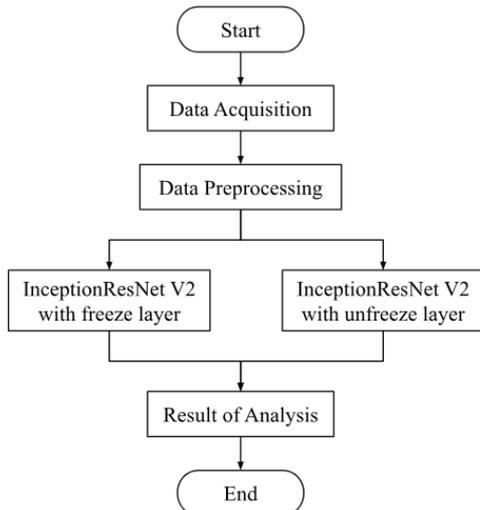
Pada bagian ini merupakan proses pengiriman gambar dari ESP32-Cam ke Node-RED. Pengiriman gambar dilakukan menggunakan protokol komunikasi MQTT dengan memanfaatkan jaringan Wi-Fi. ESP32-Cam akan mengirimkan gambar yang telah ditangkap lalu pada Node-RED akan menerimanya dengan cara *subscribe* topik yang sama dengan topik *publish* pada ESP32-Cam.

2.5. Preprocessing

Pada bagian ini merupakan proses pengolahan data gambar yang diterima dari ESP-Cam sebelum dimasukan pada model *machine learning*. Pada bagian ini terdiri dari beberapa proses, yaitu *resize* gambar, konversi *array*, menambahkan dimensi, dan penggabungan menjadi 1 *array*.

2.6. Model

Pada bagian ini merupakan proses pembuatan model machine learning yang akan digunakan dalam klasifikasi smoking dan not-smoking pada DesMoCam. Model yang digunakan yaitu Convolutional Neural Network (CNN) dengan arsitektur Inception Resnet V2 dengan penambahan layer dense. Dalam penentuan model terbaik, peneliti melakukan serangkaian pengujian seperti yang ditunjukkan pada Gambar 2.



Gambar 2. Flowchart Tahap Pencarian Model Terbaik

2.6.1. Data Acquisition

Pada tahap ini dilakukan dengan tujuan untuk mengumpulkan data yang akan digunakan selama proses pelatihan model. Data yang digunakan berisi gambar orang merokok (*smoking*) dan tidak merokok (*not-smoking*) yang berasal dari Mendeley dataset [19].

2.6.2. Data Preprocessing

Data *preprocessing* yakni tahap awal untuk mengolah data mentah (*raw data*) menjadi data bersih yang siap digunakan untuk proses selanjutnya. Teknik yang digunakan yaitu *resize*, *rescale*, *rotation*, dan *flip*.

2.6.3. Modelling

Pemodelan dilakukan sebanyak 2 kali yaitu *pre-trained* model InceptionResNetV2 dengan dan tanpa *freeze layer*. Selain itu, dalam setiap model pengujian ada penambahan *Dense layer* untuk meningkatkan tingkat akurasi model. Model yang telah dilatih akan mengeluarkan sebuah output dari dua kelas yaitu *smoking* atau *not-smoking*.

2.6.4. Result of Analysis

Setelah melakukan pengujian, dilanjutkan dengan analisis hasil klasifikasi. Analisis ini dilakukan terhadap nilai akurasi menggunakan

metode *confusion matrix*. Metode *Confusion Matrix* merepresentasikan hasil evaluasi model dengan menggunakan tabel matriks dimana kelas prediksi akan dibandingkan dengan kelas asli. Tabel 1 berikut menyajikan *Confusion Matrix* untuk klasifikasi 2 kelas. Adapun Persamaan (1) menunjukkan rumus perhitungan akurasi.

Tabel 1. *Confusion Matrix*

Actual Class	Predicted Class	
	Positive	Negative
Positive	True Positive	False Negative
Negative	False Positive	True Negative

$$accuracy = \frac{(TP+TN)}{TP+TN+FP+FN} 100\% \quad (1)$$

Keterangan:

TP : True Positive

TN : True Negative

FP : False Positive

FN : False Negative

2.6.5. Post Processing

Pada bagian ini merupakan hasil dari proses pengolahan setelah gambar diolah pada model *machine learning*. Pada bagian ini akan dilanjutkan dengan pengondisian dari hasil yang diperoleh. Jika hasil pengolahan *machine learning* menunjukkan bahwa terdapat orang yang melakukan kegiatan merokok pada ruangan tersebut, maka akan diberikan peringatan dalam bentuk teguran melalui *speaker*.

3. HASIL DAN PEMBAHASAN

3.1. Konsep Alat

DesMoCam merupakan nama dari alat yang diusulkan yang terdiri dari kata *Detection Smoking Camera*. Fungsi dari teknologi ini adalah untuk membantu petugas di instansi yang terdapat kawasan bebas rokok. Konsep dari alat ini yaitu sebagai solusi alternatif untuk melakukan kegiatan penertiban orang yang melakukan kegiatan merokok di kawasan bebas rokok dengan cara memberikan peringatan dalam bentuk teguran melalui *speaker*. Alat ini memiliki beberapa bagian yaitu bagian pendeteksi dan *server*. Bagian pendeteksi merupakan bagian menyerupai CCTV menggunakan kamera dari ESP32-CAM, terdapat *speaker* di dalamnya, dan bagian ini dapat terhubung ke jaringan Wi-Fi untuk melakukan pengiriman gambar dan penerimaan hasil pendeteksi ada atau tidaknya perokok. Selain itu, pada bagian pendeteksi juga dilengkapi dengan memori micro SD Card untuk menyimpan suara peneguran yang akan disetel saat terdeteksi ada yang merokok. Bagian kedua yaitu bagian *server*. Model *Machine Learning* sebagai media pendeteksian gambar akan diletakan pada Node-RED. Komunikasi yang digunakan menerapkan teknologi Internet of Things (IoT) yaitu dengan protokol komunikasi MQTT. Dari bagian pendeteksi akan mengirimkan gambar dengan

mempublish ke topik pada MQTT dan bagian *server* akan menerima dengan me-*subscribe* topik tersebut. Hasil pengolahan gambar pada model *machine learning* akan menghasilkan output yang akan dikirimkan melalui MQTT kepada bagian pendeteksi kembali untuk menyalakan peringatan saat terdeteksi terdapat orang yang merokok.

3.2. Pembuatan Akurasi Model

3.2.1. Data Acquisition

Dataset dalam penelitian ini terdiri dari 3 jenis dataset yaitu data *training*, data *validation*, dan data *testing*. Akan tetapi, pada pembuatan modelnya sendiri hanya digunakan data *training* dan data *validation*. Struktur dataset ditunjukkan pada tabel 2 berikut.

Tabel 2. Dataset dalam pembuatan model

Dataset	Smoking	Not smoking
Data <i>training</i>	855	805
Data <i>validation</i>	200	200

3.2.2. Data Preprocessing

Pembuatan model dilakukan dengan menggunakan Google Colaboratory. Sebelum digunakan dalam pembuatan model, data akan dilakukan *preprocessing* terlebih dahulu agar pelatihan model dapat menghasilkan akurasi yang baik. Untuk resolusi citra dataset akan dilakukan *resize* menjadi 227x227. Selanjutnya, citra akan dilakukan *rescale* dengan skala 1/255. Setiap citra di-*rotation* sebesar 20 derajat untuk meningkatkan keragaman dataset. Terakhir, teknik *flip* diatur dengan nilai *vertical* dan *horizontal*.

3.2.3. Modelling

Pengujian dilakukan menggunakan 20 epoch pada pre-trained model Inception ResNet V2 dengan dan tanpa *freeze layer* menghasilkan nilai akurasi dan nilai *loss* untuk masing-masing model. Adapun hasilnya dapat dilihat pada Tabel 3 berikut

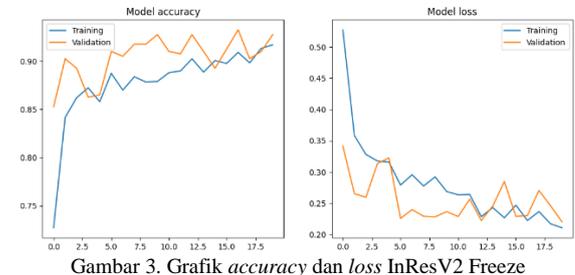
Tabel 3. Tingkat akurasi model pengujian

Model	Accuracy	Loss	T _{epoch1}
InResV2 Freeze	92,75%	0,5	224ms/step
InResV2 Unfreeze	92,50%	0,246	542ms/step

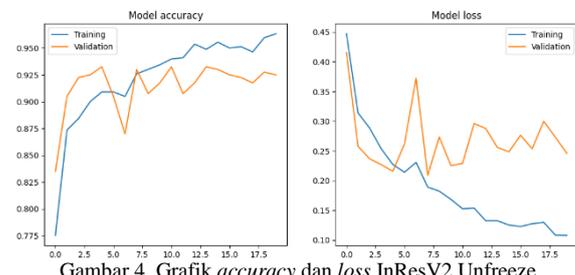
Berdasarkan Tabel 3, dapat diketahui bahwa nilai akurasi tertinggi dihasilkan oleh model InResV2 Freeze dengan nilai akurasi sebesar 92,75%. Sementara itu, nilai *loss* terendah dihasilkan pada model InResV2 Unfreeze dengan nilai *loss* yaitu 0,245. Selain itu, nilai rata-rata kecepatan tiap *epoch* paling rendah dihasilkan oleh InResV2 Freeze dengan waktu 224ms/step. Dalam memilih model terbaik, grafik akurasi dan *loss* selama pelatihan juga dibandingkan untuk melihat performa model apakah mengalami *overfitting*, *underfitting*, dan *goodfit*.

Kondisi *overfitting* terjadi apabila *training loss* bernilai lebih rendah dibandingkan *validation loss*.

Underfitting terjadi ketika *training loss* dan *validation loss* sama-sama bernilai tinggi. Selanjutnya, kondisi *good fit* dimana *training loss* maupun *validation loss* bernilai sama rendahnya. Perbandingan kedua model pelatihan dapat ditunjukkan pada Gambar 3 dan Gambar 4.



Gambar 3. Grafik *accuracy* dan *loss* InResV2 Freeze



Gambar 4. Grafik *accuracy* dan *loss* InResV2 Unfreeze

Pada Gambar 3 terlihat bahwa grafik akurasi InResV2 Freeze mengalami peningkatan untuk *training* dan *validation*. Sementara itu, grafik *loss* untuk *training* dan *validation* mengalami penurunan hingga kedua grafik beberapa kali saling bertemu. Kondisi ini menunjukkan bahwa terdapat perbaikan performa model menuju kondisi *goodfit*.

Gambar 4 menunjukkan grafik akurasi InResV2 Unfreeze yang mengalami peningkatan pada nilai *training* dan nilai *validation*. Adapun nilai grafik *loss* dari *training* dan *validation* mengalami penurunan. Akan tetapi, kedua nilai tersebut terlihat tidak saling bertemu di akhir *epoch*. Ini menunjukkan bahwa model mengalami performa yang belum terlalu baik atau mengalami kondisi *overfitting*.

3.2.4. Result of Analysis

Kedua model yang dihasilkan selama pelatihan memiliki nilai akurasi yang cenderung tinggi. Namun, dengan membandingkan grafik pada Gambar 3 dan Gambar 4 dapat terlihat bahwa model InResV2 Freeze merupakan model terbaik yang dapat digunakan dalam model klasifikasi DesMoCam. Model terbaik menunjukkan nilai akurasi tertinggi sebesar 92,75% dengan waktu prediksi paling tinggi yaitu 224ms/step. Meskipun nilai *loss* model yang dihasilkan cukup tinggi, tetapi performa model menunjukkan kondisi *goodfit*. Kondisi *goodfit* dalam *machine learning* merupakan kondisi yang baik, dimana model secara cepat belajar dengan baik untuk mengurangi nilai *loss* atau kesalahan dalam melakukan klasifikasi citra dengan peningkatan nilai

akurasi model. Tabel 4 menunjukkan detail dari arsitektur model InResV2 Freeze

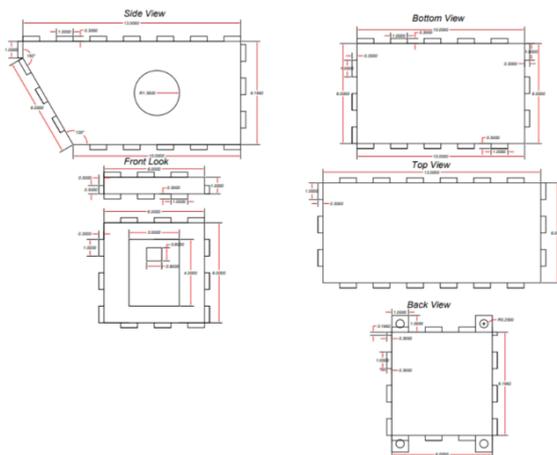
Tabel 4. Detail Arsitektur Model InResV2 Freeze

Name	Feature Map	Output Size	Activation
Input	3	256x256	-
<i>inception_resnet_v2</i> (Functional)	1536	6x6	-
GlobalAveragePooling2D	-	1536	Relu
FC 1	-	512	Relu
FC 2	-	1024	Relu
FC 3	-	2	Softmax

Model InResV2 Freeze merupakan model arsitektur yang menggunakan *transfer learning* dari model InceptionResnetV2 yang sudah disediakan oleh TensorflowHub dengan *weight* dari imagenet. Model yang sudah ada kemudian ditambahkan Dense Layer sebanyak 512 layer dan 1024 layer. Terakhir, model akan mengeluarkan keluaran untuk 2 kelas yaitu *smoking* dan *not smoking*. Input yang dapat diterima model yaitu gambar berwarna dengan ukuran 256x256 piksel.

3.3. Prototype Alat

Prototype alat terbagi menjadi dua seperti yang disebutkan sebelumnya yaitu bagian pendeteksi dan bagian *server*. Bagian pendeteksi terdiri dari ESP32-CAM, Module MAX98357, *speaker*, dan modul *micro sd card* dikemas dengan *casing* akrilik. *Casing* akrilik akan menyesuaikan ukurannya agar ESP32-CAM dapat menangkap gambar dan agar *speaker* dapat berbunyi ketika mendeteksi orang yang merokok.



Gambar 5. Prototype Alat DesMoCam

Gambar 5 menunjukkan Prototype DesMoCam yang akan dibuat. DesMoCam berdimensi kurang lebih 6x10x13 cm yang akan memuat seluruh bagian ESP32-CAM Module MAX98357, *speaker*, dan modul *micro sd card*.

Bagian kedua yaitu *server* yang merupakan mini komputer raspberry pi. *Server* yang digunakan pada raspberry pi yaitu *platform* Node-RED. Model yang telah dibuat akan berjalan di atas Node-RED dengan memasukan model.json pada *node* tf.model. Mini

komputer raspberry pi pada alat ini ditempatkan terpisah dengan bagian pendeteksi karena hanya berfungsi sebagai *server*, tetapi harus dalam satu jaringan Wi-Fi yang sama.

3.4. Cara Kerja Alat

Alat dapat dihidupkan dengan menyambungkan adaptor *power supply* ke sumber listrik dan siapkan Wi-Fi yang sudah dimasukan pada pemrograman ESP32-CAM dan Raspberry pi. Alat bagian pendeteksi dan bagian *server* akan terhubung dengan jaringan Wi-Fi sehingga keduanya terhubung dengan jaringan rlocal. Kemudian alat pendeteksi pada ESP32-CAM akan mengambil gambar setiap 5 detik sekali. Hasil gambar akan dikirimkan ke Node-RED pada raspberry pi melalui protokol komunikasi MQTT. Setelah gambar diterima oleh Node-RED, gambar akan dimasukan ke *node pre-processing*. Pada *node pre-processing* gambar akan dibuat menjadi *array* dan dilakukan *rescaling* agar gambar dapat diproses pada *node* model *machine learning*. *Node* yang digunakan untuk menampung model *machine learning* yaitu *node* tf.model. Setelah gambar masuk pada *node* tersebut, *node* tf.model akan mengeluarkan keluaran berupa nilai yang menunjukkan merokok atau tidak merokok. Ketika hasil menunjukkan terdapat orang yang merokok, *node* function akan mengeluarkan nilai 1 (*True*) dan akan dikirimkan ke bagian pendeteksi melalui protokol MQTT. Pada bagian ESP32-CAM akan menerima nilai tersebut, ketika nilai 1 (*True*) maka akan diberikan peringatan dalam bentuk teguran melalui *speaker*. Sedangkan ketika hasil model *machine learning* mengeluarkan nilai 0 (*False*) dan dikirim ke ESP32-CAM, maka sistem tidak melakukan aksi pemberian peringatan. Alur dari alat ini akan mengulang kembali alurnya dari alat bagian pendeteksi mengambil gambar.

4. DISKUSI

Hasil pemodelan yang dilakukan menggunakan Inception ResNet V2 menghasilkan nilai akurasi sebesar lebih dari 92%. Akurasi tersebut memiliki hasil yang lebih baik dibandingkan dengan penelitian di India [20] pada tahun 2023 yang menggunakan model *machine learning* biasa yakni *logic regression*, *Gaussian Naive Bayes*, *Random Forest Classifier*, and *XGBoost Classifier* dan menghasilkan presisi tertinggi sebesar 79,4%. Sebaliknya, penelitian lainnya dari Hungaria tentang deteksi perokok menggunakan data gambar dan teks yang sedikit menghasilkan akurasi model sebesar 74% untuk gambar dan 98% untuk teks. Model yang menghasilkan akurasi lebih tinggi adalah model XLM-RoBERTa [21]. Perbedaan hasil akurasi di antara kedua penelitian tersebut karena perbedaan model yang digunakan. Model dengan kompleksitas yang lebih tinggi mampu mendeteksi gambar dengan lebih akurat dibandingkan dengan model *machine*

learning yang biasanya. karena kemampuannya menangani pola dan fitur kompleks dalam gambar. Penelitian telah menunjukkan bahwa model pembelajaran mendalam, seperti jaringan saraf konvolusional (CNN), unggul dalam tugas klasifikasi gambar dengan mengekstraksi fitur hierarki dari gambar secara efektif, sehingga menghasilkan peningkatan akurasi klasifikasi [22] [23] [24] [25]. Model *deep learning* mendapat manfaat dari teknik seperti pembelajaran transfer, pemilihan fitur dinamis, dan konfigurasi hyperparameter yang dioptimalkan, yang selanjutnya meningkatkan kemampuan prediktifnya dalam tugas-tugas seperti membedakan antara jaringan payudara normal dan tumor atau menilai kedalaman luka bakar [26]. Selain itu, model *deep learning*, terutama yang sudah dimodifikasi jika dilatih dengan pendekatan prapemrosesan data yang tepat, dapat mencapai tingkat akurasi yang tinggi, seperti yang ditunjukkan dalam pendeteksian gambar palsu menggunakan model analisis tingkat kesalahan.

DesMoCam memiliki kelebihan dibandingkan alat-alat yang telah diuji sebelumnya. Alat yang dibuat dalam penelitian [27] pada tahun 2020, belum menjelaskan model kecerdasan buatan yang digunakan beserta akurasinya. Penelitian lainnya oleh [28] pada tahun 2020 mengenai deteksi asap di lingkungan dalam ruangan menggunakan machine learning, tidak menggunakan deteksi gambar tetapi memakai deteksi asap langsung menggunakan rotary smoking machine. DesMoCam menggabungkan machine learning model InceptionResNet2 yang telah dikenal memiliki akurasi tinggi dengan raspberry pi dan ESP32-CAM sederhana. Raspberry pi dan ESP32-CAM yang sudah banyak diterapkan dalam berbagai jenis IOT membuat DesMoCam mudah dalam proses pembuatannya namun tetap memberikan ketepatan hasil pendeteksian perokok. Kolaborasi antara teknologi terkini dengan masalah kesehatan umum yang mendasar diharapkan dapat menjadi solusi. Tidak hanya solusi dan bantuan bagi para pemerintah dalam menertibkan kawasan tanpa rokok, diharapkan DesMoCam dapat menjadi solusi jangka panjang untuk usaha penurunan angka penyakit tidak menular yang disebabkan oleh rokok dan angka penurunan penyakit pernapasan, mengingat rokok menjadi sumber dari banyaknya penyakit. Outcome akhirnya diharapkan kondisi kesehatan di Indonesia akan terus meningkat, serta mampu berkontribusi pada pencapaian SDG nomor 3, 9, dan 11, serta pembangunan yang lebih efisien di Indonesia.

Dalam upaya pengembangan dan efektivitas DesMoCam, rencana berkelanjutan yang akan dilakukan yaitu mengimplementasikannya. DesMoCam ini secara khusus akan diterapkan pada ruangan tertentu, dengan fokus utama pada kawasan tanpa asap rokok. Rencana implementasi DesMoCam di dalam ruangan tidak hanya melibatkan aspek teknologi, tetapi juga melibatkan kerjasama erat

dengan berbagai pihak terkait. Salah satu langkah utama adalah menjalin kemitraan dengan instansi kesehatan, perguruan tinggi, mahasiswa, serta peneliti di bidang teknologi. Kolaborasi ini diharapkan dapat memberikan kontribusi dalam pengembangan dan peningkatan efektivitas DesMoCam, sekaligus memperkuat pemahaman akan dampak positifnya terhadap kesehatan masyarakat.

Dalam melibatkan instansi kesehatan, tempat yang menjadi target utama rencana implementasi DesMoCam adalah rumah sakit dan puskesmas. Dengan dukungan dari pihak kesehatan, diharapkan penerapan ini dapat menjadi bagian dari upaya lebih luas dalam menciptakan lingkungan yang bersih dan bebas dari asap rokok di fasilitas kesehatan tersebut. Melibatkan mahasiswa dan peneliti juga memiliki tujuan untuk memanfaatkan wawasan dan keahlian mereka dalam pengembangan teknologi ini, sehingga dapat lebih efektif dan responsif terhadap kebutuhan praktis di lapangan.

Pentingnya keterkaitan dengan peraturan yang berlaku juga menjadi sorotan dalam rencana ini. Penerapan DesMoCam akan diatur sesuai dengan Undang-Undang Nomor 36 Tahun 2009 Pasal 115 tentang Pemerintah Daerah yang wajib menetapkan kawasan tanpa rokok di wilayahnya. Penetapan kawasan tanpa rokok di wilayah tertentu akan menjadi dasar hukum yang mendukung implementasi ini, memastikan bahwa langkah-langkah yang diambil sesuai dengan norma dan aturan yang berlaku. Dengan kerangka kerja ini, diharapkan implementasi DesMoCam dapat menjadi langkah yang terencana, legal, dan berdaya guna dalam mendukung upaya mewujudkan kawasan tanpa rokok di lingkungan kesehatan.

5. KESIMPULAN

DesMoCam (Detection Smoking Camera) memiliki 2 bagian, yaitu bagian pendeteksi dan server. Bagian pendeteksi menyerupai CCTV menggunakan kamera dari ESP32-CAM, terdapat speaker di dalamnya, dan dapat terhubung ke jaringan Wi-Fi untuk melakukan pengiriman gambar dan penerimaan hasil pendeteksi ada atau tidaknya perokok. Bagian server merupakan raspberry pi menggunakan platform Node-RED sebagai servernya. Selanjutnya gambar tersebut diproses di Node Red dan menghasilkan output berupa klasifikasi merokok dan tidak merokok serta peringatan melalui speaker. Model yang digunakan yaitu jenis *transfer learning* bernama Inception ResNet V2 yang telah dimodifikasi parameternya. Hasil yang didapatkan yakni akurasi sebesar 92,75% dengan modifikasi *freeze* dan *loss* sebesar 0,5. Keberlanjutan dari alat ini diharapkan mampu diterapkan pada seluruh wilayah kawasan tanpa rokok dengan kerjasama berbagai pihak dalam 2-3 tahun ke depan.

UCAPAN TERIMA KASIH

Kami mengucapkan terima kasih kepada Rektor Universitas Jenderal Soedirman, Dekan Fakultas Teknik, dan Dekan Fakultas Ilmu Kesehatan yang telah mendukung terselesaikannya penelitian ini. Kami juga mengucapkan terima kasih kepada Dadang Iskandar, S.T., M.Eng. untuk diskusi yang bermanfaat serta dukungan dan dorongannya.

DAFTAR PUSTAKA

- [1] World Health Organization, "Tobacco," 2022. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/tobacco>. [Accessed: Dec. 10, 2023].
- [2] Vital Strategies, "Report: Global Tobacco Users at 1.3 Billion; Smoking Among Young Teens Ages 13-15 Increases in 63 Countries," 2022. [Online]. Available: <https://www.vitalstrategies.org/tobacco-atlas-global-tobacco-users-at-1-3-billion-smoking-among-young-teens-ages-13-15-increases-in-63-countries/#:~:text=May%2018%2C%202022>. [Accessed: Dec. 10, 2023].
- [3] W. Max, H. Y. Sung, and Y. Shi, "Deaths from secondhand smoke exposure in the United States: Economic implications," *Am. J. Public Health*, vol. 102, no. 11, pp. 2173–2180, 2012, doi: 10.2105/AJPH.2012.300805.
- [4] Data Indonesia, "Sebanyak 23,8% Penduduk Indonesia Merokok pada 2021," 2021. [Online]. Available: <https://dataindonesia.id/industri-perdagangan/detail/sebanyak-238-penduduk-indonesia-merokok-pada-2021>. [Accessed: Dec. 12, 2023].
- [5] Kementerian Kesehatan Republik Indonesia, "Tahun 2023, Seluruh Daerah Ditargetkan Miliki Kawasan Tanpa Rokok, Sehat Negeriku," 2023. [Online]. Available: <https://sehatnegeriku.kemkes.go.id/baca/umum/20230608/3043211/tahun-2023-seluruh-daerah-ditargetkan-miliki-kawasan-tanpa-rokok/>. [Accessed: Dec. 14, 2023].
- [6] World Health Organization, "Tobacco," 2022. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/tobacco>. [Accessed: Dec. 10, 2023].
- [7] Centers for Disease Control and Prevention, "Economic Trends in Tobacco | Smoking and Tobacco Use | CDC." [Online]. Available: https://www.cdc.gov/tobacco/data_statistics/fact_sheets/economics/econ_facts/index.htm. [Accessed: Feb. 9, 2024].
- [8] X. Xu, S. S. Shrestha, K. F. Trivers, L. Neff, B. S. Armour, and B. A. King, "US healthcare spending attributable to cigarette smoking in 2014," *Preventive Medicine*, vol. 150, p. 106529, 2021.
- [9] World Health Organization, "GATS Global Adult Tobacco Survey, Fact Sheet Indonesia 2021," 2021. [Online]. Available: https://cdn.who.int/media/docs/default-source/ncds/ncd-surveillance/data-reporting/indonesia/indonesia-national-2021-factsheet.pdf?sfvrsn=53eac4fd_1. [Accessed: Feb. 9, 2024].
- [10] Badan Kebijakan Kemenkes RI, "Perokok Dewasa di Indonesia Meningkatkan Dalam Sepuluh Tahun Terakhir," 2021. [Online]. Available: <https://www.badankebijakan.kemkes.go.id/perokok-dewasa-di-indonesia-meningkat-dalam-sepuluh-tahunterakhir>. [Accessed: Feb. 10, 2024].
- [11] L. J. Sembiring and CNBC Indonesia, "Riset: Rugi Negara Lebih Besar Ketimbang Untung dari Rokok!, CNBC Indonesia," 2021. [Online]. Available: <https://www.cnbcindonesia.com/news/20210812161438-4-268044/riset-rugi-negara-lebih-besar-ketimbang-untung-dari-rokok>. [Accessed: Feb. 12, 2024].
- [12] Tobacco Tactics and University of Bath, "Unsustainable: Big Tobacco's use of the UN SDGs," 2023. [Online]. Available: <https://tobaccotactics.org/article/unsustainable-big-tobaccos-use-of-the-un-sdgs>. [Accessed: Feb. 12, 2024].
- [13] Kementerian PPN, "Sekilas SDGs." [Online]. Available: <https://sdgs.bappenas.go.id/sekilas-sdgs>. [Accessed: Feb. 14, 2024].
- [14] Kementerian Kesehatan Republik Indonesia, "Tahun 2023, Seluruh Daerah Ditargetkan Miliki Kawasan Tanpa Rokok, Sehat Negeriku," 2023. [Online]. Available: <https://sehatnegeriku.kemkes.go.id/baca/umum/20230608/3043211/tahun-2023-seluruh-daerah-ditargetkan-miliki-kawasan-tanpa-rokok>. [Accessed: Jan. 22, 2024].
- [15] F. Moura and J. de Abreu e Silva, "Smart Cities: Definitions, Evolution of the Concept and Examples of Initiatives," pp. 1–9, 2019. doi: 10.1007/978-3-319-71059-4_6-1.
- [16] A. Khan, S. Khan, B. Hassan, and Z. Zheng, "CNN-based smoker classification and detection in smart city application," *Sensors*, vol. 22, no. 3, p. 892, 2022.
- [17] S. Somantri, I. Yustiana, and A. Nugraha, "Electrical consumption monitoring and controlling system based on IoT and mobile

- application,” in 2020 International Conference on ICT for Smart Society (ICISS), 2020, pp. 1-5, doi: 10.1109/ICISS50791.2020.9307620. p. 1241, 2020.CNNs." Atmosphere 11, no. 11 (2020): 1241
- [18] Y. Valikhujaev, A. Abdusalomov, and Y. I. Cho, “Automatic fire and smoke detection method for surveillance systems based on dilated CNNs,” Atmosphere, vol. 11, no. 11, p. 1241, 2020.
- [19] A. Khan, S. Khan, B. Hassan, and Z. Zheng, “CNN-based smoker classification and detection in smart city application,” Sensors, vol. 22, no. 3, p. 892, 2022.
- [20] I. Showkat and V. Gupta, “Smoker Detection Using Machine Learning,” Tuijin Jishu/Journal of Propulsion Technology, vol. 44, no. 4, pp. 1533-1544, 2023.
- [21] R. Lakatos, et al., “A multimodal deep learning architecture for smoking detection with a small data approach,” Frontiers in Artificial Intelligence, vol. 7, p. 1326050, 2024.
- [22] R. Altabeiri, M. Alsafasfeh, and M. Alhasanat, “Image compression approach for improving deep learning applications,” Int. J. Electr. Comput. Eng. (IJECE), vol. 13, no. 5, pp. 5607-5616, 2023.
- [23] Q. Gu, N. Prodduturi, and S. N. Hart, “Deep Learning in Automating Breast Cancer Diagnosis from Microscopy Images,” medRxiv, p. 2023-06, 2023.
- [24] A. Abubakar, M. Ajuji, and A. M. Turaki, “Diagnostic Accuracy of Deep Learning in Medical Image Analysis-A Case Study Using Deep Burns,” 2023.
- [25] Q. Lv, S. Zhang, and Y. Wang, “Deep learning model of image classification using machine learning,” Advances in Multimedia, vol. 2022, pp. 1-12, 2022.
- [26] D. Agrawal, H. Makwana, S. S. Dave, S. Degadwala, and V. Desai, “Error Level Analysis and Deep Learning For Detecting Image Forgeries,” in 2023 7th International Conference on Computing Methodologies and Communication (ICCMC), 2023, pp. 114-117, doi: 10.1109/ICCMC57404.2023.10048032.
- [27] S. Somantri, I. Yustiana, and A. Nugraha, “Electrical consumption monitoring and controlling system based on IoT and mobile application,” in 2020 International Conference on ICT for Smart Society (ICISS), 2020, pp. 1-5, doi: 10.1109/ICISS50791.2020.9307620.
- [28] Y. Valikhujaev, A. Abdusalomov, and Y. I. Cho, “Automatic fire and smoke detection method for surveillance systems based on dilated CNNs,” Atmosphere, vol. 11, no. 11,