

Prediksi Kualitas Udara Berbasis Citra Menggunakan Pre-Trained Inception V3 dalam Perspektif Keberlanjutan

Aliyah Kurniasih^{1*}, Cantika Nur Previana², Andi Purnomo³

^{1,2,3}Program Studi Ilmu Komputer, Universitas Ary Ginanjar

*aliyah.kurniasih@uag.ac.id

Abstrak

Perkembangan kecerdasan buatan mendorong optimalisasi model deep learning untuk analisis citra. Polusi udara merupakan masalah lingkungan yang signifikan dan berdampak pada kesehatan manusia serta keseimbangan ekosistem. Peningkatan emisi dari aktivitas industri, transportasi, dan pembakaran bahan bakar fosil menjadi faktor utama yang memperburuk kualitas udara di berbagai wilayah. Penelitian ini bertujuan menganalisis pengaruh preprocessing data dan strategi pelatihan terhadap kinerja model, meliputi penghapusan data citra duplikat, pembagian data, augmentasi data, penggunaan class weight pada data latih, serta pengaturan learning rate menggunakan Inception V3 transfer learning model. Hasil menunjukkan bahwa kombinasi strategi tersebut mencapai accuracy sebesar 89,28% pada tingkat nilai error hanya sebesar 0,338, memiliki stabilitas, dan kemampuan generalisasi model yang baik. Penerapan preprocessing dan strategi pelatihan yang tepat dan efektif dalam meningkatkan kinerja model. Sehingga model yang lebih akurat dan andal dapat mendukung pengambilan keputusan berbasis data secara lebih efisien serta berkontribusi pada berbagai sektor seperti kesehatan dan lingkungan dalam mendukung pembangunan berkelanjutan.

Kata kunci : InceptionV3, augmentasi citra, class weight, learning rate, pembagian data, polusi udara

Abstract

Advances in artificial intelligence are driving the optimization of deep learning models for image analysis. Air pollution is a significant environmental problem that impacts human health and the balance of ecosystems. Increased emissions from industrial activities, transportation, and the burning of fossil fuels are major factors contributing to deteriorating air quality in various regions. This study aims to analyze the influence of data preprocessing and training strategies on model performance, including the removal of duplicate image data, data splitting, data augmentation, the use of class weights on training data, and learning rate tuning using the Inception V3 transfer learning model. The results show that the combination of these strategies achieved an accuracy of 89.28% with an error rate of only 0.338, demonstrating stability and good model generalization capabilities. The application of appropriate and effective preprocessing and training strategies enhances model performance. Consequently, a more accurate and reliable model can support data-driven decision-making more efficiently and contribute to various sectors such as health and the environment in supporting sustainable development.

Keywords : InceptionV3, image augmentation, class weights, learning rate, data splitting, air pollution

1. Pendahuluan

Pencemaran udara dapat diartikan adanya satu atau lebih zat fisik, kimia, atau biologis di udara dalam jumlah yang dapat mengancam kesehatan manusia, hewan, dan tumbuhan, mengganggu estetika serta kenyamanan atau merusak aset.

Beberapa gangguan fisik terkait pencemaran udara seperti polusi udara, suhu tinggi, radiasi, atau pencemaran cahaya dianggap sebagai bagian dari polusi udara^[1]. Polusi udara baik di luar maupun di dalam ruangan berkontribusi terhadap munculnya penyakit pernapasan serta

masalah kesehatan lainnya dan merupakan faktor utama dalam meningkatnya angka penyakit dan kematian^[2]. Polusi udara sangat berdampak signifikan terhadap organ pernapasan manusia, seperti menyebabkan gejala bersin, gatal pada tenggorokan, mata berair, dan batuk. Individu yang memiliki sensitivitas tinggi pada organ pernapasannya, polusi udara dapat memicu asma yang bisa mengancam nyawa dalam beberapa kasus^[3]. Terpapar polusi udara dalam jangka waktu yang panjang dapat juga meningkatkan kemungkinan terjadinya penyakit jantung, serangan stroke, dan bahkan kematian yang terjadi lebih awal^[4]. Polusi udara tersebut dapat bersumber dari emisi gas buang yang dihasilkan oleh kendaraan^[1], pencemaran lingkungan yang dihasilkan dari asap industri pabrik^[5], pembakaran sampah^[6], dan kondisi alam seperti aktivitas vulkanik^[7]. Kualitas udara yang buruk merupakan salah satu penyebab utama masalah kesehatan global. Berdasarkan data WHO, lebih dari 7 juta kematian prematur per tahun terkait dengan paparan polusi udara. Selain itu, kualitas udara yang rendah berdampak pada produktivitas ekonomi, perubahan iklim, dan kualitas hidup masyarakat. Pemantauan kualitas udara yang akurat menjadi aspek krusial dalam upaya mitigasi dampak ini^[8].

Pemantauan kualitas udara banyak mengandalkan stasiun sensor fisik yang mampu mengukur parameter seperti PM2.5, PM10, NO2,

SO2, O3, dan CO. Namun, biaya instalasi dan perawatan yang tinggi, keterbatasan distribusi geografis, serta kurangnya akses di wilayah berkembang menyebabkan ketersediaan data sering kali tidak merata^[9]. Seiring perkembangan teknologi pengolahan citra digital dan *deep learning*, muncul peluang untuk memanfaatkan citra visual dari citra langit atau citra satelit yang dapat berkorelasi dengan tingkat polusi udara. Menggunakan *Convolutional Neural Network* (CNN), model dapat dilatih untuk mengenali pola visual yang tidak kasat mata secara langsung namun relevan dengan kualitas udara.

Penelitian ini mengusulkan prediksi kualitas udara berbasis data citra dengan kebaruan menggunakan metode *Pre-trained Inception V3* model, di mana menggunakan *Convolutional Neural Network* sebagai pondasi arsitektur yang mampu mengekstrak fitur visual dari citra lingkungan sebagai representasi kondisi atmosfer secara *real-time* seperti foto langit, maupun data visual perkotaan. Pendekatan lain seperti pembobotan kelas pada data latih, strategi pembagian dan augmentasi data, yang tepat sangat penting untuk menghasilkan model yang general. Usulan ini diharapkan dapat meningkatkan efisiensi dibandingkan metode sensor konvensional, dan mendukung upaya pencapaian indikator *Sustainable Development Goals* (SDGs), khususnya pada tujuan 3 tentang kesehatan yang menargetkan pengurangan

kematian akibat polusi udara (indikator 3.9.1), serta tujuan 11 tentang kota berkelanjutan yang menekankan pemantauan tingkat partikulat udara seperti PM2.5 dan PM10 (indikator 11.6.2)^[10]. Dengan demikian penelitian ini bertujuan untuk mengembangkan model prediksi kualitas udara berbasis citra yang tidak hanya akurat secara teknis, tetapi juga relevan untuk di implementasikan secara nyata dalam mendukung kebijakan berbasis data untuk pembangunan berkelanjutan

2. Tinjauan Pustaka

2.1. Penelitian Terkait

Dataset citra India dan Nepal (publik) telah digunakan untuk membuat model yang dapat memprediksi kualitas udara.

1. Pada penelitian Wiryawan & Aditya (2025), melakukan perbandingan dari beberapa teknik *image processing* seperti *histogram equalization*, *limited adaptive histogram equalization*, *gamma correction*, dan *contrast stretching*, untuk meningkatkan kualitas citra. Model di latih menggunakan MobileNet V3 pada 3.000 citra dari total 12.240 citra, resolusi 224x224 piksel. Hasil model terbaik pada saat menggunakan *image processing* yaitu *histogram equalization* dengan *accuracy* sebesar 69%^[11].

2. Kemudian penelitian Ozkok (2025), mendapati *accuracy* sebesar 90.45% pada saat menggunakan Xception model, augmentasi data

berupa *rotation*, *shifting*, *shearing*, *zooming*, *horizontal flip*. Resolusi citra 224x224 piksel, 15 *epoch*, *batch size* 16, dan *learning rate* 0.0001^[12]. Selanjutnya pada *state of the art pre-trained* model yang lainnya yaitu Eff-AQI menghasilkan *accuracy* sebesar 95.42%^[13].

3. Pada penelitian Khan et al., (2025), tiga sumber dataset citra digabungkan, melakukan filter citra menggunakan analisis *standard deviation* dan *laplacian* filter untuk memfilter citra yang akan digunakan. *Hyperparameter* menggunakan GA (*Genetic Algorithm*) pada variasi nilai *learning rate* 0.001, 0.0005, 0.0001, *batch size* 32, 64, 128, 256, dan momentum 0.9, 0.95, 0.99, menghasilkan *accuracy* 95.44%^[14].

4. Penelitian Hardini et al., (2023), menggunakan data berupa 3.000 foto langit di Indonesia dan data pendukung yang diperoleh dari jaringan sensor kualitas udara di berbagai wilayah untuk validasi, data diproses untuk memprediksi kualitas udara. Metode *Convolutional Neural Networks* (CNN) digunakan untuk ekstraksi fitur gambar, diikuti dengan analisis statistik menggunakan SmartPLS (*Structural Equation Modeling-Partial Least Squares*). Hasil penelitian menunjukkan bahwa CNN dapat menangkap hubungan kompleks antara kualitas udara dan faktor lingkungan, memberikan prediksi yang lebih akurat dibandingkan metode tradisional. Selain itu, ditemukan bahwa variabel pengalaman digital,

loyalitas, dan kepuasan secara signifikan mempengaruhi adopsi platform *AIR-Protection*^[15].

2.2. Landasan Teori

1. Data *Prprocessing*

Data *preprocessing* merupakan proses mengatasi masalah yang ada dalam dataset sehingga data siap digunakan untuk pelatihan model *machine learning*^[16]. Permasalahan yang ada dalam data bisa berupa *missing value*, data duplikat, ketidaksesuaian tipe data dengan isi data^[17].

2. Agumentasi Data

Augmentasi data merupakan proses untuk menghasilkan variasi data baru, dengan tujuan untuk menghasilkan model yang dapat melakukan generalisasi, tangguh, dan mengenali objek dengan lebih baik, serta mencegah kemungkinan terjadinya *overfitting* dan bias^[18].

3. Inception V3

Arsitektur model *deep learning* pada *pre-trained* model InceptionV3, tersusun dari blok penyusun yang bersifat simetris dan asimetris, meliputi lapisan konvolusi, *average pooling*, *max pooling*, *concatenation*, *dropout* serta lapisan *fully connected* yang dapat melakukan pengenalan citra dengan baik^[19].

4. Metrik Evaluasi Model

Accuracy merupakan metrik yang dihitung sebagai persentase prediksi yang benar dari total

prediksi yang dibuat (1). Kemudian metrik seperti *precision* (2), *recall* (3), dan *f1-score* (4)^[19].

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

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


$$\text{Recall} = \frac{TP}{TP+FN} \quad (3)$$

$$F1 - \text{score} = \frac{2 \times \text{Precision} \times \text{Recall}}{P\text{recision} + \text{Recall}} \quad (4)$$

3. Metode Penelitian

3.1. Tahapan Penelitian

Gambar 1 merupakan tahapan dalam penelitian ini, di mulai dari data yang dibersihkan, pembentukan arsitektur model, melatih model, serta yang terakhir evaluasi dan inferensi model. Data *preprocessing* terdiri dari menghapus data duplikat, pembagian data, augmentasi data, dan penanganan data yang tidak seimbang.



Gambar 1. Alur Penelitian.


1. Data

Penelitian ini menggunakan dataset citra India dan Nepal^[20]. Sumber dataset memiliki citra

sebanyak 12.240 data citra berjenis citra RGB (*Red, Green, Blue*) dengan resolusi yang seragam yaitu 224x224 piksel. Dataset memiliki 6 label kelas, diantaranya *unhealthy sensitive*, *unhealthy*, *very unhealthy*, *moderate*, *good*, dan *hazardous*. Terdapat ketidakseimbangan kelas, di mana kelas *unhealthy sensitive* mendominasi sebagai kelas yang memiliki data citra terbanyak yaitu 2.863 citra atau sebesar 23,4%. Kelas minoritas terdapat pada kelas *hazardous* sejumlah 1.447 citra atau 11,8%. Detail jumlah data dari setiap label kelas seperti yang disajikan pada Tabel 1 dan Gambar 2.

Tabel 1. Jumlah Data Setiap Kelas

Kelas	Jumlah	Persentase
unhealthy sensitive	2.863	23.4%
unhealthy	2.622	21.4%
very unhealthy	2.194	17.9%
moderate	1.573	12.9%
good	1.541	12.6%
hazardous	1.447	11.8%
Total	12.240	100%



Gambar 2. Persentase Data Setiap Kelas.

Setelah dilakukan pengecekan lebih lanjut, bahwa terindikasi terdapat citra duplikat dengan kelompok citra yang duplikat sebanyak 129, total file citra duplikat sebanyak 258 citra. Jumlah citra

duplikat dari setiap label kelas disajikan pada Tabel 2.

Tabel 2. Jumlah Citra Duplikat

Kelas	Kelompok Citra Duplikat	File Citra Duplikat
Unhealthy sensitive	4	8
unhealthy	2	4
very unhealthy	1	2
unhealthy sensitive = very unhealthy	1	2
good	1	2
hazardous	120	240
Total	129	258

2. Data Preprocessing

Data *preprocessing* yang dilakukan terdiri dari 4 proses, pertama melakukan penanganan dari data citra yang duplikat, kedua melakukan pembagian data, ketiga augmentasi data, dan keempat *imbalance class* data. Data citra duplikat dilakukan penanganan berupa penghapusan file citra dari setiap kelompok citra dan disisakan hanya satu file citra dari setiap kelompok citra.

Langkah awal yang dilakukan pada pembagian data yaitu melakukan pemisahan data menjadi tiga bagian dari setiap label kelas. Data latih sebanyak 70%, data validasi 20%, dan data uji 10%. Kemudian setiap jumlah pada unik data dari data latih, data validasi, dan data uji, hanya 50% data yang akan digunakan untuk melatih dan mengevaluasi model. Proses augmentasi yang dilakukan pada data latih diantaranya melakukan normalisasi data, memutar citra asli pada sudut sebesar 25 derajat, memiringkan sudut pandang citra secara acak dengan intensitas geseran sebesar 10% atau 0.1 dari total ukuran citra,

memperbesar citra secara acak dalam kisaran 10% dari ukuran aslinya, dan membalik gambar secara horizontal secara acak selama proses pelatihan. Pada data validasi dan data uji hanya dilakukan normalisasi data citra. Setiap kali model melakukan iterasi pelatihan, model akan memproses 16 gambar yang telah di augmentasi secara bersamaan sebelum memperbarui parameter (bobot) *neural network*, citra yang digunakan di *resize* menjadi 160x160 piksel.

Imbalance class data citra yaitu dengan cara menghitung bobot setiap kelas berbanding terbalik dengan jumlah sampel pada kelas tersebut (5), di mana w_i merupakan bobot untuk kelas ke- i , n_i jumlah sampel pada kelas ke- i , N total seluruh sampel dalam dataset, dan K merupakan jumlah total kelas.

$$w_i = \frac{1}{n_i} \times \frac{N}{K} \quad (5)$$

Pendekatan ini digunakan agar kelas yang memiliki jumlah sampel lebih sedikit akan memperoleh bobot yang lebih besar, sehingga kontribusi dalam *loss function* menjadi lebih signifikan selama proses pelatihan. Sebaliknya, pada kelas mayoritas akan memiliki bobot lebih kecil untuk mencegah dominasi terhadap proses pelatihan model. Strategi implementasi ini bertujuan untuk meningkatkan performa model dalam mendeteksi kelas minoritas serta mengurangi bias prediksi, terutama pada dataset yang tidak seimbang sehingga model mampu

melakukan generalisasi yang lebih baik terhadap seluruh distribusi kelas.

3. Arsitektur Model

Convolutional layer pada Inception V3 model, selain sebagai pondasi arsitektur model, *convolutional layer* tersebut sekaligus menjadi *feature extraction* pada data citra. Seluruh *layer* pada *base* model InceptionV3 dibekukan agar parameter bobot dari setiap *layer* tidak diperbarui selama proses pelatihan. Tujuannya untuk mempertahankan representasi fitur umum yang telah dipelajari sebelumnya dari dataset *ImageNet*, sehingga model tidak kehilangan kemampuan ekstraksi fitur dasar. Kemudian dilakukan proses *unfreezing* terhadap lima *layer* terakhir, memungkinkan hanya sebagian kecil dari *network* untuk diperbaharui selama pelatihan. Tujuannya agar *layer* tersebut berperan dalam menangkap fitur yang spesifik terhadap domain atau tugas prediksi kualitas udara, sehingga penyesuaian parameter pada bagian ini dapat meningkatkan performa model terhadap dataset citra polusi udara tanpa mengganggu representasi fitur dasar yang telah stabil.

Selanjutnya terdapat penyesuaian arsitektur setelah *base* model, yaitu penambahan dua *hidden layer* yang terdiri dari *convolutional layer* dan *dense layer*, serta *output layer*. Tabel 3 merupakan arsitektur yang dirancang pada penelitian ini.

Tabel 3. Arsitektu Model

Layer	Jenis Layer	Nilai
Input Layer		RGB 160x160
Base Model		
Hidden Layer	Conv2D	padding same
		ReLU
		unit 32, (3, 3)
	batchNormalizat ion	
	MaxPool2D	(2, 2)
	Flatten	
Hidden Layer	Dense Layer	unit 512
		ReLU
	Dropout Layer	0.2
Output Layer	Dense Layer	unit 6
		Softmax

4. Melatih Model

Proses melatih model dilakukan *hyperparameter tuning learning rate*, di mana nilai *learning rate* awal sebesar 0.01 dan akan tetap konstan dalam rentang 10 *epoch*, kemudian mengalami penurunan secara eksponensial setiap kali jumlah *epoch* mencapai kelipatan dari 10 *epoch*, menggunakan $epoch/10$ menunjukkan berapa kali penurunan telah terjadi hingga *epoch* 30. Proses tersebut dilakukan dengan Formula (6), di mana η_0 merupakan *initial learning rate*, γ adalah *decay factor* ($0 < \gamma < 1$) dan *epoch* yaitu iterasi pelatihan saat ini, T *decay epoch* (interval penurunan), dan $\lfloor \cdot \rfloor$ menyatakan operasi pembulatan ke bawah.

$$\text{learning rate} = \eta_0 \times \gamma^{\left\lfloor \frac{\text{epoch}}{T} \right\rfloor} \quad (6)$$

Hyperparameter loss function digunakan untuk menghitung selisih atau ketidakmiripan antara distribusi probabilitas hasil prediksi model dan distribusi label sebenarnya (*ground truth*). Kemudian mengoptimasi proses *training* model

menggunakan Adam (*Adaptive Moment Estimation*) untuk memperbarui bobot *neural network* agar meminimalkan nilai *loss function* (kesalahan prediksi). Jumlah total iterasi untuk seluruh data latih 30, jumlah sampel data yang dapat melewati *neural network* pada satu waktu adalah 16, dan validasi selama proses *training* menggunakan data validasi, menggunakan *callbacks function* yang telah diatur, dan data latih yang telah dilakukan pembobotan pada setiap kelas. *Hyperparameter* beserta nilainya disajikan dalam Tabel 4.

Tabel 4. *Hyperparameter* Model

Hyperparamter	Nilai
Loss Function	Categorical Crossentropy
Optimizer	Adam
Epoch	30
Batch Size	16
Validation	Data validasi
Callbacks	LR scheduler
Class Weight	Class Weights

Melatih model menggunakan metrix *accuracy* dan *loss function* untuk melihat kehandalan model. *Loss function* digunakan untuk mengukur seberapa besar perbedaan antara hasil prediksi model dengan target (nilai aktual)^[21].

5. Evaluasi dan Inferensi Model

Evaluasi model dilakukan menggunakan data uji agar menghasilkan model yang dapat mengeneralisasi data dengan baik. Evaluasi model menggunakan metrix *accuracy*, *precision*, *recall*, dan *f1-score*. Inferensi model juga menggunakan

data uji, untuk membuktikan hasil model yang telah dilatih dapat memberikan prediksi kelas sesuai dengan kelas aktualnya, dan memberikan nilai probabilitas hasilnya.

4. Hasil dan Pembahasan

4.1. Hasil Penelitian

1. Hasil Data Preprocessing

Setelah dilakukan penanganan pada *file* citra duplikat maka jumlah data kelompok citra yang duplikat menjadi 129 *file* citra.

Total *file* citra setelah penghapusan adalah 12.111 data, di mana data latih 8.475 citra dan hanya 4.236 citra (50%) yang digunakan untuk melatih model. Data validasi 2.420 citra dan sebanyak 1.209 citra (50%) yang digunakan untuk memvalidasi model pada saat pelatihan. Data uji 1.216 citra dan hanya 607 (50%) digunakan untuk mengevaluasi model. Komposisi jumlah setiap kelas dari data latih, data validasi dan data uji disajikan pada Tabel 5.

Tabel 5. Hasil Pembagian Data

Data	Kelas	Jumlah	50%
latih	unhealthy sensitive	2.001	1.000
	unhealthy	1.833	916
	very unhealthy	1.534	767
	moderate	1.101	550
	good	1.078	539
	hazardous	928	464
validasi	unhealthy sensitive	571	285
	unhealthy	524	262
	very unhealthy	438	219
	moderate	314	157
	good	308	154

Data	Kelas	Jumlah	50%
uji	hazardous	265	132
	unhealthy sensitive	287	143
	unhealthy	263	131
	very unhealthy	220	110
	moderate	158	79
	good	154	77
	hazardous	134	67
Total		12.111	6.052

Tabel 6 merupakan hasil dari pembobotan kelas, di mana kelas mayoritas *unhealthy sensitive* dengan jumlah data citra terbanyak memiliki bobot paling kecil yaitu 0.706, dan kelas minoritas *hazardous* memiliki bobot paling besar yaitu 1.5255.

Tabel 6. Hasil Pembobotan

Kelas	Bobot
unhealthy sensitive	0.706
unhealthy	0.7707
very unhealthy	0.9205
moderate	1.2836
good	1.3098
hazardous	1.5255

2. Hasil Arsitektur Model

Tabel 7 merupakan hasil arsitektur model yang telah didefinisikan beserta *output shape* dan jumlah parameter yang dihasilkan dari setiap *layer*. Total parameter sebanyak 22.412.742 dan *trainable* parameter sebanyak 609.894, *non-trainable* parameter sebanyak 21.802.848.

Tabel 7. Hasil Arsitektur Model


Layer	Output Shape	Parameter
Inception_V3 (Functional)	(None, 3, 3, 2048)	21.802.784
conv2d (Conv2D)	(None, 3, 3, 32)	589.856

Layer	Output Shape	Parameter
batch_normalization (BatchNormalization)	(None, 3, 3, 32)	128
max_pooling2d (MaxPooling2D)	(None, 1, 1, 32)	0
flatten (Flatten)	(None, 32)	0
dense (Dense)	(None, 512)	16.896
dropout (Dropout)	(None, 512)	0
dense (Dense)	(None, 6)	3.078


3. Hasil Melatih Model

Training model selama 86 menit menggunakan engine GPU T4 pada epoch ke 30 dan learning rate 0,0001 menghasilkan accuracy sebesar 89,17% dengan loss function 28,28%, di mana validation accuracy sebesar 87,84% dan validation loss function sebesar 33,92%.

Gambar 3 menunjukkan perkembangan accuracy model selama proses training dan validasi terhadap 30 epoch. Gambar 4 merupakan training dan validation loss selama 30 epoch.



Gambar 3. Accuracy Training Model.



Gambar 4. Loss Function Training Model.


4. Hasil Evaluasi Model

Evaluasi model menghasilkan nilai accuracy sebesar 89,28% dengan loss function 33,80%, dan menghasilkan nilai precision sebesar 88,53%, recall 89,55% dan f1-score 88,94%. Detail nilai precision, recall, f1-score dari setiap kelas disajikan pada Tabel 8.

Tabel 8. Hasil Evaluasi Model

Kelas	Precision	Recall	F1-score	Support
unhealthy	90,30%	84,62%	92,73%	143
sensitive				
unhealthy	95,20%	90,84%	92,97%	131
very	92,73%	92,73%	92,73%	110
unhealthy				
moderate	86,25%	87,34%	86,79%	79
good	79,78%	92,21%	85,54%	77
hazardous	86,96%	89,55%	88,24%	67

Gambar 5 merupakan hasil confusion matrix, di mana pada tabel confusion matrix dapat diketahui dengan jelas berapa jumlah data yang diprediksi dengan benar (true), dan berapa jumlah data yang diprediksi dengan salah (false). Hasil tersebut menunjukkan misalnya pada kelas very unhealthy dari total data uji sebanyak 110 citra, menghasilkan 102 citra yang diprediksi dengan benar (true very unhealthy), dan 8 citra yang salah diprediksi (false very unhealthy), citra yang salah diprediksi diantaranya 1 citra diprediksi sebagai good, 3 citra terprediksi hazardous, 1 citra terprediksi moderate, dan 3 citra terprediksi unhealthy sensitive.



Gambar 5. Confusion Matrix.

5. Hasil Inferensi Model

Inferensi model merupakan proses menguji model untuk memprediksi hasil menggunakan input data citra, di mana inferensi model ini dilakukan menggunakan data citra dari data uji yang sudah diketahui label actualnya, agar dapat dipastikan apakah hasil prediksi model sudah sesuai atau belum, kemudian juga menampilkan nilai *confidence* dari hasil prediksinya. Tabel 9 adalah hasil inferensi model menggunakan input data citra kelas *good*, *hazardous*, dan *moderate*, di mana nilai *confidence* yang dihasilkan sudah cukup baik walalupun pengujian dilakukan pada data kelas minoritas seperti *hazardous*.

Tabel 9. Hasil Inferensi Model

Citra	Variabel	Value
	Actual	Unhealthy Sensitive
	Prediction	Unhealthy Sensitive
	Confidence	91,04%
	Actual	Very Unhealthy
	Prediction	Very Unhealthy
	Confidence	97,14%
	Actual	Hazardous
	Prediction	Hazardous
	Confidence	99,98%

4.2. Pembahasan

Berdasarkan hasil eksperimen, proses *training* model arsitektur menunjukkan performa yang stabil, konvergen, dan tidak *overfitting*. Grafik *training* dan *validation accuracy* serta *loss* mengonfirmasi bahwa nilai *accuracy* terus naik hingga mencapai 89,17% pada *training* dan 87,84% pada *validation* di epoch ke-30, sejalan dengan grafik *loss* yang melandai secara konsisten 28,28% (train) dan 33,92% (val). Ketika d evaluasi pada data uji, model mampu mempertahankan stabilitas kinerjanya dengan menghasilkan nilai *accuracy* akhir sebesar 89,28% dan skor rata-rata *precision* 88,53%, *recall* 89,55%, serta *f1-score* 88,94%. Jika mengamati melalui *confusion matrix*, performa impresif ini sangat diperkuat oleh kemampuan model dalam mengklasifikasikan kategori kritis seperti kelas *unhealthy_sensitive* 121 prediksi benar dan *unhealthy* 119 prediksi benar, meskipun terdapat sedikit tantangan minor berupa misklasifikasi kecil antara kelas yang berdekatan rentangnya, seperti kelas *good* dan *moderate*. Dampak nyata dari hasil *training* selama 86 menit menggunakan GPU T4 ini adalah hadirnya sebuah model klasifikasi kualitas udara yang sangat andal, seimbang, dan siap diimplementasikan untuk skenario dunia nyata. Tingginya nilai *f1-score* dan *recall* pada kelas-kelas seperti *unhealthy*, *unhealthy sensitive*, dan *very unhealthy* memberikan jaminan bahwa

model ini memiliki tingkat *false negative* yang sangat rendah untuk kategori udara. Implikasi praktisnya adalah sistem pendeteksi ini tidak akan melewati kondisi udara buruk yang mengancam kesehatan masyarakat, sehingga sangat aman dan efektif jika digunakan sebagai sistem peringatan dini kualitas lingkungan. Melalui efisiensi arsitektur yang memanfaatkan *transfer learning* Inception V3, pemangku kepentingan maupun pengembang aplikasi dapat langsung memanfaatkannya untuk mitigasi risiko kesehatan publik secara presisi dan objektif.

5. Kesimpulan

Berdasarkan hasil penelitian, bahwa penerapan preprocessing dan strategi pelatihan yang tepat, meliputi penghapusan data citra duplikat, skema pembagian data yang proporsional, augmentasi data, penggunaan class weight, serta pengaturan hyperparameter seperti learning rate, memberikan pengaruh signifikan terhadap peningkatan kinerja model deep learning. Kombinasi seluruh faktor tersebut menghasilkan model yang lebih akurat, robust, dan memiliki kemampuan generalisasi yang lebih baik. Selain itu, temuan ini juga berkontribusi pada pencapaian Sustainable Development Goals (SDGs), khususnya dalam mendukung pengambilan Keputusan berbasis data yang lebih efektif dan efisien di berbagai bidang seperti kesehatan dan lingkungan, sehingga mendorong

peningkatan kualitas hidup dan keberlanjutan pembangunan..

6. Daftar Pustaka

- [1] N. Putu and D. Arwini, "Dampak Pencemaran Udara Terhadap Kualitas Udara di Provinsi Bali," *J. Ilm. Vastuwidya*, vol. 2, no. 2, pp. 20–30, 2019.
- [2] I. Buana and D. A. Harahap, "Asbestos , Radon and Polusi Udara Sebagai Faktor Resiko Kanker Paru pada Perempuan Bukan Perokok," *Averrous J. Kedokt. dan Kesehat. Malikussaleh*, vol. 8, no. 1, pp. 1–16, 2022, doi: <https://doi.org/10.29103/averrous.v8i1.7088>.
- [3] A. A. Anandari, A. F. Wadjdi, and G. Harsono, "Dampak Polusi Udara terhadap Kesehatan dan Kesiapan Pertahanan Negara di Provinsi DKI Jakarta," *J. Educ.*, vol. 6, no. 2, pp. 10868–10884, 2024, doi: 10.31004/joe.v6i2.4880.
- [4] Aynun Zubaydah, Azza Zauziyah Sabilah, Dyah Permata Sari, and Fania Nur Aulia Hidayah, "Mengurangi Emisi: Mendorong Transisi ke Energi Bersih untuk Mengatasi Polusi Udara," *BIOCHEPHY J. Sci. Educ.*, vol. 4, no. 1, pp. 11–21, 2024, doi: 10.52562/biocephy.v4i1.1062.
- [5] A. A. Rifai and M. Azzahra, "Analisis Dampak Asap Pabrik Industri PT Multi Energi Biomassa Terhadap Kondisi Masyarakat Sekitar," *J. Inov. dan Pengabd. Kpd. Masy.*, vol. 2, no. 3, pp. 637–645, 2023, doi: <https://doi.org/10.58578/aldyas.v2i3.1487>.
- [6] U. K. Viesta Tya Amanda W, Rifchyka Putri Hermawan, "Implikasi Hukum Lingkungan Pencemaran Udara: Tinjauan Penegakan dan Tanggung Jawab Hukum (Studi Kasus : Kebakaran TPA Kota Semarang)," *J. Ilm. Wahana Pendidik.*, vol. 10, no. 24, pp. 802–810, 2024, doi: <https://jurnal.peneliti.net/index.php/JIWP/article/view/9236> p-ISSN:
- [7] J. N. Saly and C. Metriska, "Kebijakan Pemerintah Dalam Pengendalian Pencemaran Udara di Indonesia Berdasarkan Undang-Undang Nomor 32 Tahun 2009," *J. Kewarganegaraan*, vol. 7, no. 2, pp. 1642–1648, 2023, [Online]. Available:

- <https://journal.upy.ac.id/index.php/pkn/article/view/5405/3206>)
- [8] WHO, "Air pollution," World Health Organization. Accessed: Apr. 28, 2026.
 - [9] Dinas Lingkungan Hidup, "Stasiun Pemantauan Kualitas Udara," Dinas Lingkungan Hidup.
 - [10] UN. Secretary-General and Inter-Agency and Expert Group on Sustainable Development Goal Indicators, "Final List of Proposed Sustainable Development Goal Indicators (Annex IV of Report of the Inter-Agency and Expert Group on Sustainable Development Goal Indicators: Note / by the Secretary-General)," *Rep. Inter-Agency Expert Gr. Sustain. Dev. Goal Indic.*, pp. 1–62, 2016.
 - [11] W. A. Wiryawan and C. S. K. Aditya, "Optimization of Sky Image Enhancement to the Performance of Air Quality Classification Model Using Mobilenet V3," *Decod. J. Pendidik. Teknol. Inf.*, vol. 5, no. 3, pp. 1293–1311, 2025, doi: 10.51454/decode.v5i3.1412.
 - [12] F. O. Ozkok, "Image-Based Air Pollution Classification Using Deep Learning Techniques," *Eurasia Proc. Sci. Technol. Eng. Math.*, vol. 35, pp. 302–313, 2025, doi: 10.55549/epstem.1806639.
 - [13] S. Utomo *et al.*, *Eff-AQI: An Efficient CNN-Based Model for Air Pollution Estimation: A Study Case in India*, vol. 1, no. 1. Association for Computing Machinery, 2023. doi: 10.1145/3582515.3609531.
 - [14] A. A. Khan, M. A. Majid, and A. Dandoush, "Image-Based Air Quality Estimation Using Convolutional Neural Network Optimized by Genetic Algorithms: A Multi-Dataset Approach," *Int. J. Adv. Comput. Sci. Appl.*, vol. 16, no. 3, pp. 1177–1185, 2025, doi: 10.14569/IJACSA.2025.01603113.
 - [15] M. Hardini, M. H. R. Chakim, L. Magdalena, H. Kenta, A. S. Rafika, and D. Julianingsih, "Image-based Air Quality Prediction using Convolutional Neural Networks and Machine Learning," *APTISI Trans. Technopreneursh.*, vol. 5, no. 1SP, pp. 109–123, 2023, doi: 10.34306/att.v5i1Sp.337.
 - [16] A. Kurniasih and C. N. Previana, "Implementation of GridSearchCV to Find the Best Hyperparameter Combination for Classification Model Algorithm in Predicting Water Potability," *J. Artif. Intell. Eng. Appl.*, vol. 4, no. 2, pp. 1174–1182, 2025, doi: 10.59934/jaiea.v4i2.844.
 - [17] Achmad Baroqah Pohan, Irmawati, and A. Kurniasih, "Optimization of Classification Algorithm with GridSearchCV and Hyperparameter Tuning for Sentiment Analysis of the Nusantara Capital City," *J. Artif. Intell. Eng. Appl.*, vol. 3, no. 3, pp. 808–814, 2024, doi: 10.59934/jaiea.v3i3.514.
 - [18] M. I. Shiddiq and A. Kurniasih, *Enhancing Exam Cheating Detection with MobileOne: A YOLOv5 Algorithm Approach to Abnormal Behavior Recognition*, no. Bic 2024. Atlantis Press International BV, 2025. doi: 10.2991/978-94-6463-854-7_2.
 - [19] M. B. A. Rachman, A. Kurniasih, A. Sundawijaya, and A. Nuraminah, "Penerapan Blok SE-NET Pada Deep Learning Inceptionv3 untuk Meningkatkan Deteksi Penyakit Mpx pada Manusia," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 5, pp. 987–992, 2024, doi: 10.25126/jtiik.2024117978.
 - [20] A. Rouniyar, P.-A. Hsiung, S. Utomo, and J. Ayeelyan, "Air Pollution Image Dataset from India and Nepal," Kaggle Dataset. Accessed: Mar. 02, 2026.
 - [21] R. A. Akmal, S. Hartati, and A. Kurniasih, "Penerapan Pre-Trained Networks untuk Deteksi Jenis Tanaman Herbal Berdasarkan Citra Daun," *Infomatek*, vol. 26, no. 2, pp. 265–272, 2024, doi: 10.23969/infomatek.v26i2.19474.