Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

Klasifikasi Kekeruhan Air Berbasis Citra Menggunakan EfficientNet-Lite0 pada Raspberry Pi 4 untuk Pemantauan Real-Time Instalasi Pengolahan Air Minum

Haryono✉, Muhammad Nur*✉, Rizki Darmawan✉
Fakultas Teknologi Informasi dan Digital, Universitas Bani Saleh, Indonesia

Abstrak

Kekeruhan merupakan parameter wajib kualitas air minum yang harus dipantau secara kontinu, tetapi turbidimeter konvensional memerlukan kontak langsung dengan sampel dan kalibrasi rutin, serta belum mendukung pemantauan *real-time* berbiaya rendah di instalasi pengolahan air minum. Penelitian ini bertujuan mengembangkan dan memvalidasi sistem klasifikasi kekeruhan air berbasis citra menggunakan EfficientNet-Lite0 yang dijalankan langsung pada Raspberry Pi 4. *Dataset* seimbang berisi 600 citra sampel air dari Perumda Tirta Bhagasasi, Bekasi, dikelompokkan ke dalam tiga kelas, yaitu jernih (<25 NTU), sedang (100–200 NTU), dan keruh (>300 NTU), kemudian dibagi secara terstratifikasi menjadi 80% data latih dan 20% data validasi. Citra diubah ukurannya menjadi 224×224 piksel, dinormalisasi, dan diaugmentasi melalui rotasi, *flip* horizontal, *zoom*, serta penyesuaian kecerahan. Model dilatih dengan *transfer learning* dua fase dari bobot ImageNet, lalu dikonversi ke format TensorFlow Lite dengan kuantisasi *dynamic-range* dan diintegrasikan dengan *dashboard* web berbasis Flask. Hasil pengujian menunjukkan akurasi pelatihan 99,79% dan akurasi validasi 100%, dengan *precision*, *recall*, dan *F1-score* sebesar 1,00 pada ketiga kelas pada data validasi yang juga digunakan untuk pemilihan model dan belum diuji pada data uji independen tanpa kesalahan klasifikasi pada 120 citra validasi. Pada Raspberry Pi 4, sistem berjalan stabil pada 0,7–0,8 FPS dengan rata-rata skor kepercayaan 0,91–0,97 dan estimasi 21, 182, serta 381 NTU yang merupakan konstanta pemetaan per kelas dan bukan hasil pengukuran kuantitatif untuk kelas jernih, sedang, dan keruh. Temuan ini menunjukkan bahwa model *deep learning* ringan pada perangkat *edge* layak digunakan sebagai alat pendukung pemantauan kekeruhan tanpa kontak yang hemat biaya, meskipun validasi lapangan dan kalibrasi terhadap turbidimeter acuan masih diperlukan.

Kata Kunci: *Computer Vision*; *Edge Computing*; Kualitas Air; TensorFlow Lite; *Transfer Learning*

Abstract

Turbidity is a mandatory parameter for drinking water quality that must be continuously monitored, but conventional turbidimeters require direct contact with the sample and regular calibration, and they do not yet support low-cost real-time monitoring at water treatment facilities. This study aims to develop and validate an image-based water turbidity classification system using EfficientNet-Lite0 running directly on a Raspberry Pi 4. A balanced dataset containing 600 water sample images from Perumda Tirta Bhagasasi, Bekasi, was grouped into three classes: clear (<25 NTU), medium (100–200 NTU), and turbid (>300 NTU), then stratified into 80% training data and 20% validation data. The images were resized to 224×224 pixels, normalized, and augmented through rotation, horizontal flipping, zoom, and brightness adjustment. The model was trained using two-phase transfer learning from ImageNet weights, then converted to TensorFlow Lite format with dynamic-range quantization and integrated into a Flask-based web dashboard. Testing results showed a training accuracy of 99.79% and a validation accuracy of 100%, with precision, recall, and F1-score all at 1.00 for the three classes on the validation data, which was also used for model selection and hasn't been tested on independent test data, with no misclassifications on 120 validation images. On a Raspberry Pi 4, the system ran stably at 0.7–0.8 FPS with an average confidence score of 0.91–0.97 and estimates of 21, 182, and 381 NTU, which are class mapping constants rather than quantitative measurement results for clear, moderate, and turbid classes. This finding shows that lightweight deep learning models on edge devices are feasible to use as a cost-effective contactless turbidity monitoring tool, even though field validation and calibration against a reference turbidimeter are still needed.

Keywords: Computer Vision; Edge Computing; TensorFlow Lite; Transfer Learning; Water Quality

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

***Corresponding Author:**
Muhammad Nur, Universitas Bani Saleh, Indonesia
Email: mnur@ubs.ac.id

1. PENDAHULUAN

Penyediaan air minum yang aman merupakan kebutuhan dasar masyarakat sekaligus kewajiban utama penyelenggara air minum. Di Indonesia, Peraturan Menteri Kesehatan Nomor 2 Tahun 2023 menetapkan kekeruhan sebagai parameter fisik wajib air minum dengan kadar maksimum kurang dari 3 NTU (*Nephelometric Turbidity Unit*) [1]. Kekeruhan tidak sekadar berkaitan dengan estetika; partikel tersuspensi berperan sebagai media pengangkut kontaminan sehingga kekeruhan dipandang sebagai parameter paling mendesak untuk dikendalikan pada tahap pengolahan [2]. Pada instalasi pengolahan air (IPA), kekeruhan juga menjadi variabel operasional penting karena gangguan kekeruhan memengaruhi kinerja proses dan waktu pemulihan kualitas air olahan [3]. Kondisi ini relevan bagi Perumda Tirta Bhagasasi yang mengolah air baku untuk wilayah Bekasi dan sekitarnya, sehingga fluktuasi kualitas air baku perlu diketahui sedini mungkin agar penyesuaian proses dapat dilakukan tepat waktu. Berbeda dengan air olahan yang harus memenuhi ambang tersebut, kekeruhan air baku umumnya jauh lebih tinggi dan berfluktuasi, sehingga pemantauannya berfungsi sebagai dasar penyesuaian proses, seperti dosis koagulan, bukan sebagai pemeriksaan kepatuhan mutu air minum.

Pemantauan kekeruhan di IPA umumnya masih mengandalkan turbidimeter nefelometri yang mengukur cahaya terhambur pada sudut sekitar 90° terhadap sumber cahaya [4]. Pendekatan ini terstandar, tetapi analisis berbasis laboratorium membutuhkan peralatan berbiaya tinggi dan tenaga terlatih [5], serta menimbulkan jeda waktu antara terjadinya perubahan kualitas air dan tindakan korektif [6]. Sensor daring berbasis *Internet of Things* (IoT) menawarkan pengukuran kontinu, namun adopsinya masih terkendala biaya perangkat serta kebutuhan penggantian atau pembaruan sensor secara berkala [7]. Di sisi lain, pengelola sistem air menghadapi regulasi yang semakin ketat serta infrastruktur yang mahal dan menua, sehingga membutuhkan alat pemantauan yang lebih efisien [8]. Dengan demikian, diperlukan metode pemantauan kekeruhan air baku yang tidak memerlukan kontak langsung dengan sampel, berbiaya rendah, dan mampu menyajikan informasi secara *real-time*.

Perkembangan kecerdasan buatan membuka peluang baru dalam pemantauan kualitas air. Machine learning telah digunakan untuk mengestimasi parameter kualitas air dari penginderaan jauh dekat permukaan [9] dan berbagai metode kecerdasan buatan untuk deteksi badan air serta pemantauan kualitas air berbasis penginderaan jauh telah dikaji secara sistematis [10]. Pada fasilitas pengolahan, model machine learning berbasis data sensor mampu memprediksi konsentrasi total nitrogen efluen dengan peningkatan kinerja sekitar 41% dibandingkan metode lain [11], sedangkan convolutional neural network (CNN) telah diterapkan untuk memprediksi kelayakan air berdasarkan warna pada citra sampel [12]. CNN unggul dalam mempelajari representasi visual secara *end-to-end* dan terus berkembang melalui teknik kompresi model seperti *pruning* dan kuantisasi [13]. EfficientNet memperkenalkan *compound scaling* yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan sehingga menghasilkan akurasi tinggi dengan jumlah parameter yang jauh lebih kecil [14]. Untuk komputasi di lapangan, Raspberry Pi banyak digunakan sebagai platform IoT berbiaya rendah [15], termasuk sebagai modul *edge* pemrosesan citra pada sistem akuaponik [16]. Elmessery et al. [17] melaporkan waktu inferensi 15,2 ± 3,1 ms pada Raspberry Pi 4B untuk pengendali *deep reinforcement learning* ringan. Optimasi arsitektur model perlu mempertimbangkan perangkat keras sasaran [18], dan kinerja berbagai model deep learning telah dibandingkan pada Raspberry Pi serta perangkat edge lainnya [19].

Meskipun demikian, kajian terdahulu menyisakan beberapa kesenjangan. Pertama, sebagian besar studi kecerdasan buatan untuk kualitas air menggunakan data sensor tabular atau citra penginderaan jauh [9], [10], [11] [12], sedangkan studi berbasis citra RGB yang ada masih menilai kualitas air secara umum dan belum diarahkan pada klasifikasi tingkat kekeruhan air baku di IPA. Kedua, sistem IoT pada IPA seperti yang dikembangkan Forhad et al. [20] memantau pH, oksigen terlarut, TDS, dan suhu menggunakan sensor dan kendali berbasis PLC, sehingga belum mencakup pemantauan kekeruhan

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

berbasis visual. Ketiga, sistem pengenalan citra ringan untuk perairan, misalnya deteksi makroplastik berbasis YOLOv8 [21], membuktikan kelayakan *computer vision* secara *real-time*, tetapi tidak ditujukan untuk klasifikasi tingkat kekeruhan. Sepengetahuan penulis, integrasi EfficientNet-Lite0 dengan Raspberry Pi 4 untuk klasifikasi kekeruhan air baku secara *real-time* dalam konteks IPA air minum di Indonesia belum dilaporkan.

Penelitian ini mengusulkan sistem pemantauan kekeruhan berbasis citra yang menjalankan model EfficientNet-Lite0 hasil *transfer learning* dalam format TensorFlow Lite (TFLite) langsung pada Raspberry Pi 4 tanpa ketergantungan pada komputasi awan. Kontribusi penelitian ini meliputi: (1) *dataset* citra kekeruhan tiga kelas yang dilabeli berdasarkan pengukuran turbidimeter terhadap sampel dari Perumda Tirta Bhagasasi; (2) *pipeline* pelatihan dua fase dan konversi TFLite dengan kuantisasi *dynamic-range* yang dapat dijalankan pada CPU ARM; serta (3) prototipe sistem *real-time* yang dilengkapi estimasi NTU berbasis kelas dan *dashboard* web yang dapat diakses dari perangkat dalam jaringan lokal.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk (1) merancang dan mengevaluasi model klasifikasi kekeruhan air berbasis EfficientNet-Lite0 pada tiga kelas operasional, yaitu jernih, sedang, dan keruh; (2) mengimplementasikan dan menguji inferensi *real-time* model TFLite pada Raspberry Pi 4; serta (3) menyediakan antarmuka pemantauan berbasis web untuk mendukung pengambilan keputusan operator. Bagian selanjutnya dari artikel ini menguraikan metode penelitian, hasil dan pembahasan, serta kesimpulan dan arah penelitian lanjutan.

2. METODE PENELITIAN

Penelitian ini menggunakan desain eksperimental terapan yang terdiri atas enam tahap berurutan: (1) analisis kebutuhan dan pengadaan perangkat; (2) pengumpulan dan pelabelan *dataset*; (3) praproses dan augmentasi data; (4) pelatihan dan evaluasi model; (5) konversi model ke TFLite dan deployment pada perangkat *edge*; serta (6) pengujian sistem secara *real-time* dan validasi *dashboard*. Penelitian dilaksanakan di Perumda Tirta Bhagasasi, Bekasi, dengan sampel air baku yang diambil sebelum proses koagulasi-flokulasi. Arsitektur sistem yang dibangun ditunjukkan pada Gambar 1.

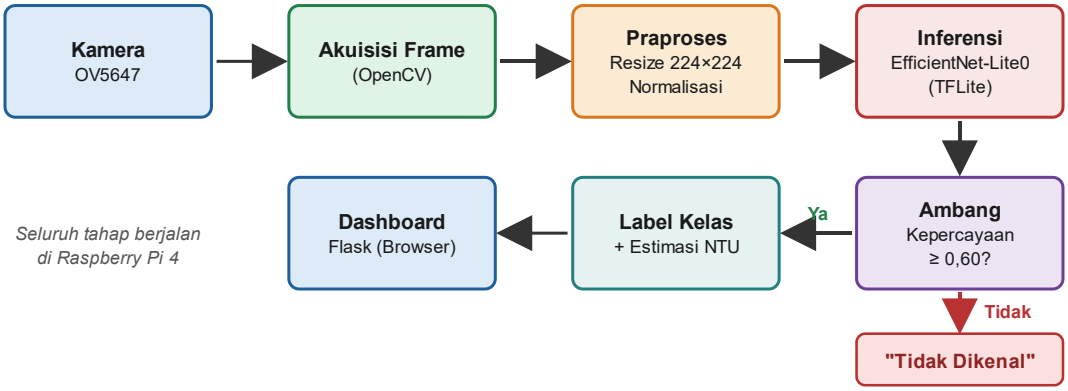

Gambar 1. Arsitektur *Pipeline* Sistem Pemantauan Kekeruhan Air *Real-Time* Berbasis Raspberry Pi 4

Gambar 1 memperlihatkan alur kerja sistem dari akuisisi hingga penyajian hasil. *Frame* dari kamera OV5647 dibaca melalui OpenCV, diubah ukurannya menjadi 224×224 piksel dan dinormalisasi, lalu diproses oleh model EfficientNet-Lite0 dalam format TFLite. Prediksi dengan probabilitas tertinggi di bawah ambang kepercayaan 0,60 ditandai sebagai "Tidak Dikenal", sedangkan prediksi yang melewati ambang dipetakan ke label kelas dan estimasi NTU untuk ditampilkan pada *dashboard* Flask. Seluruh proses berlangsung di perangkat tanpa koneksi ke layanan awan.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

2.1. Perangkat Keras dan Perangkat Lunak

Spesifikasi perangkat yang digunakan dirangkum pada Tabel 1. Raspberry Pi 4 Model B dengan RAM 8 GB berperan sebagai perangkat *edge*, modul kamera OV5647 digunakan untuk akuisisi citra, dan vial kaca borosilikat bening 15 mL digunakan sebagai wadah sampel standar. Pelatihan model dilakukan pada laptop dengan GPU NVIDIA, sedangkan inferensi dijalankan sepenuhnya pada Raspberry Pi 4.

Tabel 1. Spesifikasi Perangkat Keras dan Perangkat Lunak

Komponen	Spesifikasi / Fungsi
Perangkat *edge*	Raspberry Pi 4 Model B, RAM 8 GB, BCM2711 Cortex-A72 1,5 GHz
Kamera	OV5647 5 MP RGB, antarmuka CSI-2, resolusi 2592×1944 piksel
Penyimpanan	MicroSD 32 GB Kelas 10
Platform pelatihan	Laptop dengan GPU NVIDIA, TensorFlow 2.10 (CUDA)
Sistem operasi	Raspberry Pi OS Bullseye 64-bit
Pengolahan citra	OpenCV 4.6
Inferensi model	TensorFlow Lite Runtime 2.10
Web framework	Flask 2.3
Bahasa pemrograman	Python 3.9

Tabel 1 menunjukkan bahwa seluruh komponen sistem menggunakan perangkat keras komoditas dan perangkat lunak sumber terbuka. Konfigurasi ini dipilih agar sistem mudah direplikasi oleh unit pengolahan air lain dengan biaya perangkat keras sekitar Rp2.700.000.

2.2. Pengumpulan dan Pelabelan *Dataset*

Citra diambil menggunakan kamera OV5647 yang dipasang pada tripod tetap dengan jarak 15 cm dari wadah sampel, dengan penerangan lampu cincin LED 5600 K pada intensitas 400–600 lux. Sampel air baku diambil dari intake Perumda Tirta Bhagasasi pada beberapa waktu pengambilan sehingga diperoleh tiga tingkat kekeruhan, kemudian nilai kekeruhan setiap sampel diverifikasi menggunakan turbidimeter HACH 2100N. Setiap kelas terdiri atas 200 citra sehingga total dataset berjumlah 600 citra, sebagaimana dirangkum pada Tabel 2. Karena sampel air baku diambil pada beberapa waktu pengambilan yang berbeda untuk memperoleh tiga tingkat kekeruhan, dan setiap sampel yang telah diverifikasi nilai kekeruhannya direkam berulang kali pada susunan akuisisi yang sama, sebagian citra dalam satu kelas berasal dari sampel air yang sama. Jumlah sampel air fisik dan jumlah sesi akuisisi tidak dilaporkan secara terpisah dari jumlah citra pada penelitian ini; pencatatan identitas sampel dan sesi akuisisi sebagai metadata dataset dijadikan bagian dari perbaikan protokol pada penelitian lanjutan.

Tabel 2. Distribusi *Dataset* per Kelas Kekeruhan

Kelas	Rentang NTU	Jumlah Citra	Data Latih	Data Validasi
Jernih	< 25	200	160	40
Sedang	100–200	200	160	40
Keruh	> 300	200	160	40
Total	–	600	480	120

Tabel 2 menunjukkan bahwa dataset bersifat seimbang dengan proporsi 33,3% untuk setiap kelas. Rentang NTU antarkelas dibuat tidak bersinggungan agar label mencerminkan kategori operasional yang jelas. Label "jernih" pada penelitian ini bersifat relatif terhadap rentang kekeruhan air baku dan tidak menyatakan kesesuaian dengan baku mutu air minum (<3 NTU). Pembagian data dilakukan secara terstratifikasi dengan rasio 80:20 sehingga diperoleh 480 citra latih dan 120 citra validasi, seperti

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

divisualisasikan pada Gambar 2. Pembagian tersebut dilakukan pada tingkat citra, dengan stratifikasi diterapkan untuk menjaga proporsi 160 citra latih dan 40 citra validasi pada setiap kelas sebagaimana tercantum pada Tabel 2. Konsekuensi dari mekanisme ini adalah citra yang berasal dari sampel air dan sesi akuisisi yang sama dapat tersebar pada data latih maupun data validasi, sehingga terdapat potensi kebocoran data pada tingkat sampel. Akurasi validasi yang dilaporkan pada penelitian ini karenanya perlu dibaca sebagai kinerja model pada kondisi akuisisi yang sama (within-session performance), bukan sebagai estimasi kemampuan generalisasi terhadap sampel air atau sesi akuisisi yang sepenuhnya baru. Pemisahan berbasis sampel atau sesi akuisisi (group-wise split) tidak diterapkan pada penelitian ini karena identitas sampel dan sesi akuisisi tidak dicatat sebagai metadata dataset, sehingga pengelompokan citra menurut asal sampel tidak dapat direkonstruksi secara retrospektif tanpa pengumpulan data ulang. Keterbatasan ini dinyatakan secara eksplisit pada bagian keterbatasan penelitian dan dijadikan agenda utama penelitian lanjutan.

2.3. Praproses dan Augmentasi Data

Seluruh citra diubah ukurannya dari 2592×1944 menjadi 224×224 piksel menggunakan interpolasi bilinear, kemudian nilai piksel setiap kanal dibagi 255 sehingga berada pada rentang [0, 1]. Augmentasi daring diterapkan hanya pada data latih menggunakan ImageDataGenerator, meliputi rotasi ±20°, *flip* horizontal dengan peluang 50%, *zoom* ±20%, dan penyesuaian kecerahan ±30%. Citra hasil augmentasi dibangkitkan secara acak pada setiap *epoch* dan tidak disimpan, sehingga data validasi tetap terdiri atas citra asli untuk estimasi kinerja yang tidak bias.

2.4. Arsitektur Model dan Strategi *Transfer Learning*

EfficientNet-Lite0 merupakan varian ringan dari keluarga EfficientNet [14] yang ditujukan untuk inferensi pada perangkat bergerak dan *edge*, dengan sekitar 4,7 juta parameter dan ukuran model sekitar 5,4 MB dalam presisi float32. Bobot hasil pelatihan ImageNet digunakan sebagai inisialisasi, kemudian lapisan klasifikasi asli diganti dengan GlobalAveragePooling2D, *Dropout* (*rate* 0,2), dan Dense tiga neuron dengan aktivasi *softmax*. Pelatihan dilakukan dalam dua fase: pada fase pertama (*epoch* 1–5) seluruh *backbone* dibekukan dan hanya *head* yang dilatih, sedangkan pada fase kedua (*epoch* 6–25) 30 lapisan teratas *backbone* dibuka untuk *fine-tuning*. Konfigurasi pelatihan selengkapnya disajikan pada Tabel 3.

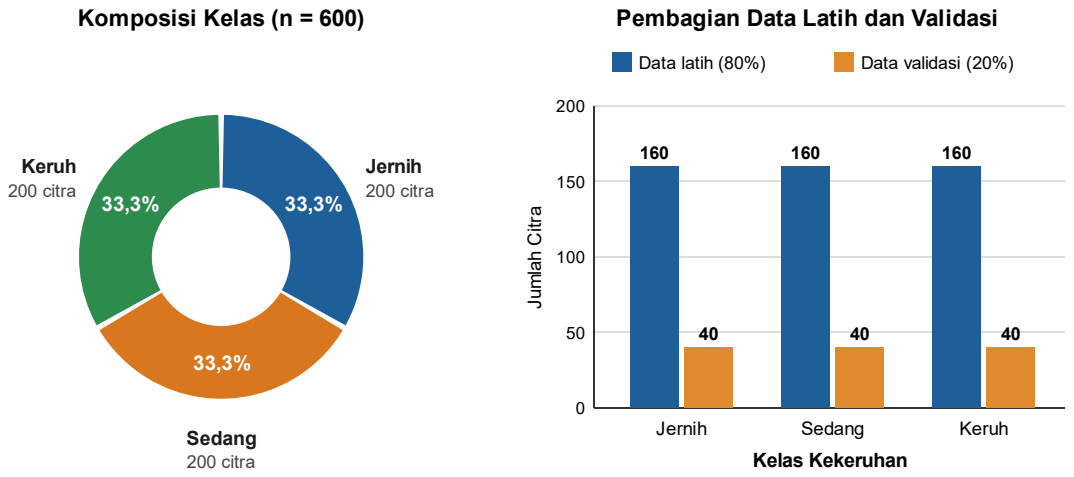

Gambar 2. Distribusi *Dataset*: Komposisi Kelas (kiri) serta Pembagian Data Latih dan Validasi (kanan)

Gambar 2 menegaskan bahwa tidak terdapat ketidakseimbangan kelas pada data latih maupun data validasi. Kondisi ini memungkinkan akurasi digunakan sebagai metrik utama tanpa bias terhadap kelas mayoritas, sekaligus membuat nilai *precision* dan *recall* per kelas dapat dibandingkan secara langsung.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

Tabel 3. Konfigurasi Pelatihan Model

Parameter	Nilai
Backbone	EfficientNet-Lite0 (bobot ImageNet)
Ukuran input	224 × 224 × 3
Kelas keluaran	3 (jernih, sedang, keruh)
Fase 1 (*epoch* 1–5)	*Backbone* dibekukan, hanya *head* dilatih
Fase 2 (*epoch* 6–25)	30 lapisan teratas dan *head* di-*fine-tune*
Total *epoch*	25
Batch size	16
Optimizer / *learning rate*	Adam / 1×10^{-4}
Dropout	0,20
Fungsi *loss*	*Categorical cross-entropy*
Format ekspor	TFLite (kuantisasi *dynamic-range*)

Tabel 3 menunjukkan bahwa *learning rate* yang kecil dan pembekuan *backbone* pada fase awal digunakan untuk mempertahankan fitur umum hasil pelatihan ImageNet, sementara *fine-tuning* pada lapisan teratas memungkinkan model menyesuaikan diri dengan karakteristik visual kekeruhan. *Dropout* dan augmentasi data berfungsi sebagai regularisasi untuk menekan risiko *overfitting* pada *dataset* berukuran terbatas.

2.5. Konversi TFLite, Deployment, dan *Dashboard* Web

Model Keras (.h5) dikonversi ke format TFLite menggunakan TFLiteConverter dengan kuantisasi *dynamic-range*, kemudian ditransfer ke Raspberry Pi 4 melalui SCP. Inferensi dijalankan menggunakan TFLite Interpreter dengan delegasi XNNPACK yang aktif secara otomatis untuk CPU. Ambang kepercayaan 0,60 diterapkan untuk menandai prediksi yang meragukan. Estimasi NTU diperoleh dari pemetaan sentroid kelas, yaitu 21 NTU untuk jernih, 182 NTU untuk sedang, dan 381 NTU untuk keruh. *Dashboard* Flask dijalankan pada port 5001 untuk menampilkan *streaming* kamera beserta hasil klasifikasi dan menyediakan *endpoint* JSON untuk integrasi dengan sistem lain. Rentang NTU ketiga kelas ditetapkan sebagai kategori operasional dengan jarak antarkelas yang sengaja dibuat lebar dan tidak bersinggungan, bukan diturunkan dari ambang baku mutu air minum, sehingga setiap kelas mewakili kondisi air baku yang secara operasional berbeda penanganannya. Nilai 21, 182, dan 381 NTU merupakan konstanta representatif per kelas yang dipetakan secara langsung dari label kelas keluaran model, bukan hasil regresi maupun pengukuran kuantitatif oleh model. Dengan demikian, setiap citra yang diklasifikasikan ke kelas yang sama akan selalu menghasilkan angka estimasi yang identik, dan angka tersebut tidak boleh ditafsirkan sebagai hasil pengukuran kekeruhan aktual sampel; pengukuran kuantitatif tetap mengacu pada turbidimeter HACH 2100N.

2.6. Metrik Evaluasi

Kinerja klasifikasi dievaluasi pada data validasi (n = 120) menggunakan *confusion matrix* dan metrik turunannya, yaitu akurasi, *precision*, *recall*, dan *F1-score* per kelas dengan skema *one-vs-rest*. Akurasi dihitung menggunakan (1).

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

Precision dan *recall* masing-masing dihitung menggunakan (2) dan (3), sedangkan *F1-score* sebagai rata-rata harmonik keduanya dihitung menggunakan (4).

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

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

$$F1 = 2 \times \frac{P \times R}{P+R} \quad (4)$$

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

Pada (1)–(4), A adalah akurasi, P adalah *precision*, R adalah *recall*, TP (*true positive*) adalah jumlah sampel suatu kelas yang diprediksi benar sebagai kelas tersebut, TN (*true negative*) adalah jumlah sampel kelas lain yang benar diprediksi bukan kelas tersebut, FP (*false positive*) adalah jumlah sampel kelas lain yang salah diprediksi sebagai kelas tersebut, dan FN (*false negative*) adalah jumlah sampel kelas tersebut yang salah diprediksi sebagai kelas lain. Selain metrik klasifikasi, kinerja *real-time* pada Raspberry Pi 4 dievaluasi melalui *throughput* inferensi (FPS), rata-rata skor kepercayaan, dan stabilitas prediksi, yaitu persentase frame yang diprediksi sesuai kelas sampel, selama sesi pemantauan kontinu 10 menit untuk setiap kelas. Nilai FPS yang dilaporkan merupakan throughput keseluruhan siklus pemantauan sebagaimana ditampilkan pada dashboard, yaitu mencakup akuisisi frame dari kamera, praproses citra, inferensi TFLite, hingga pengiriman label kelas dan estimasi NTU ke antarmuka web; nilai tersebut bukan waktu inferensi model secara terpisah. Pengukuran dilakukan pada kondisi operasi normal perangkat tanpa instrumentasi profiling per tahap, sehingga waktu inferensi, waktu pemrosesan total, penggunaan RAM, dan sebaran latensi antarframe tidak dicatat sebagai variabel terpisah.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pelatihan model, evaluasi klasifikasi pada data validasi, dan pengujian sistem secara *real-time* pada Raspberry Pi 4, kemudian membahas makna temuan tersebut terhadap kesenjangan penelitian yang telah diidentifikasi pada bagian Pendahuluan.

3.1. Dinamika Pelatihan Model

Gambar 3 dan Gambar 4 menyajikan kurva akurasi dan *loss* selama 25 *epoch*. Pada fase pertama (*epoch* 1–5) ketika *backbone* dibekukan, akurasi pelatihan meningkat dari 0,4063 menjadi 0,8208 dan akurasi validasi dari 0,7917 menjadi 0,9417. Setelah *fine-tuning* dimulai pada fase kedua, akurasi validasi mencapai 1,0000 pada awal fase tersebut (*epoch* ke-8 pada Tabel 4) dan selanjutnya berada pada rentang 0,9917–1,0000 hingga akhir pelatihan.

Tabel 4. Rekapitulasi Riwayat Pelatihan pada *Epoch* Terpilih

Epoch	Akurasi Latih	Akurasi Validasi	*Loss* Latih	*Loss* Validasi
1	0,4063	0,7917	1,1139	0,8182
5	0,8208	0,9417	0,6753	0,5107
8	0,9292	1,0000	0,4953	0,3451
10	0,9542	1,0000	0,3558	0,2994
15	0,9646	1,0000	0,2699	0,2071
20	0,9833	0,9917	0,2037	0,1519
25	0,9917	0,9917	0,1681	0,1342

Tabel 4 mengonfirmasi bahwa peningkatan kinerja terbesar terjadi pada lima *epoch* pertama dan awal fase *fine-tuning*. Penurunan akurasi validasi menjadi 0,9917 pada *epoch* ke-20 dan ke-25 setara dengan satu citra yang salah diklasifikasikan dari 120 citra validasi, sehingga fluktuasi tersebut tergolong kecil. Model akhir yang dievaluasi pada Tabel 5 dan Gambar 5 adalah bobot dengan akurasi validasi tertinggi yang disimpan melalui mekanisme checkpoint selama pelatihan. Karena bobot terbaik dipilih berdasarkan akurasi validasi, data validasi pada penelitian ini berperan ganda sebagai data pemilihan model sekaligus data evaluasi, sehingga nilai pada Tabel 5 dan Gambar 5 harus dibaca sebagai kinerja validasi dan bukan sebagai kinerja pada data uji independen.

Gambar 3 menunjukkan bahwa kurva akurasi validasi berada di atas atau berimpit dengan kurva akurasi pelatihan sepanjang proses pelatihan. Pola ini wajar karena augmentasi hanya diterapkan pada data latih, sehingga data latih lebih sulit diklasifikasikan dibandingkan data validasi yang berupa citra asli.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

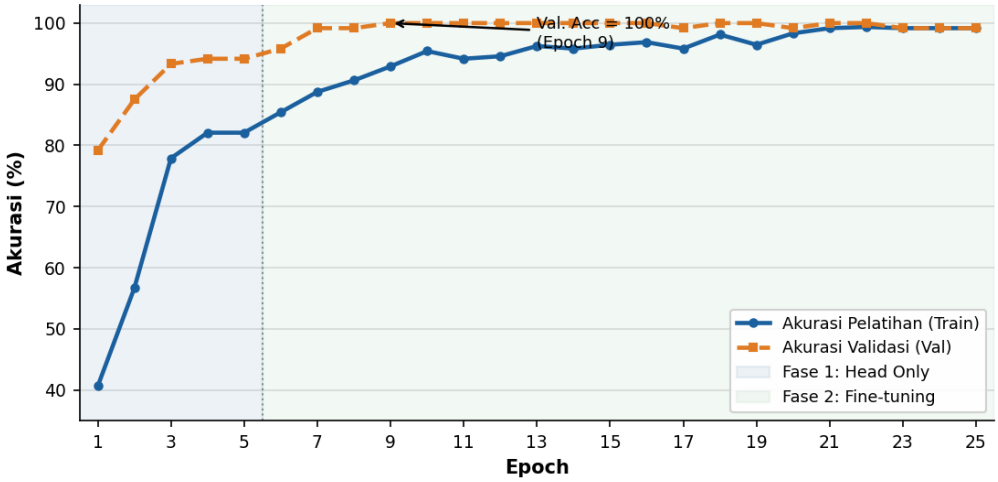

Gambar 3. Kurva Akurasi Pelatihan dan Validasi Model EfficientNet-Lite0 selama 25 *Epoch*

Gambar 4 memperlihatkan penurunan *loss* pelatihan dari 1,1139 pada *epoch* pertama menjadi 0,1681 pada *epoch* ke-25, sedangkan *loss* validasi turun dari 0,8182 menjadi 0,1342. Tidak adanya kenaikan *loss* validasi pada akhir pelatihan mengindikasikan tidak terjadinya *overfitting* terhadap data latih dalam rentang 25 *epoch*, meskipun indikasi ini terbatas pada data validasi yang berasal dari kondisi akuisisi yang sama. Nilai akurasi dan *loss* pada *epoch* terpilih dirangkum pada Tabel 4.

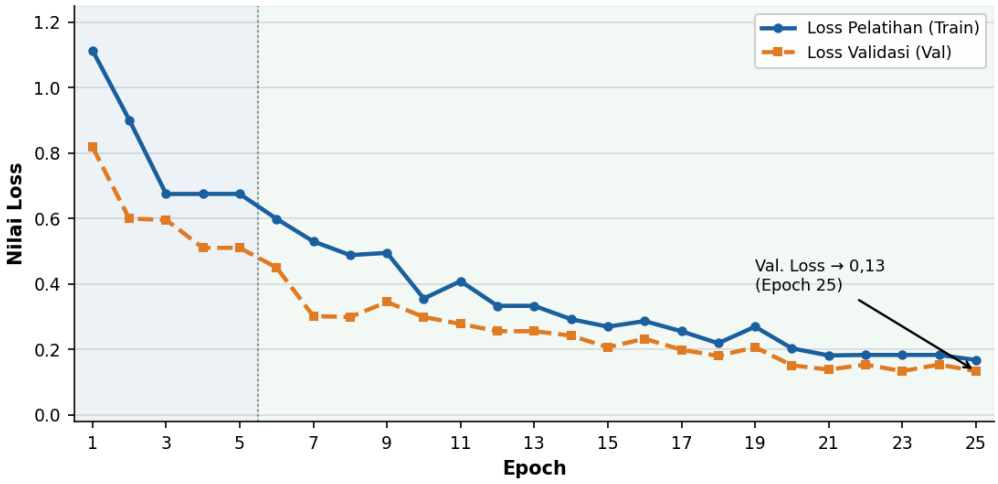

Gambar 4. Kurva *Loss* Pelatihan dan Validasi Model EfficientNet-Lite0 selama 25 *Epoch*

3.2. Evaluasi Klasifikasi pada Data Validasi

Evaluasi ini dilakukan terhadap model akhir, yaitu bobot dengan akurasi validasi tertinggi yang disimpan melalui mekanisme checkpoint selama pelatihan, dan diterapkan pada 120 citra validasi yang terbagi merata ke dalam tiga kelas kekeruhan. Evaluasi tersebut menghasilkan akurasi pelatihan 99,79% dan akurasi validasi 100%. Laporan klasifikasi per kelas pada data validasi disajikan pada Tabel 5, menunjukkan bahwa *precision*, *recall*, dan *F1-score* bernilai 1,00 pada ketiga kelas, sehingga tidak terdapat *false positive* maupun *false negative* pada data validasi. Distribusi prediksi per kelas ditunjukkan melalui *confusion matrix* pada Gambar 5.

Ketiga metrik pada Tabel 5 dihitung dari jumlah prediksi benar dan salah untuk setiap kelas. Precision menyatakan proporsi citra yang diprediksi sebagai suatu kelas dan benar-benar berasal dari kelas tersebut, sehingga mencerminkan tingkat kesalahan positif palsu. Recall menyatakan proporsi citra suatu kelas yang berhasil dikenali oleh model, sehingga mencerminkan tingkat kesalahan negatif

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

palsu. F1-score merupakan rata-rata harmonik dari precision dan recall yang merangkum keduanya dalam satu nilai, sedangkan support menunjukkan jumlah citra validasi pada setiap kelas. Nilai 1,00 pada seluruh metrik berarti setiap citra validasi diklasifikasikan tepat sesuai label aslinya.

Rata-rata makro dan rata-rata tertimbang pada Tabel 5 juga bernilai 1,00. Kesamaan kedua nilai tersebut disebabkan oleh jumlah citra yang seimbang pada setiap kelas, yaitu 40 citra per kelas, sehingga tidak ada kelas yang mendominasi perhitungan rata-rata. Kondisi ini menunjukkan bahwa kinerja model merata pada ketiga tingkat kekeruhan dan tidak bias terhadap kelas tertentu.

Tabel 5. Laporan Klasifikasi pada Data Validasi (n = 120)

Kelas	*Precision*	*Recall*	*F1-Score*	*Support*
Jernih	1,00	1,00	1,00	40
Sedang	1,00	1,00	1,00	40
Keruh	1,00	1,00	1,00	40
Rata-rata makro	1,00	1,00	1,00	120
Rata-rata tertimbang	1,00	1,00	1,00	120
Akurasi	–	–	1,00	120

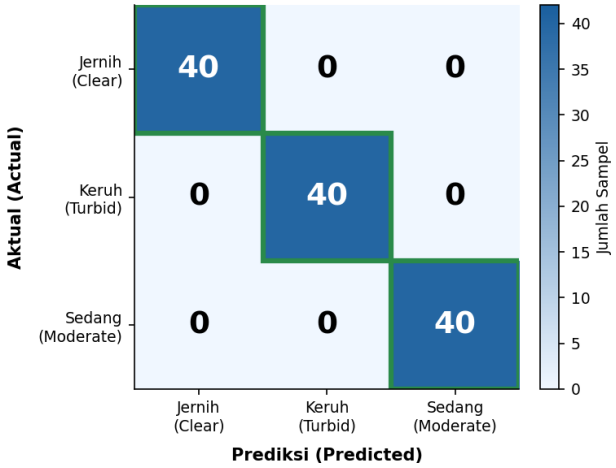

Gambar 5. *Confusion Matrix* Model EfficientNet-Lite0 pada Data Validasi (n = 120)

Pada confusion matrix, elemen diagonal menyatakan jumlah citra yang diprediksi sesuai label sebenarnya, sedangkan elemen di luar diagonal menyatakan jumlah kekeliruan antarkelas. Gambar 5 menunjukkan bahwa seluruh nilai berada pada diagonal utama, yaitu 40 citra untuk masing-masing kelas, dan seluruh elemen di luar diagonal bernilai nol. Dengan demikian, tidak terjadi kekeliruan antara kelas jernih dan sedang maupun antara kelas sedang dan keruh pada kondisi akuisisi yang terstandardisasi.

Kesempurnaan hasil tersebut perlu dimaknai secara proporsional. Akurasi 100% diperoleh pada 120 citra validasi yang diambil dalam kondisi pencahayaan, jarak kamera, dan latar belakang yang terkendali, dengan perbedaan visual antarkelas yang cukup kontras. Selain itu, sebagaimana dijelaskan pada subbab sebelumnya, data validasi juga digunakan sebagai dasar pemilihan bobot terbaik, sehingga nilai ini cenderung bersifat optimistis dan belum menggambarkan kinerja model pada data uji independen.

Dengan demikian, hasil pada Tabel 5 dan Gambar 5 sebaiknya dibaca sebagai bukti bahwa EfficientNet-Lite0 mampu memisahkan ketiga kelas kekeruhan secara konsisten pada kondisi akuisisi yang terstandardisasi, bukan sebagai jaminan kinerja pada kondisi lapangan yang bervariasi. Pengujian pada data uji independen serta pada variasi pencahayaan, jenis wadah, dan sumber air yang berbeda menjadi langkah lanjutan yang diperlukan untuk memverifikasi kemampuan generalisasi model.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

3.3. Kinerja *Real-Time* pada Raspberry Pi 4

Pengujian *real-time* dilakukan dengan menjalankan model TFLite pada Raspberry Pi 4 selama 10 menit untuk setiap kelas sampel. Gambar 6 memperlihatkan contoh tampilan antarmuka pemantauan pada Raspberry Pi 4 saat mendeteksi sampel kelas sedang.

Tabel 6. Kinerja Klasifikasi *Real-Time* pada Raspberry Pi 4

Sampel Air	Kelas Terdeteksi	Rata-rata Kepercayaan	Estimasi NTU	FPS	Stabilitas
Jernih	Jernih	0,97 ± 0,02	21	0,7	100%
Sedang	Sedang	0,91 ± 0,05	182	0,7	96%
Keruh	Keruh	0,94 ± 0,03	381	0,8	99%

Tabel 6 menunjukkan bahwa ketiga jenis sampel terklasifikasi sesuai kelasnya dengan rata-rata skor kepercayaan 0,97 ± 0,02 untuk jernih, 0,91 ± 0,05 untuk sedang, dan 0,94 ± 0,03 untuk keruh. *Throughput* berada pada 0,7–0,8 FPS atau sekitar satu pembaruan klasifikasi setiap 1,3 detik, dengan utilisasi CPU 35–40% selama operasi kontinu. Kelas sedang memiliki stabilitas terendah (96%) dan simpangan skor kepercayaan terbesar, sejalan dengan posisinya yang secara visual berada di antara kelas jernih dan keruh. Perbandingan metrik tersebut divisualisasikan pada Gambar 7. Angka 0,7–0,8 FPS tersebut, yang setara dengan satu pembaruan klasifikasi setiap sekitar 1,3–1,4 detik, merupakan throughput siklus penuh (akuisisi–praproses–inferensi–penyajian ke dashboard), bukan waktu inferensi model saja; utilisasi CPU 35–40% yang tercatat juga merupakan utilisasi keseluruhan proses selama operasi kontinu. Rincian waktu inferensi rata-rata, waktu pemrosesan total per tahap, penggunaan RAM, dan variasi latensi tidak disajikan karena pengujian dirancang untuk menilai kelayakan operasional sistem secara utuh, bukan membedah biaya komputasi per tahap, dan instrumentasi profiling tersebut menuntut pengujian ulang pada perangkat yang berada di luar cakupan revisi ini. Demikian pula perbandingan kinerja sebelum dan sesudah konversi ke TensorFlow Lite tidak dilakukan karena model Keras float32 tidak dijalankan pada Raspberry Pi 4 dalam penelitian ini; konversi dan kuantisasi dynamic-range diterapkan sejak awal sebagai prasyarat agar model dapat berjalan pada perangkat edge. Laju pembaruan sekitar 1,3–1,4 detik dinilai memadai untuk pemantauan kekeruhan air baku yang berubah secara lambat, sehingga keterbatasan pengukuran ini tidak mengubah kesimpulan mengenai kelayakan operasional sistem.

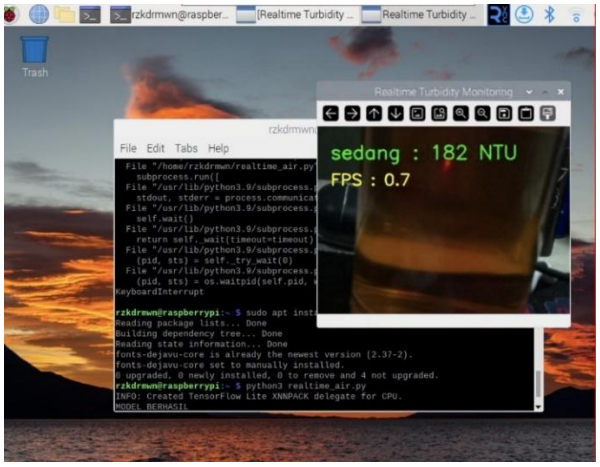

Gambar 6. Hasil Deteksi *Real-Time* Sampel Air Kelas Sedang pada Raspberry Pi 4

Gambar 6 menunjukkan bahwa sistem menampilkan label kelas "sedang" dengan estimasi 182 NTU dan laju 0,7 FPS pada jendela pemantauan, sementara terminal mengonfirmasi bahwa delegasi XNNPACK aktif untuk inferensi pada CPU. Tampilan ini membuktikan bahwa seluruh *pipeline*, mulai dari akuisisi citra hingga penyajian hasil, berjalan langsung pada perangkat *edge*.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

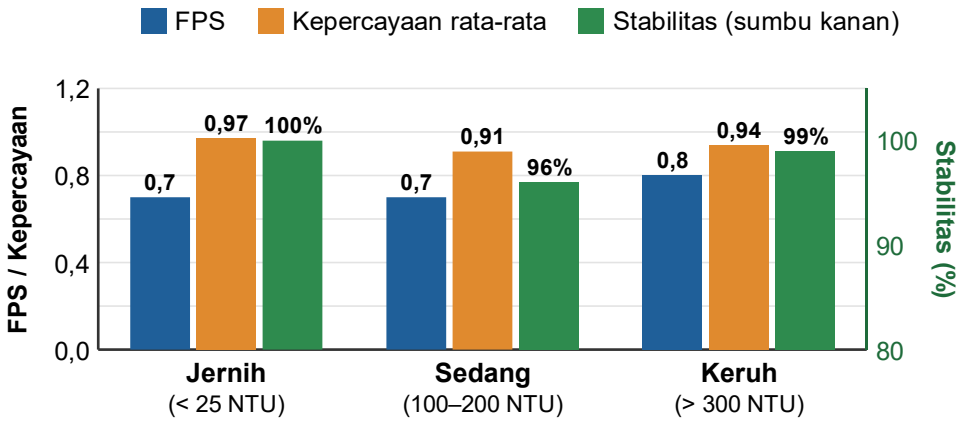

Gambar 7. Kinerja Inferensi *Real-Time* pada Raspberry Pi 4: FPS, Skor Kepercayaan, dan Stabilitas per Kelas

Gambar 7 memperlihatkan bahwa FPS relatif seragam antarkelas, sehingga beban komputasi tidak bergantung pada tingkat kekeruhan sampel. Variasi terutama tampak pada skor kepercayaan dan stabilitas yang menurun pada kelas sedang. Selama pengujian juga teramati bahwa perubahan hasil prediksi umumnya terjadi ketika intensitas pencahayaan berubah secara signifikan atau ketika posisi kamera terlalu jauh dari objek. Hasil klasifikasi juga dapat dipantau dari perangkat lain melalui *dashboard* web sebagaimana ditunjukkan pada Gambar 8.



Gambar 8. *Dashboard* Pemantauan Kualitas Air Baku Berbasis Web

Gambar 8 menunjukkan *dashboard* yang diakses melalui alamat IP Raspberry Pi pada port 5001. *Dashboard* menampilkan siaran langsung kamera, label kelas beserta indikator warna, estimasi NTU, nilai FPS, serta waktu pengamatan, sehingga operator dapat memantau kondisi air baku dari laptop maupun ponsel yang terhubung pada jaringan lokal yang sama.

3.4. Pembahasan

Akurasi validasi 100% dan *F1-score* 1,00 pada seluruh kelas menunjukkan bahwa pada kondisi akuisisi terkontrol, ketiga tingkat kekeruhan memiliki ciri visual yang cukup berbeda, terutama pada

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

warna, opasitas, dan transmisi cahaya melalui wadah sampel, sehingga dapat dipisahkan oleh fitur yang dipelajari EfficientNet-Lite0 melalui *transfer learning*. Temuan ini menjawab kesenjangan pertama pada bagian Pendahuluan, yaitu minimnya pemanfaatan citra RGB berbiaya rendah untuk klasifikasi kekeruhan. Meskipun demikian, nilai sempurna tersebut perlu ditafsirkan secara hati-hati karena 120 citra validasi berasal dari sesi akuisisi dan kondisi pencahayaan yang sama dengan data latih dan sekaligus digunakan untuk pemilihan model sehingga tidak berfungsi sebagai data uji independen, serta rentang NTU antarkelas sengaja dibuat berjarak lebar. Oleh karena itu, hasil ini lebih tepat dipandang sebagai bukti kelayakan (*proof of concept*) daripada estimasi kinerja pada kondisi lapangan. Penelitian ini tidak menyediakan data uji terpisah yang sepenuhnya tidak digunakan selama pelatihan maupun pemilihan model. Dataset yang tersedia hanya terdiri atas 600 citra dengan 120 citra validasi, sehingga memisahkan sebagian citra tersebut menjadi data uji akan menyisakan subset evaluasi yang terlalu kecil untuk memberikan estimasi kinerja per kelas yang stabil. Penyediaan data uji independen sebagaimana disarankan menuntut siklus akuisisi baru dengan sampel air baru, kondisi pencahayaan yang berbeda, dan sesi pengambilan yang terpisah, disertai verifikasi ulang nilai kekeruhan menggunakan turbidimeter acuan; kegiatan tersebut berada di luar cakupan revisi naskah ini. Konsekuensinya, klaim penelitian ini dibatasi pada kelayakan teknis sistem dalam kondisi akuisisi terkontrol, dan akurasi sempurna yang dilaporkan tidak diklaim sebagai ukuran kemampuan generalisasi. Pengujian dengan sampel baru lintas kondisi pencahayaan, karakteristik air, dan sesi pengambilan ditetapkan sebagai langkah wajib pada penelitian lanjutan sebelum sistem digunakan secara operasional. Terkait estimasi NTU, nilai 21, 182, dan 381 NTU yang ditampilkan sistem berasal dari pemetaan konstanta per kelas, sehingga keluarannya hanya memiliki tiga nilai diskret dan tidak bervariasi mengikuti kekeruhan aktual sampel. Perbandingan kuantitatif terhadap pembacaan turbidimeter HACH 2100N menggunakan MAE, RMSE, atau koefisien korelasi karena itu tidak disajikan: metrik tersebut hanya akan mengukur selisih antara tiga konstanta kelas dan nilai acuan, bukan kemampuan prediksi model, dan koefisien korelasi pada tiga nilai diskret tidak informatif secara statistik. Evaluasi metrologis yang bermakna menuntut model regresi NTU kontinu beserta data uji berpasangan citra–nilai turbidimeter pada rentang kekeruhan yang rapat, yang berada di luar cakupan penelitian ini dan telah ditetapkan sebagai agenda penelitian lanjutan.

Posisi penelitian ini terhadap studi terdahulu dirangkum pada Tabel 7. Studi [9] dan [10] mengandalkan data penginderaan jauh yang memerlukan sensor dan pemrosesan khusus, sedangkan studi [11] dan [12] masing-masing bekerja pada data sensor tabular dan klasifikasi kualitas air umum berbasis warna citra, tanpa fokus pada tingkat kekeruhan. Sistem IoT pada IPA yang dikembangkan Forhad et al. [20] menyediakan pemantauan *real-time*, tetapi bergantung pada sensor kontak dan tidak mencakup kekeruhan. Tikász et al. [21] menunjukkan bahwa model visi ringan dapat berjalan secara *real-time* pada perangkat berdaya rendah, dan penelitian ini memperluas prinsip tersebut ke klasifikasi tingkat kekeruhan air baku.

Tabel 7 menunjukkan bahwa penelitian ini menggabungkan masukan citra RGB berbiaya rendah, inferensi *real-time*, deployment pada perangkat *edge*, dan fokus eksplisit pada kekeruhan dalam satu sistem yang diuji pada konteks IPA air minum di Indonesia. Kombinasi atribut tersebut belum ditemukan pada studi pembanding yang dikaji. Dari sisi deployment, *throughput* 0,7–0,8 FPS jauh lebih rendah dibandingkan waktu inferensi 15,2 ms yang dilaporkan Elmessery et al. [17]. Perbedaan ini wajar karena model pada penelitian tersebut berupa jaringan *fully connected* berukuran kecil, sedangkan penelitian ini memproses citra 224×224 piksel melalui CNN sekaligus menanggung beban akuisisi kamera, *overlay*, dan *streaming* web pada CPU yang sama. Meskipun demikian, pembaruan klasifikasi sekitar setiap 1,3 detik tetap memadai untuk pemantauan kekeruhan air baku karena keputusan operasional, seperti penyesuaian dosis koagulan, tidak diambil pada skala sub-detik. Alqahtani et al. [19] mengevaluasi model *deep learning* pada Raspberry Pi dengan dan tanpa akselerator TPU, sehingga penggunaan akselerator semacam itu relevan untuk diuji apabila diperlukan laju inferensi yang lebih tinggi.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

Tabel 7. Perbandingan dengan Penelitian Terdahulu

Penelitian	Metode	Data Masukan	*Real-Time*	Perangkat *Edge*	Target
Zhao et al. [9]	Ensemble *machine learning*	Penginderaan jauh dekat permukaan	Tidak dilaporkan	Tidak	Parameter kualitas air
Safder et al. [11]	RNN multi-attention dan PLS	Data sensor IPAL	Ya	Tidak	Total nitrogen efluen
Vijay Anand et al. [12]	CNN	Parameter fisikokimia	Tidak dilaporkan	Tidak	Kualitas air
Forhad et al. [20]	Sensor IoT dan PLC	pH, DO, TDS, suhu	Ya	Tidak	Parameter non-kekeruhan
Tikász et al. [21]	YOLOv8	Video RGB	Ya	Ya	Makroplastik
Penelitian ini	EfficientNet-Lite0 (TFLite)	Citra RGB sampel air	Ya	Raspberry Pi 4	Tingkat kekeruhan

Secara praktis, sistem ini dapat berfungsi sebagai lapisan peringatan dini yang melengkapi, bukan menggantikan, turbidimeter terkalibrasi. Biaya perangkat keras sekitar Rp2.700.000 dan perawatan yang terbatas pada pembersihan lensa menjadikan sistem ini menarik bagi IPA dengan keterbatasan tenaga teknis instrumentasi, sekaligus menjawab hambatan biaya dan penggantian sensor yang dikemukakan Miller et al. [7]. Secara metodologis, penelitian ini menunjukkan bahwa *transfer learning* dua fase pada arsitektur ringan dapat menghasilkan model yang siap dijalankan pada CPU ARM tanpa akselerator tambahan.

3.5. Keterbatasan dan Penelitian Lanjutan

Penelitian ini memiliki beberapa keterbatasan. Pertama, *dataset* diperoleh dalam kondisi terkontrol, yaitu jarak kamera, wadah, dan pencahayaan yang tetap, dengan sampel air baku yang dipindahkan ke vial, sehingga belum merepresentasikan kondisi pemantauan langsung pada aliran air baku, seperti riak permukaan, cahaya alami, dan variasi musiman komposisi air baku. Kedua, klasifikasi tiga kelas dengan rentang NTU yang tidak bersinggungan belum mencakup nilai di antara kelas, misalnya 25–100 NTU dan 200–300 NTU, serta belum menyasar ambang regulasi air minum di bawah 3 NTU [1]. Ketiga, estimasi NTU berbasis sentroid kelas belum dikalibrasi secara metrologis terhadap turbidimeter acuan. Keempat, kelas sedang menunjukkan stabilitas terendah dan prediksi dapat berubah ketika intensitas cahaya berubah signifikan. Kelima, kinerja EfficientNet-Lite0 belum dibandingkan dengan arsitektur ringan lain maupun metode berbasis fitur warna sebagai baseline. Keenam, pembagian data latih dan validasi dilakukan secara acak terstratifikasi pada tingkat citra, sehingga citra dari sampel air dan sesi akuisisi yang sama dapat muncul pada kedua subset; karena identitas sampel dan sesi akuisisi tidak dicatat sebagai metadata dataset, pemisahan berbasis sampel belum dapat diterapkan secara retrospektif, sehingga angka akurasi yang dilaporkan berpotensi optimistis terhadap kemampuan generalisasi pada sampel baru. Ketujuh, penelitian ini tidak menggunakan data uji independen: data validasi sekaligus menjadi dasar pemilihan bobot terbaik melalui mekanisme checkpoint, sehingga akurasi 100% dan F1-score 1,00 yang dilaporkan merupakan kinerja validasi pada kondisi akuisisi terkontrol dan belum diuji pada sampel air baru maupun sesi pengambilan yang berbeda. Kedelapan, estimasi NTU yang ditampilkan sistem merupakan konstanta per kelas, bukan keluaran kuantitatif model, sehingga tidak dapat dibandingkan secara metrologis dengan turbidimeter acuan melalui MAE, RMSE, maupun koefisien korelasi. Kesembilan, pengukuran kinerja real-time hanya mencakup throughput siklus penuh dan utilisasi CPU; waktu inferensi per tahap, penggunaan RAM, sebaran latensi, serta perbandingan kinerja sebelum dan sesudah konversi ke TensorFlow Lite belum diukur. Penelitian lanjutan perlu (1) memperluas *dataset* lintas musim dan kondisi cuaca; (2) mengembangkan

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

model regresi NTU kontinu yang dikalibrasi terhadap turbidimeter acuan; (3) merancang sel pengukuran optis tertutup dengan iluminasi terkontrol; (4) menguji akselerator perangkat keras dan integrasi dengan sistem SCADA; serta (5) membandingkan EfficientNet-Lite0 dengan arsitektur ringan lain, seperti MobileNetV2, dan baseline berbasis fitur warna; (6) memperbanyak jumlah sampel air fisik dan sesi akuisisi agar evaluasi dapat dilakukan dengan skema pemisahan berbasis sampel dan sesi (group-wise split) maupun validasi silang antar-sesi; (7) menyiapkan data uji independen dari sampel air baru dengan variasi kondisi pencahayaan dan sesi akuisisi yang tidak digunakan selama pelatihan maupun pemilihan model; serta (8) melengkapi pengujian perangkat edge dengan profiling per tahap, yaitu waktu inferensi rata-rata, waktu pemrosesan total, penggunaan RAM, sebaran latensi, dan perbandingan kinerja model sebelum serta sesudah konversi TensorFlow Lite dengan kuantisasi dynamic-range.

4. KESIMPULAN

Penelitian ini merancang, melatih, dan mengimplementasikan sistem pemantauan kekeruhan air berbasis citra menggunakan EfficientNet-Lite0 pada Raspberry Pi 4. Terkait tujuan pertama, model hasil *transfer learning* dua fase mampu mengklasifikasikan tiga tingkat kekeruhan operasional dengan akurasi validasi 100% serta *precision*, *recall*, dan *F1-score 1,00* pada seluruh kelas; nilai tersebut merupakan kinerja pada data validasi yang juga digunakan untuk pemilihan model, sehingga belum dikonfirmasi pada data uji independen. Terkait tujuan kedua, model yang dikonversi ke format TFLite dengan kuantisasi *dynamic-range* dapat dijalankan secara stabil pada CPU Raspberry Pi 4 dengan laju 0,7–0,8 FPS tanpa ketergantungan pada komputasi awan. Terkait tujuan ketiga, *dashboard* berbasis Flask memungkinkan operator memantau label kelas, estimasi NTU, dan siaran kamera dari perangkat apa pun dalam jaringan lokal. Kontribusi utama penelitian ini adalah bukti kelayakan bahwa kamera RGB berbiaya rendah dan model *deep learning* ringan pada perangkat *edge* dapat menjadi alat pendukung pemantauan kekeruhan tanpa kontak di IPA air minum, sekaligus menyediakan *dataset* tiga kelas dan *pipeline* yang dapat direplikasi. Karena hasil diperoleh pada kondisi akuisisi terkontrol, sistem ini diposisikan sebagai pelengkap turbidimeter terkalibrasi, bukan penggantinya. Arah penelitian terpenting berikutnya adalah pengujian pada data uji independen dari sampel dan sesi akuisisi baru, diikuti validasi lapangan jangka panjang di Perumda Tirta Bhagasasi melalui akuisisi citra langsung pada aliran air baku serta pengembangan model regresi NTU kontinu yang dikalibrasi terhadap turbidimeter acuan.

PERNYATAAN KONTRIBUSI PENULIS (CREDIT)

Haryono: Konseptualisasi, metodologi, supervisi. **Muhammad Nur:** Penulisan – tinjauan dan penyuntingan. **Rizki Darmawan:** Pengumpulan data, analisis, validasi, visualisasi.

PERNYATAAN KONFLIK KEPENTINGAN

Para penulis menyatakan bahwa tidak terdapat kepentingan finansial atau hubungan pribadi yang diketahui yang dapat memengaruhi hasil penelitian yang dilaporkan dalam artikel ini.

PERNYATAAN PENDANAAN

Para penulis menyatakan bahwa tidak menerima dukungan finansial untuk penelitian dari pihak manapun. Seluruh biaya untuk penelitian, penulisan, dan publikasi sepenuhnya berasal dari penulis.

PERNYATAAN PENGGUNAAN AI GENERATIF DAN TEKNOLOGI BERBANTUAN AI DALAM PROSES PENULISAN

Selama penyusunan dan revisi naskah, penulis menggunakan Claude (Anthropic) untuk membantu penyuntingan bahasa, penyusunan draf revisi, dan pemeriksaan konsistensi naskah. Seluruh keluaran alat tersebut telah ditinjau, disunting, dan diverifikasi oleh penulis, dan penulis bertanggung jawab

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

penuh atas isi publikasi. Teknologi AI tidak digunakan untuk menghasilkan atau memanipulasi data, citra, maupun hasil penelitian.

REFERENCES

[1] K. K. Indonesia, *Peraturan Menteri Kesehatan Nomor 2 Tahun 2023 tentang Peraturan Pelaksanaan Peraturan Pemerintah Nomor 66 Tahun 2014 tentang Kesehatan Lingkungan*, Kementerian Kesehatan Republik Indonesia, Jakarta, 2023. Available: https://jdih.kemkes.go.id/documents/peraturan-menteri-kesehatan-nomor-2-tahun-2023

[2] L. Augustin and T. Baumann, "High-resolution monitoring of the Günz River: Assessing water quality risks for managed aquifer recharge," *Natural Hazards and Earth System Sciences*, vol. 25, no. 10, pp. 4003–4020, Oct. 2025 doi: 10.5194/nhess-25-4003-2025.

[3] J. Park, J. Ahn, J. Kim, Y. Yoon, and J. Park, "Prediction and Interpretation of Water Quality Recovery after a Disturbance in a Water Treatment System Using Artificial Intelligence," *Water (Basel).*, vol. 14, no. 15, p. 2423, Aug. 2022 doi: 10.3390/w14152423.

[4] J. Rocher, J. M. Jimenez, J. Tomas, and J. Lloret, "Low-Cost Turbidity Sensor to Determine Eutrophication in Water Bodies," *Sensors*, vol. 23, no. 8, p. 3913, Apr. 2023 doi: 10.3390/s23083913.

[5] G. M. e Silva, D. F. Campos, J. A. T. Brasil, M. Tremblay, E. M. Mendiondo, and F. Ghiglieno, "Advances in Technological Research for Online and In Situ Water Quality Monitoring—A Review," *Sustainability*, vol. 14, no. 9, p. 5059, Apr. 2022 doi: 10.3390/su14095059.

[6] Z. Czyczula Rudjord, M. J. Reid, C. U. Schwermer, and Y. Lin, "Laboratory Development of an AI System for the Real-Time Monitoring of Water Quality and Detection of Anomalies Arising from Chemical Contamination," *Water (Basel).*, vol. 14, no. 16, p. 2588, Aug. 2022 doi: 10.3390/w14162588.

[7] M. Miller, A. Kisiel, D. Cembrowska-Lech, I. Durlik, and T. Miller, "IoT in Water Quality Monitoring—Are We Really Here?," *Sensors*, vol. 23, no. 2, p. 960, Jan. 2023 doi: 10.3390/s23020960.

[8] M. À. Cugueró-Escofet and V. Puig, "Advances in the Monitoring, Diagnosis and Optimisation of Water Systems," *Sensors*, vol. 23, no. 6, p. 3256, Mar. 2023 doi: 10.3390/s23063256.

[9] Y. Zhao *et al.*, "Retrieval of Water Quality Parameters Based on Near-Surface Remote Sensing and Machine Learning Algorithm," *Remote Sens. (Basel).*, vol. 14, no. 21, p. 5305, Oct. 2022 doi: 10.3390/rs14215305.

[10] L. Yang, J. Driscol, S. Sarigai, Q. Wu, C. D. Lippitt, and M. Morgan, "Towards Synoptic Water Monitoring Systems: A Review of AI Methods for Automating Water Body Detection and Water Quality Monitoring Using Remote Sensing," *Sensors*, vol. 22, no. 6, p. 2416, Mar. 2022 doi: 10.3390/s22062416.

[11] U. Safder, J. Kim, G. Pak, G. Rhee, and K. You, "Investigating Machine Learning Applications for Effective Real-Time Water Quality Parameter Monitoring in Full-Scale Wastewater Treatment Plants," *Water (Basel).*, vol. 14, no. 19, p. 3147, Oct. 2022 doi: 10.3390/w14193147.

[12] M. Vijay Anand, C. Sohitha, G. N. Saraswathi, and G. Lavanya, "Water quality prediction using CNN," *J. Phys. Conf. Ser.*, vol. 2484, no. 1, p. 012051, May 2023 doi: 10.1088/1742-6596/2484/1/012051.

[13] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 33, no. 12, pp. 6999–7019, Dec. 2022 doi: 10.1109/TNNLS.2021.3084827.

[14] Y. Xu, T. M. Khan, Y. Song, and E. Meijering, "Edge deep learning in computer vision and medical diagnostics: a comprehensive survey," *Artif. Intell. Rev.*, vol. 58, no. 3, p. 93, Jan. 2025 doi: 10.1007/s10462-024-11033-5.

[15] K. M. Hosny, A. Magdi, A. Salah, O. El-Komy, and N. A. Lashin, "Internet of things applications using Raspberry-Pi: a survey," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 13, no. 1, p. 902, Feb. 2023 doi: 10.11591/ijece.v13i1.pp902-910.

[16] S. Wan, K. Zhao, Z. Lu, J. Li, T. Lu, and H. Wang, "A Modularized IoT Monitoring System with Edge-Computing for Aquaponics," *Sensors*, vol. 22, no. 23, p. 9260, Nov. 2022 doi: 10.3390/s22239260.

[17] W. M. Elmessery *et al.*, "Lightweight deep deterministic policy gradient for edge computing in recirculating aquaculture systems: real-time feeding control with reduced computational requirements," *Sci. Rep.*, vol. 15, no. 1, p. 37960, Oct. 2025 doi: 10.1038/s41598-025-21677-0.

[18] R. Del Prete *et al.*, "Optimizing deep learning models for on-orbit deployment through neural architecture search," *Sci. Rep.*, vol. 15, no. 1, p. 37783, Oct. 2025 doi: 10.1038/s41598-025-21467-8.

[19] D. K. Alqahtani, M. A. Cheema, and A. N. Toosi, "Benchmarking Deep Learning Models for Object Detection on Edge Computing Devices," in *Service-Oriented Computing. ICSOC 2024*, D. K. Alqahtani, M. A. Cheema, and A. N. Toosi, 2025, pp. 142–150. doi: 10.1007/978-981-96-0805-8_11.

[20] H. M. Forhad *et al.*, "IoT based real-time water quality monitoring system in water treatment plants (WTPs)," *Heliyon*, vol. 10, no. 23, p. e40746, Dec. 2024 doi: 10.1016/j.heliyon.2024.e40746.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/

Journal of Artificial Intelligence and Technology Information
Website : https://ejournal.techcart-press.com/index.php/jaiti
E-ISSN 2985-6396
P-ISSN 2985-5306
Volume 4, Number 4, December 2026
https://doi.org/10.58602/jaiti.v4i4.452
Page 919-934

[21] G. Tikász, M. Gyalai-Korpos, G. Fleit, and S. Baranya, "Real-time detection of macroplastic pollution in inland waters: development of a lightweight image recognition system," *Front. Environ. Sci.*, vol. 13, Oct. 2025 doi: 10.3389/fenvs.2025.1666271.

Copyright © 2026, The Author(s).
This is an open access article under the CC BY-SA license
https://creativecommons.org/licenses/by-sa/4.0/