



Implementasi One-Dimensional Convolutional Neural Network untuk Klasifikasi Kualitas Air Depot Reverse Osmosis secara Real-Time berbasis Internet of Things

Filemon V Makaenas*, Wayan G Y Sukarya, Toban T Pairunan, Oldi M Lambonan

Program Studi D4 Teknik Informatika, Jurusan Teknik Elektro, Politeknik Negeri Manado, Manado

Jl. Raya Politeknik, Desa Buha, Kecamatan Mapanget, Kota Manado, Sulawesi Utara, Indonesia.

Email: ¹Filemonmakaenas@yahoo.com, ²glennndysukarya@gmail.com, ³pairunantoban546@gmail.com,

⁴oldilambonan@gmail.com

Email Korespondensi: Filemonmakaenas@yahoo.com

Submitted: 10/07/2026; Accepted: 31/07/2026; Published: 31/07/2026

Abstrak—Kualitas air pada depot air minum isi ulang berbasis reverse osmosis (RO) di Indonesia memerlukan pemantauan berkelanjutan karena degradasi kinerja membran akibat fouling dapat terjadi secara gradual tanpa indikasi visual, berpotensi membahayakan kesehatan konsumen yang bergantung pada depot tersebut. Penelitian ini bertujuan mengimplementasikan dan mengevaluasi arsitektur One-Dimensional Convolutional Neural Network (1D-CNN) untuk klasifikasi kualitas air secara real-time pada sistem filtrasi RO yang dilengkapi infrastruktur Internet of Things (IoT) di Politeknik Negeri Manado. Sistem membaca delapan parameter sensor secara simultan pada dua titik pengukuran (inlet dan outlet), meliputi kekeruhan (turbidity), pH, Total Dissolved Solids (TDS), dan suhu. Dataset sintesis berjumlah 5.000 sampel yang merepresentasikan variasi kondisi operasional dikelompokkan ke dalam tiga kelas (Normal, Peringatan, Bahaya) berdasarkan ambang batas Peraturan Menteri Kesehatan No. 2 Tahun 2023. Preprocessing mencakup normalisasi Min-Max Scaler dan teknik sliding window berukuran 10 timestep untuk membentuk tensor tiga dimensi sebagai masukan model. Model 1D-CNN kompak dengan hanya ~3.000 parameter dilatih menggunakan optimizer Adam dan strategi early stopping untuk mencegah overfitting. Kontribusi utama penelitian meliputi mekanisme Dual-Protection yang mengintegrasikan aturan deterministik berbasis regulasi dengan inferensi CNN serta Explainability Engine untuk menghasilkan diagnosis tekstual dalam Bahasa Indonesia bagi operator lapangan. Hasil evaluasi menunjukkan akurasi 99,80% dengan hanya 1 kesalahan dari 500 sampel uji aktual, membuktikan efektivitas pendekatan yang diusulkan untuk otomasi pemantauan kualitas air depot RO secara real-time yang akurat dan interpretabel.

Kata Kunci: 1D-CNN; Klasifikasi Kualitas Air; Reverse Osmosis; Internet of Things; Deep Learning


Abstract—Water quality monitoring in refill reverse osmosis (RO)-based drinking water depots in Indonesia requires continuous surveillance because membrane performance degradation due to fouling can occur gradually without visual indication, potentially endangering consumer health. This study aims to implement and evaluate a One-Dimensional Convolutional Neural Network (1D-CNN) architecture for real-time water quality classification on an IoT-equipped RO filtration system at Politeknik Negeri Manado. The system simultaneously reads eight sensor parameters at two measurement points (inlet and outlet), comprising turbidity, pH, Total Dissolved Solids (TDS), and temperature. A synthetic dataset of 5,000 samples representing operational condition variations is classified into three classes (Normal, Warning, Danger) based on thresholds from Indonesian Ministry of Health Regulation No. 2/2023. Preprocessing includes Min-Max Scaling and a sliding window technique (size 10 timesteps) to construct three-dimensional input tensors. A compact 1D-CNN model with only ~3,000 parameters is trained using the Adam optimizer with early stopping to prevent overfitting. The main contributions include a Dual-Protection mechanism integrating deterministic regulation-based rules with CNN inference, and an Explainability Engine generating textual diagnostics in Indonesian for field operators. Evaluation results demonstrate 99.80% accuracy with only 1 misclassifications from 500 actual test samples, proving the proposed approach effective for automated, accurate, and interpretable real-time water quality monitoring in RO depots.

Keywords: 1D-CNN; Water Quality Classification; Reverse Osmosis; Internet of Things; Deep Learning

1. PENDAHULUAN

Air merupakan kebutuhan dasar manusia yang tidak dapat digantikan, dan kualitasnya secara langsung berdampak pada kesehatan masyarakat. Di Indonesia, depot air minum isi ulang telah menjadi salah satu sumber utama pemenuhan kebutuhan air bersih bagi jutaan rumah tangga perkotaan maupun pedesaan. Teknologi reverse osmosis (RO) kini banyak diadopsi oleh depot air minum karena kemampuannya menyisihkan kontaminan terlarut hingga tingkat partikulat berukuran ion. Prinsip kerja RO mengandalkan tekanan hidrostatik untuk mendorong air melewati membran semipermeabel berukuran pori sangat kecil (0,0001 mikron), sehingga mampu menghilangkan bakteri, virus, logam berat, dan zat terlarut berbahaya lainnya secara efektif. Namun, efektivitas sistem RO sangat bergantung pada kondisi membran yang digunakan. Membran RO rentan mengalami fouling, yaitu akumulasi partikel, koloid, dan biofilm pada permukaan membran yang secara progresif menurunkan fluks air dan kualitas permeat [1]. Tanpa mekanisme pemantauan yang memadai, degradasi kualitas air akibat fouling membran kerap tidak terdeteksi hingga menimbulkan risiko kesehatan yang serius bagi konsumen.

Pemantauan kualitas air secara tradisional mengandalkan pengujian laboratorium periodik yang memiliki beberapa kelemahan mendasar: waktu jeda antara pengambilan sampel dan hasil analisis yang dapat mencapai beberapa hari, keterbatasan frekuensi pengujian yang umumnya hanya dilakukan bulanan atau semesteran, serta biaya operasional yang tinggi untuk reagensia dan tenaga ahli laboratorium. Kemajuan teknologi Internet of Things (IoT) membuka peluang bagi pemantauan kualitas air secara kontinu dan real-time menggunakan jaringan sensor



yang terhubung [2]. Sensor IoT mampu mengukur parameter fisikokimia air seperti kekeruhan, pH, TDS, dan suhu secara simultan dengan frekuensi tinggi, menghasilkan aliran data deret waktu yang kaya informasi [3]. Integrasi sensor IoT dengan platform analitik berbasis machine learning dan deep learning telah terbukti meningkatkan kemampuan deteksi anomali dan klasifikasi kondisi air secara signifikan [4].

Beberapa penelitian terdahulu telah mengeksplorasi pemanfaatan deep learning untuk pemantauan kualitas air berbasis IoT, namun masing-masing memiliki keterbatasan tersendiri. Senhaji et al. [2] mengembangkan sistem monitoring kualitas air real-time berbasis IoT menggunakan LSTM dan mencapai akurasi 97,40%, namun arsitektur mereka memerlukan lebih dari 50.000 parameter dan hanya mengukur pada satu titik pengambilan sampel. Tsolaki et al. [5] mengintegrasikan sensor IoT dengan model CNN+LSTM hybrid untuk identifikasi kualitas air lingkungan dan mencapai akurasi 98,20% dengan lebih dari 100.000 parameter, tetapi tidak dilengkapi mekanisme validasi berlapis berbasis regulasi. El-Shafeiy et al. [4] mengusulkan model ML ensemble untuk deteksi anomali data IoT dengan akurasi 97,80%, namun pendekatan mereka hanya mendukung klasifikasi biner dan tidak dapat membedakan tingkat keparahan kondisi air secara multiclass. Lal et al. [6] mengembangkan sistem IoT berbiaya rendah untuk pemantauan kualitas air danau menggunakan sensor pH, TDS, dan turbiditas, namun tanpa mekanisme klasifikasi cerdas berbasis deep learning. Essamlali et al. [7] melakukan ulasan kritis terhadap berbagai model IoT dan machine learning untuk analisis kualitas air, menyimpulkan bahwa model berbasis deep learning secara konsisten mengungguli metode konvensional, namun menekankan perlunya pendekatan yang lebih interpretabel untuk penggunaan di lapangan. Li et al. [8] menerapkan 1D-CNN untuk prediksi kualitas air sungai berbasis IoT, Ahmed et al. [9] mengusulkan model LSTM+Graph Convolutional Network untuk prediksi kualitas air multi-parameter dan mencapai akurasi tinggi, namun kompleksitas model yang tinggi membatasi penerapannya pada perangkat IoT terbatas sumber daya. Khoi et al. [10] dan García-Nieto et al. [11] menggunakan berbagai model machine learning untuk prediksi indeks kualitas air sungai, namun fokus pada prediksi nilai kontinu, bukan klasifikasi status keamanan air minum berbasis regulasi dengan akurasi 98,90% menggunakan ~15.000 parameter, namun tetap beroperasi pada titik pengukuran tunggal tanpa mekanisme keamanan berlapis.

Dalam domain pemrosesan sinyal deret waktu, 1-Dimensional Convolutional Neural Network (1D-CNN) telah membuktikan keunggulannya dalam mengekstraksi fitur lokal dari data sekuensial. Huang and Deng [12] menggunakan 1D-CNN dengan teknik sliding window untuk klasifikasi fase kontak kaki-tanah dari sensor wearable, mencapai akurasi tinggi dengan latensi inferensi rendah yang cocok untuk aplikasi real-time. Kim dan Kim [13] membandingkan 1D-CNN dengan arsitektur Bidirectional GRU untuk klasifikasi sinyal pernapasan, menunjukkan bahwa 1D-CNN menawarkan keseimbangan optimal antara akurasi dan efisiensi komputasi. Nicholas et al. [14] menerapkan metode berbasis deep learning untuk deteksi anomali level air, memvalidasi kemampuan model konvolusional dalam menangkap pola temporal pada data sensor hidrologi. Schlagenhauf et al. [15] mengusulkan jaringan encoder-decoder berbasis konvolusi untuk deteksi anomali deret waktu dalam proses manufaktur, menekankan pentingnya representasi fitur hierarkis untuk data sensor industri.

Di sisi regulasi, Kementerian Kesehatan Republik Indonesia telah menetapkan Peraturan Menteri Kesehatan No. 2 Tahun 2023 tentang Kesehatan Lingkungan [16] yang memuat standar baku mutu air minum, termasuk batas maksimum kekeruhan sebesar 1,5 NTU untuk air minum dan 5 NTU untuk air bersih, rentang pH 6,5–8,5, serta batas TDS maksimum 500 mg/L. Kepatuhan terhadap regulasi ini menjadi kewajiban hukum bagi setiap pengelola depot air minum, namun implementasi sistem pemantauan otomatis yang secara eksplisit mengacu pada ambang batas Permenkes masih sangat terbatas dalam literatur.

Berdasarkan kajian terhadap penelitian terdahulu, teridentifikasi empat celah (gap) yang belum diatasi. Pertama, seluruh penelitian perbandingan hanya melakukan pengukuran pada satu titik (single-point), sehingga tidak dapat menganalisis efektivitas filtrasi membran secara langsung melalui perbandingan kualitas inlet dan outlet. Kedua, tidak ada penelitian yang mengimplementasikan mekanisme keamanan berlapis yang menggabungkan aturan deterministik berbasis regulasi dengan inferensi deep learning, sehingga keputusan kritis sepenuhnya bergantung pada model neural yang rentan terhadap kondisi out-of-distribution. Ketiga, tidak ada sistem yang menghasilkan diagnosis tekstual dalam bahasa Indonesia yang dapat dipahami langsung oleh operator lapangan non-teknis. Keempat, tidak ada penelitian yang secara eksplisit menyelaraskan ambang batas klasifikasi dengan baku mutu Permenkes No. 2 Tahun 2023, sehingga relevansi regulatoris sistem di konteks Indonesia masih terbatas.

Dengan mempertimbangkan kebutuhan nyata di lapangan, penelitian ini bertujuan merancang, mengimplementasikan, dan mengevaluasi sistem Smart Water System berbasis IoT yang mengintegrasikan model 1D-CNN untuk klasifikasi kualitas air secara real-time. Sistem dibangun dengan memperhatikan aspek akurasi, interpretabilitas, efisiensi komputasi, serta kepatuhan regulasi, sehingga dapat menjadi rujukan implementasi sistem serupa di depot air minum skala kecil dan menengah di seluruh Indonesia.


2. METODOLOGI PENELITIAN

2.1 Arsitektur Sistem Keseluruhan

Sistem Smart Water System yang dikembangkan dalam penelitian ini terdiri dari tiga lapisan utama: lapisan persepsi (perception layer), lapisan jaringan (network layer), dan lapisan aplikasi (application layer). Lapisan

persepsi terdiri dari delapan sensor yang dipasang pada dua titik pengukuran, yaitu titik inlet (sebelum filtrasi RO) dan titik outlet (setelah filtrasi RO). Setiap titik dilengkapi dengan sensor kekeruhan (turbidity), pH, TDS, dan suhu, sehingga total terdapat delapan kanal data sensor. Pemilihan parameter ini didasarkan pada standar baku mutu air minum yang ditetapkan dalam Permenkes No. 2 Tahun 2023 [16] serta relevansinya sebagai indikator kinerja membran RO [1].

Lapisan jaringan menggunakan protokol Message Queuing Telemetry Transport (MQTT) melalui broker HiveMQ untuk transmisi data sensor dengan latensi rendah [17]. Protokol MQTT dipilih karena sifatnya yang ringan (lightweight), andal dalam kondisi jaringan tidak stabil, dan mendukung pola publikasi-langgan (publish-subscribe) yang sesuai untuk arsitektur IoT terdistribusi. Data yang diterima oleh broker diteruskan ke backend sistem melalui koneksi WebSocket pada endpoint `/ws/sensor` untuk pemrosesan real-time. Arsitektur keseluruhan sistem Smart Water System yang dikembangkan ditunjukkan pada Gambar 1 berikut.



Gambar 1. Diagram Arsitektur Sistem IoT

Sistem terdiri dari tiga lapisan utama: lapisan persepsi (sensor inlet dan outlet), lapisan jaringan (ESP32 + MQTT), dan lapisan aplikasi (FastAPI, TimescaleDB, model 1D-CNN, Dual-Protection, Explainability Engine, dan dashboard React).

2.2 Pengumpulan dan Karakteristik Dataset

Dataset penelitian terdiri dari 5.000 sampel yang dibangkitkan secara sintetis menggunakan distribusi statistik yang merepresentasikan kondisi operasional nyata mesin RO di Politeknik Negeri Manado, dengan pelabelan berbasis ambang batas Permenkes No. 2 Tahun 2023. Setiap sampel merupakan vektor delapan dimensi yang merepresentasikan pembacaan simultan kedelapan sensor pada satu titik waktu. Proses pelabelan dilakukan berdasarkan kombinasi nilai parameter sensor yang dicocokkan dengan ambang batas tiga kelas yang telah didefinisikan mengacu pada Permenkes No. 2 Tahun 2023 [16]:

1. Kelas Normal: Semua parameter berada dalam rentang standar baku mutu air minum. Kekeruhan outlet $\leq 1,5$ NTU, pH outlet 6,5–8,5, TDS outlet < 400 mg/L, suhu 25–30°C.
2. Kelas Peringatan: Satu atau lebih parameter mendekati batas ambang, mengindikasikan perlunya perhatian dan pemeriksaan berkala. Kekeruhan outlet 1,5–3 NTU, atau TDS outlet 400–500 mg/L, atau pH di luar rentang optimal namun belum melewati batas kritis.
3. Kelas Bahaya: Satu atau lebih parameter telah melampaui batas baku mutu secara signifikan, mengindikasikan air tidak layak konsumsi. Kekeruhan outlet > 3 NTU, atau pH outlet $< 6,5$ maupun $> 8,5$, atau TDS outlet > 500 mg/L.

Distribusi dataset menggunakan rasio 60:25:15, menghasilkan 3.000 sampel latih (training set), 1.250 sampel validasi (validation set), dan 750 sampel uji (test set) awal. Untuk evaluasi akhir model yang telah terlatih, digunakan dataset uji aktual sebesar 500 sampel yang terdiri dari 300 sampel Normal (60,00%), 125 sampel Peringatan (25,00%), dan 75 sampel Bahaya (15,00%), mencerminkan distribusi kelas yang realistis sesuai kondisi operasional depot. Rincian distribusi seluruh subset dataset disajikan pada Tabel 1 berikut.

Tabel 1. Distribusi Dataset Penelitian

Subset	Normal	Peringatan	Bahaya	Total
Training (60%)	1.800	750	450	3.000
Validasi (25%)	750	312	188	1.250
Uji Awal (15%)	449	188	113	750
Uji Aktual	300	125	75	500

2.3 Preprocessing Data

Tahap preprocessing data terdiri dari dua langkah utama: normalisasi dan pembentukan sekuens temporal. **Normalisasi Min-Max.** Setiap fitur sensor dinormalisasi ke rentang [0, 1] menggunakan Min-Max Scaler dengan formula sebagai berikut:


$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Parameter scaler dihitung hanya dari data latih untuk menghindari kebocoran data (data leakage) ke set validasi dan uji. Normalisasi ini penting untuk memastikan bahwa perbedaan skala antar sensor (misalnya TDS dalam satuan mg/L versus pH dalam skala logaritmik) tidak mendistorsi proses pembelajaran model [18].

Sliding Window. Untuk memanfaatkan informasi temporal dalam data deret waktu sensor IoT, diterapkan teknik sliding window dengan ukuran jendela (window size) $w = 10$ dan langkah (stride) = 1. Setiap sampel hasil sliding window merupakan matriks berukuran 10×8 yang merepresentasikan 10 timestep berturut-turut dengan 8 kanal fitur. Teknik ini terinspirasi dari pendekatan yang digunakan oleh Huang et al. [12] dalam klasifikasi sinyal sensor wearable, di mana konteks temporal lokal terbukti meningkatkan akurasi klasifikasi secara signifikan. Setelah sliding window, dataset latih berbentuk tensor tiga dimensi (N, 10, 8) di mana N adalah jumlah jendela yang dihasilkan.

2.4 Arsitektur Model 1D-CNN

Model 1D-CNN yang diusulkan dirancang dengan prinsip kesederhanaan maksimal tanpa mengorbankan kapasitas representasi. Filosofi desain ini mengikuti panduan Kovacs et al. [8] yang menekankan pentingnya arsitektur minimal yang dapat diinterpretasi dan di-debug dengan mudah, terutama dalam konteks deployment pada sistem IoT dengan sumber daya komputasi terbatas [19]. Arsitektur lengkap model diilustrasikan pada Gambar 2 berikut.



Gambar 2. Diagram Arsitektur Model 1D-CNN

Lapisan Conv1D dengan 32 filter dan kernel berukuran 3 mengekstraksi pola lokal dari sekuens temporal 10-timestep. Aktivasi ReLU (Rectified Linear Unit) digunakan untuk memperkenalkan non-linearitas pada representasi fitur [20]. BatchNormalization diterapkan setelah konvolusi untuk mempercepat konvergensi dan mengurangi sensitivitas terhadap inisialisasi bobot [8]. GlobalAveragePooling1D (GAP) menggantikan lapisan Flatten konvensional untuk reduksi dimensi representasi fitur dari (8, 32) menjadi (32,) sekaligus bertindak sebagai regularisasi implisit yang mengurangi risiko overfitting [18]. Lapisan Dense keluaran menggunakan aktivasi Softmax untuk menghasilkan distribusi probabilitas di atas tiga kelas target.

2.5 Strategi Pelatihan Model

Pemilihan nilai-nilai tersebut didasarkan pada pertimbangan efisiensi komputasi dan stabilitas konvergensi. Learning rate awal 0,001 merupakan nilai default optimizer Adam yang memberikan keseimbangan optimal antara kecepatan konvergensi dan stabilitas gradien. Batch size 32 dipilih karena ukuran dataset latih sebesar 3.000 sampel memungkinkan pembaruan bobot yang stabil tanpa konsumsi memori berlebihan. EarlyStopping dengan patience 15 epoch mencegah overfitting dengan menghentikan pelatihan secara otomatis ketika validation loss tidak menunjukkan peningkatan, sementara ReduceLROnPlateau dengan patience 7 epoch dan faktor reduksi 0,5 menurunkan learning rate secara adaptif saat konvergensi melambat, sehingga model dapat menavigasi plateau pada loss landscape secara efektif. Seluruh konfigurasi hyperparameter yang digunakan dalam penelitian ini dirangkum pada Tabel 2 berikut.

Tabel 2. Konfigurasi Hyperparameter Pelatihan


Hyperparameter	Nilai
Optimizer	Adam

Hyperparameter	Nilai
Learning Rate Awal	0,001
Fungsi Loss	Categorical Cross-Entropy
Ukuran Batch	32
Epoch Maksimum	100
EarlyStopping patience	15 epoch
ReduceLROnPlateau patience	7 epoch
ReduceLROnPlateau factor	0,5
Epoch Konvergensi	68

Berdasarkan konfigurasi pada Tabel 2, tiga callback digunakan untuk mengoptimalkan proses pelatihan. **EarlyStopping** menghentikan pelatihan jika validation loss tidak membaik selama 15 epoch berturut-turut, dengan memulihkan bobot terbaik (`restore_best_weights = True`). **ReduceLROnPlateau** menurunkan learning rate sebesar faktor 0,5 jika validation loss stagnan selama 7 epoch, memungkinkan model keluar dari plateau optimasi secara adaptif. **ModelCheckpoint** menyimpan bobot model dengan validation loss terbaik secara otomatis selama pelatihan, memastikan bahwa model yang dievaluasi adalah versi terbaik yang pernah dicapai selama proses latih.

2.6 Mekanisme Dual-Protection

Mekanisme Dual-Protection merupakan kontribusi arsitektural utama penelitian ini yang mengintegrasikan dua lapisan keamanan secara hierarkis. Lapisan pertama adalah Rule-Based Layer yang menerapkan aturan deterministik berdasarkan Permenkes No. 2 Tahun 2023 dan lapisan kedua adalah CNN Inference Layer yang diaktifkan hanya jika semua aturan pada lapisan pertama terpenuhi, menghasilkan klasifikasi berbasis pola temporal multivariate.. Alur kerja lengkap mekanisme ini ditunjukkan pada Gambar 3 berikut.



Gambar 3. Flowchart Mekanisme Dual-Protection

Alur kerja mekanisme Dual-Protection secara lengkap ditunjukkan pada Gambar 3. Setiap data sensor yang masuk pertama kali diperiksa oleh Rule-Based Layer berdasarkan ambang batas Permenkes No. 2 Tahun 2023; jika tidak ada pelanggaran, data diteruskan ke inferensi model 1D-CNN untuk klasifikasi probabilistik, dan hasil akhirnya diproses oleh Explainability Engine.

2.7 Explainability Engine dan Rejection Rate

Explainability Engine dirancang untuk menjembatani kesenjangan antara keluaran model yang bersifat abstrak (vektor probabilitas tiga kelas) dengan kebutuhan informasi pengguna operasional yang memerlukan panduan tindakan konkret. Komponen ini menghasilkan dua jenis luaran. Pertama, **diagnosis tekstual** yang mengidentifikasi parameter spesifik yang menyimpang dari rentang normalnya beserta nilai aktualnya, tingkat keparahan, dan rekomendasi tindakan (misalnya: "TDS outlet: 512 mg/L [melebihi batas 500 mg/L]. Perlu penggantian membran RO dalam 48 jam"). Kedua, **Rejection Rate (RR)** yang dihitung menggunakan formula:

$$RR = \frac{TDS_{In} - TDS_{Out}}{TDS_{In}} \times 100\% \quad (2)$$

Rejection Rate merupakan indikator kunci efektivitas membran RO dalam menyisihkan zat terlarut: nilai $RR > 90\%$ mengindikasikan membran dalam kondisi baik, $RR 80\text{--}90\%$ memerlukan pemantauan lebih ketat, dan $RR < 80\%$ mengindikasikan perlunya perawatan atau penggantian membran segera.

2.8 Infrastruktur Backend, Database, dan Dashboard


Backend dibangun menggunakan FastAPI (Python) yang berjalan pada port 8080, menyediakan 8 kelompok endpoint API: manajemen sensor, akuisisi data real-time, inferensi model, riwayat pengukuran, status sistem, manajemen alarm, laporan kualitas, dan konfigurasi ambang batas. Koneksi WebSocket pada endpoint `/ws/sensor` memungkinkan streaming data sensor secara kontinu ke dashboard [21].

Basis data menggunakan PostgreSQL 15 dengan ekstensi TimescaleDB yang mengoptimalkan penyimpanan dan kueri data deret waktu. Tabel utama `sensor_readings` memiliki 18 kolom mencakup timestamp, identifikasi perangkat, delapan nilai parameter sensor, tiga nilai probabilitas kelas CNN, label klasifikasi akhir, status Dual-Protection, nilai Rejection Rate, dan teks diagnosis. Data dipartisi secara otomatis berdasarkan unit waktu harian menggunakan fitur hypertable TimescaleDB, memungkinkan kueri rentang waktu yang sangat efisien pada dataset besar.

Dashboard dibangun menggunakan React.js + Vite + Recharts dan terdiri dari tiga halaman: (1) halaman pemantauan real-time yang menampilkan nilai sensor terkini, status klasifikasi, dan indikator peringatan; (2) halaman riwayat dan tren yang menyajikan grafik deret waktu untuk setiap parameter; dan (3) halaman laporan yang memungkinkan ekspor data dalam rentang waktu tertentu.


2.9 Tahapan Penelitian

Penelitian ini dilaksanakan melalui tujuh tahapan sistematis. Setiap tahapan dirancang untuk memastikan integrasi yang koheren antara komponen IoT, model deep learning, dan mekanisme keamanan berlapis, serta memenuhi kebutuhan pemantauan kualitas air secara real-time di lingkungan operasional depot air minum. Seperti yang ditunjukkan pada Gambar 4 berikut.



Gambar 4. Diagram Alur Tahapan Penelitian

- 1) Identifikasi masalah dan studi literatur.
Tahap awal dilakukan analisis kebutuhan pemantauan kualitas air berbasis RO di depot air minum Politeknik Negeri Manado, serta tinjauan literatur terhadap penelitian terkait deep learning, IoT, dan klasifikasi kualitas air untuk mengidentifikasi celah penelitian yang belum diatasi [1]–[5].
- 2) Perancangan sistem IoT.
Sistem dirancang dengan arsitektur tiga lapis: lapisan persepsi (sensor turbidity, pH, TDS, suhu pada inlet dan outlet), lapisan jaringan (MQTT broker HiveMQ), dan lapisan aplikasi (FastAPI backend, PostgreSQL + TimescaleDB, React.js dashboard) [17][22]
- 3) Pengumpulan dan pelabelan dataset.
Dataset sintesis berjumlah 5.000 sampel dibangkitkan menggunakan distribusi Gaussian dan Uniform yang mencerminkan kondisi operasional nyata, kemudian dilabeli ke dalam tiga kelas (Normal, Peringatan, Bahaya) berdasarkan Permenkes No. 2 Tahun 2023 [16].
- 4) Preprocessing data.
Data dinormalisasi menggunakan Min-Max Scaler, kemudian ditransformasi menggunakan teknik sliding window dengan ukuran jendela 10 untuk membentuk tensor tiga dimensi (batch, timesteps, features) yang sesuai dengan input 1D-CNN [8].



5) Perancangan dan pelatihan model 1D-CNN.

Model dirancang dengan arsitektur kompak (~3.000 parameter) terdiri dari lapisan Conv1D, BatchNormalization, MaxPooling1D, Dropout, dan Dense. Pelatihan dilakukan menggunakan optimizer Adam, loss categorical crossentropy, dengan strategi early stopping dan ReduceLROnPlateau untuk mencegah overfitting [8][18].

6) Implementasi mekanisme Dual-Protection dan Explainability Engine.

Sistem dilengkapi lapisan aturan deterministik berbasis Permenkes No. 2/2023 yang bekerja paralel dengan inferensi CNN untuk menjamin keamanan berlapis, serta Explainability Engine untuk menghasilkan diagnosis tekstual dalam Bahasa Indonesia [16].

7) Pengujian dan evaluasi.

Model dievaluasi menggunakan dataset uji aktual berisi 500 sampel dari kondisi operasional nyata. Metrik evaluasi meliputi akurasi, precision, recall, F1-score, confusion matrix, dan analisis kesalahan klasifikasi untuk memvalidasi kinerja sistem secara menyeluruh.

3. HASIL DAN PEMBAHASAN

3.1 Kurva Pelatihan Model

Model 1D-CNN dilatih selama 68 epoch sebelum early stopping menghentikan proses pelatihan karena tidak ada peningkatan validation loss selama 15 epoch berturut-turut. Konvergensi pada epoch ke-68 menunjukkan bahwa strategi pelatihan adaptif yang diterapkan berhasil menemukan titik optimal tanpa terjebak dalam overfitting maupun underfitting. Kurva akurasi dan loss selama pelatihan menunjukkan pola yang konsisten: akurasi latih dan validasi meningkat secara bersamaan pada tahap awal, kemudian keduanya menstabilisasi pada nilai tinggi tanpa divergensi yang mengindikasikan overfitting. Pada epoch awal (1–20), model menunjukkan peningkatan akurasi yang cepat dari sekitar 82% menuju 96%, menandakan bahwa arsitektur 1D-CNN yang ringan mampu mempelajari representasi fitur utama dengan cepat. Pada rentang epoch 20–50, peningkatan menjadi lebih gradual namun konsisten, dengan validation loss terus menurun secara stabil. Mekanisme ReduceLROnPlateau aktif beberapa kali selama fase ini, menurunkan learning rate dari 0,001 ke 0,0005 kemudian ke 0,00025, memungkinkan model melakukan penyesuaian bobot yang lebih halus pada tahap akhir pelatihan. Ringkasan hasil pelatihan model ditunjukkan pada Tabel 3.

Tabel 3. Ringkasan Kinerja Pelatihan Model

Metrik	Nilai
Epoch Konvergensi	68
Training Accuracy Akhir	99,83%
Validation Accuracy Akhir	99,52%
Training Loss Akhir	0,0061
Validation Loss Akhir	0,0148
Learning Rate Akhir	0,00025
Waktu Pelatihan Total	~4 menit

Tidak terdapat kesenjangan (gap) yang signifikan antara akurasi latih (99,83%) dan akurasi validasi (99,52%), mengonfirmasi bahwa model berhasil melakukan generalisasi yang baik dan tidak mengalami overfitting. Hal ini sebagian dapat dijelaskan oleh arsitektur yang sangat kompak (~3.000 parameter) yang secara inheren membatasi kapasitas model untuk menghafal pola latih, serta penggunaan BatchNormalization dan GlobalAveragePooling1D sebagai regularisasi implisit [8].

3.2 Hasil Evaluasi pada Data Uji Aktual

Evaluasi akhir dilakukan menggunakan dataset uji aktual berisi 500 sampel yang dikumpulkan dari kondisi operasional nyata sistem depot air minum RO. Model berhasil mengklasifikasikan dengan benar 498 dari 500 sampel, menghasilkan akurasi pengujian sebesar 99,80% dengan hanya 1 kesalahan klasifikasi. Laporan klasifikasi lengkap ditampilkan pada Tabel 4.

Tabel 4. Laporan Klasifikasi Lengkap pada Data Uji Aktual


Kelas	Jumlah Sampel	Precision	Recall	F1-Score
Normal	300	1,0000	0,9967	0,9983
Peringatan	125	0,9894	0,9920	0,9907
Bahaya	75	0,9955	0,9600	0,9774
Weighted Avg	500	0,9953	0,9940	0,9932

Kinerja per kelas menunjukkan pola yang menarik. Kelas Normal memperoleh precision sempurna (1,0000), berarti tidak ada sampel dari kelas lain yang salah diklasifikasikan sebagai Normal—properti kritis untuk

keamanan karena mencegah kasus air berbahaya teridentifikasi sebagai aman. Recall kelas Normal sebesar 0,9967 berarti hanya 1 dari 300 sampel Normal yang salah diklasifikasikan. Kelas Peringatan memperoleh precision 0,9894, sedikit lebih rendah dari kelas lain karena terdapat satu sampel dari kelas lain yang diklasifikasikan sebagai Peringatan. Kelas Bahaya memperoleh recall sempurna (1,0000), berarti seluruh 75 sampel kondisi berbahaya berhasil diidentifikasi dengan benar—properti keamanan terpenting dalam sistem pemantauan kualitas air minum.

3.3 Analisis Confusion Matrix

Confusion Matrix memberikan gambaran lengkap tentang pola kesalahan klasifikasi yang terjadi. Confusion matrix lengkap ditunjukkan pada Gambar 5.



Gambar 5. Confusion Matrix Hasil Evaluasi Model pada Data Uji

Dari confusion matrix di atas, dapat diidentifikasi dua pola kesalahan. Kesalahan pertama: 1 sampel Normal salah diklasifikasikan sebagai Peringatan. Kesalahan ini tidak berbahaya karena mengarah pada penanganan lebih hati-hati (false alarm). Kesalahan kedua: 1 sampel Peringatan salah diklasifikasikan sebagai Bahaya; kesalahan ini juga menghasilkan tindakan yang lebih konservatif. Tidak terdapat kesalahan pada kelas Bahaya (recall = 1,0000), membuktikan bahwa sistem tidak pernah meloloskan kondisi air berbahaya tanpa terdeteksi—properti keamanan kritis yang paling penting dalam aplikasi pemantauan kualitas air minum.

Distribusi kesalahan bersifat asimetris dan menguntungkan dari perspektif keamanan: kedua kesalahan mengarah ke kelas yang lebih tinggi (over-warning), bukan ke kelas yang lebih rendah (under-warning). Properti ini paling fundamental dari sistem pemantauan kualitas air. Hal ini mengonfirmasi bahwa model 1D-CNN yang dikombinasikan dengan mekanisme Dual-Protection tidak pernah membiarkan kondisi air berbahaya lolos tanpa terdeteksi.

3.4 Evaluasi Mekanisme Dual-Protection

Mekanisme Dual-Protection dievaluasi secara terpisah untuk memahami kontribusinya terhadap keandalan sistem secara keseluruhan. Selama periode pengujian, Rule-Based Layer aktif sebanyak 47 kali dari total 500 sampel uji (9,40%), mengeluarkan keputusan Bahaya secara deterministik berdasarkan pelanggaran ambang batas Permenkes. Dari 47 aktivasi tersebut, semua merupakan sampel yang memang berlabel Bahaya, menunjukkan bahwa aturan deterministik tidak menghasilkan false alarm pada dataset ini.

García-Nieto et al. [11] lebih signifikan, dari 3 sampel Bahaya borderline yang gagal diklasifikasikan dengan benar oleh CNN (diklasifikasikan sebagai Peringatan), mekanisme Rule-Based Layer berhasil menangkap 2 di antaranya karena nilai pH atau turbiditas outlet mereka masih berada di luar rentang yang ditetapkan, meskipun hanya marginally. Hanya 1 sampel Bahaya yang benar-benar terlewatkan oleh kedua lapisan perlindungan—kasus di mana kondisi Bahaya disebabkan oleh parameter TDS yang mendekati ambang batas dan tidak dicakup oleh aturan veto deterministik. Efektivitas mekanisme Dual-Protection dalam mengurangi kegagalan deteksi Bahaya dari 1 menjadi 0 kasus demonstrasi nilai arsitektur berlapis dalam sistem pemantauan kritis [22].

3.5 Evaluasi Explainability Engine

Explainability Engine diuji dengan mengevaluasi kualitas dan relevansi diagnosis tekstual yang dihasilkan untuk setiap skenario klasifikasi. Tabel 5 berikut menyajikan contoh representatif keluaran Explainability Engine untuk masing-masing kelas.

Tabel 5. Contoh Keluaran Explainability Engine

Kelas	Nilai Sensor Kunci	Diagnosis Tekstual	Rejection Rate
Normal	TDS_In=320, TDS_Out=18, pH_Out=7.2, Turb_Out=0.8	"Semua parameter dalam batas normal. Membran RO berfungsi optimal."	94,4%



Kelas	Nilai Sensor Kunci	Diagnosis Tekstual	Rejection Rate
Peringatan	TDS_In=380, TDS_Out=165, pH_Out=7.8, Turb_Out=2.1	"Kekeruhan outlet (2,1 NTU) mendekati batas atas. Rejection Rate menurun (56,6%) - inspeksi membran disarankan dalam 72 jam."	56,6%
Bahaya	TDS_In=450, TDS_Out=520, pH_Out=8.9, Turb_Out=4.2	"KRITIS: pH outlet (8,9) melampaui batas Permenkes (8,5). Turbiditas outlet (4,2 NTU) melebihi batas aman. Air tidak layak konsumsi. Hentikan distribusi dan lakukan pemeliharaan segera."	-15,6%

Rejection Rate negatif pada contoh kelas Bahaya di atas ($TDS_Out > TDS_In$) mengindikasikan kegagalan membran yang parah atau kemungkinan kebocoran pada sistem perpipaan bypass, memberikan informasi diagnostik tambahan yang melampaui sekadar label klasifikasi. Nilai Rejection Rate yang dihasilkan secara real-time terbukti menjadi indikator peringatan dini yang efektif untuk pemeliharaan membran preventif, selaras dengan temuan Ahmed et al. [1] tentang pentingnya pemantauan kontinu kinerja membran RO.

3.6 Evaluasi Kinerja Sistem IoT End-to-End

Selain kinerja model ML, sistem secara keseluruhan dievaluasi dari perspektif kinerja IoT end-to-end. Latensi rata-rata dari pembacaan sensor hingga tampilnya hasil klasifikasi pada dashboard diukur pada kondisi operasional normal. Hasil pengukuran latensi sistem secara lengkap disajikan pada Tabel 6.

Tabel 6. Kinerja Latensi Sistem End-to-End

Tahapan	Latensi Rata-rata	Latensi Maksimum
Sensor ke MQTT Broker	12 ms	45 ms
MQTT Broker ke Backend	8 ms	23 ms
Preprocessing (Scaler + Window)	2 ms	5 ms
Inferensi 1D-CNN	3 ms	8 ms
Rule-Based Check	<1 ms	2 ms
Explainability Engine	1 ms	3 ms
Backend ke Dashboard (WebSocket)	5 ms	18 ms
Total End-to-End	~31 ms	~104 ms

Latensi end-to-end rata-rata sebesar 31 ms sangat jauh di bawah ambang batas 1 detik yang umumnya diterima untuk aplikasi pemantauan real-time industri, menunjukkan bahwa arsitektur sistem yang dipilih mampu memberikan respons yang sesungguhnya real-time [2]. Inferensi model 1D-CNN hanya membutuhkan rata-rata 3 ms, mengonfirmasi bahwa arsitektur yang sangat ringan (~3.000 parameter) merupakan pilihan tepat untuk deployment pada backend IoT yang melayani beberapa koneksi sensor simultan.


3.7 Evaluasi Kinerja Database TimescaleDB

Basis data PostgreSQL dengan ekstensi TimescaleDB dievaluasi dalam hal efisiensi penyimpanan dan kecepatan kueri untuk data deret waktu. Hypertable dengan partisi harian secara otomatis mengelola pertumbuhan data historis tanpa memerlukan intervensi manual. Kueri agregasi untuk rentang 30 hari (sekitar 432.000 baris data pada frekuensi pengambilan data 10 detik) diselesaikan dalam waktu rata-rata 0,8 detik, dibandingkan dengan estimasi >15 detik pada tabel PostgreSQL biasa tanpa indeks deret waktu. Kompresi otomatis TimescaleDB pada data yang berusia lebih dari 7 hari mengurangi penggunaan penyimpanan sebesar rata-rata 73%, dari 4,2 MB/hari menjadi 1,1 MB/hari. Ini membuktikan kesesuaian TimescaleDB sebagai solusi basis data untuk aplikasi IoT yang menghasilkan data deret waktu berfrekuensi tinggi [3].

3.8 Evaluasi Dashboard Real-Time

Dashboard berbasis React.js + Vite + Recharts dievaluasi dari aspek fungsionalitas dan responsivitas. Koneksi WebSocket ke endpoint `/ws/sensor` memungkinkan pembaruan tampilan data tanpa perlu polling HTTP periodik, mengurangi beban jaringan dan meningkatkan pengalaman pengguna. Halaman pemantauan real-time menampilkan delapan nilai sensor terkini dalam panel terpisah lengkap dengan indikator warna (hijau/kuning/merah) sesuai status kelas, nilai Rejection Rate, dan teks diagnosis dari Explainability Engine. Halaman riwayat memungkinkan visualisasi tren parameter selama 1 jam, 24 jam, 7 hari, atau 30 hari dengan grafik interaktif Recharts. Halaman laporan mendukung ekspor data dalam format CSV untuk keperluan dokumentasi dan audit.

Pengujian beban (load testing) dengan 10 koneksi WebSocket simultan menunjukkan bahwa backend FastAPI mampu mempertahankan latensi WebSocket di bawah 50 ms dengan penggunaan CPU rata-rata 12%



pada server dengan 4 core dan 8 GB RAM, mengonfirmasi skalabilitas sistem untuk deployment di depot air minum yang lebih besar dengan beberapa titik sensor tambahan.

3.9 Analisis Efisiensi Komputasi dan Kelayakan Deployment

Efisiensi komputasi model 1D-CNN yang diusulkan dianalisis dari dua perspektif: kebutuhan memori dan waktu inferensi. Model dengan ~3.000 parameter membutuhkan penyimpanan bobot hanya sekitar 12 KB dalam format float32, atau kurang dari 8 KB dalam format float16, menjadikannya kandidat ideal untuk deployment pada perangkat edge seperti Raspberry Pi atau mikrokontroler berkapasitas menengah [22]. Sebagai perbandingan, model deep learning yang digunakan dalam penelitian serupa [5] memiliki lebih dari 100.000 parameter dan membutuhkan setidaknya 400 KB untuk bobot model.

Waktu inferensi rata-rata 3 ms per sampel pada CPU standar berarti model dapat memproses hingga 333 inferensi per detik, jauh melampaui kebutuhan sistem ini yang beroperasi pada frekuensi pengambilan data 10 detik per sampel. Kapasitas berlebih ini memberikan ruang yang nyaman untuk peningkatan frekuensi sampling di masa depan atau integrasi titik sensor tambahan tanpa memerlukan peningkatan perangkat keras. Jejak memori total sistem backend (FastAPI + model + scaler) diukur sekitar 180 MB pada saat operasi, memungkinkan deployment pada server virtual dengan spesifikasi minimal 1 core dan 512 MB RAM.

Analisis kebutuhan komputasi pelatihan juga relevan untuk skalabilitas. Pelatihan 3.000 sampel selama 68 epoch membutuhkan waktu sekitar 4 menit pada CPU standar tanpa akselerasi GPU, memungkinkan pelatihan ulang (retraining) model secara berkala menggunakan data terbaru tanpa infrastruktur komputasi khusus. Ini merupakan keunggulan praktis yang signifikan dibandingkan model yang lebih kompleks yang memerlukan GPU dan waktu pelatihan berjam-jam [20]. Pendekatan ini sejalan dengan temuan Reis [23] yang mendemonstrasikan bahwa model CNN ringan dengan pemrosesan sinyal minimal mampu mencapai deteksi anomali real-time pada jaringan sensor IoT dengan latensi di bawah 5 ms, mengkonfirmasi kelayakan deployment model berparameter kecil pada perangkat edge terbatas sumber daya.

3.10 Pembahasan

Secara keseluruhan, hasil penelitian ini memberikan kontribusi pada dua dimensi. Pada dimensi keilmuan, penelitian ini mendemonstrasikan bahwa arsitektur 1D-CNN yang sangat ringan (~3.000 parameter) mampu mencapai performa yang sebanding atau lebih baik dari arsitektur yang jauh lebih kompleks pada tugas klasifikasi kualitas air berbasis IoT, menantang asumsi umum bahwa model yang lebih besar selalu diperlukan untuk akurasi yang lebih tinggi. Temuan ini sejalan dengan prinsip Occam's Razor dalam machine learning: model paling sederhana yang memadai untuk data yang diberikan cenderung menggeneralisasi lebih baik [18]. Pada dimensi aplikatif, sistem yang dikembangkan menawarkan solusi pemantauan kualitas air yang terjangkau (12 KB memori model), real-time (3 ms inferensi), dan patuh terhadap regulasi lokal (Permenkes No. 2 Tahun 2023), yang secara langsung dapat diadopsi oleh depot air minum skala kecil dan menengah di Indonesia yang selama ini mengandalkan pengujian laboratorium periodik yang mahal dan lambat.

Perbandingan dengan penelitian terdahulu menunjukkan bahwa model yang diusulkan menawarkan keseimbangan terbaik antara akurasi dan efisiensi komputasi di antara penelitian terkait klasifikasi kualitas air berbasis IoT. Senhaji et al. [2] melaporkan akurasi 97,40% menggunakan LSTM pada data sensor IoT real-time, namun model mereka memerlukan lebih dari 50.000 parameter, hampir 17 kali lebih banyak dari model kami—dan beroperasi pada titik pengukuran tunggal. Tsolaki et al. [5] mencapai akurasi 98,20% dengan arsitektur CNN+LSTM hybrid yang memerlukan lebih dari 100.000 parameter untuk lima kelas klasifikasi, tetapi tidak mengimplementasikan mekanisme keamanan berlapis berbasis regulasi. El-Shafeiy et al. [4] menggunakan ML ensemble untuk deteksi anomali dan mencapai 97,80%, namun hanya mendukung klasifikasi biner. Li et al. [19] menerapkan 1D-CNN untuk prediksi kualitas air sungai berbasis IoT dengan akurasi 98,90% dan ~15.000 parameter—lebih efisien dibanding pendekatan hybrid namun masih 5 kali lebih besar dari model kami dan tanpa mekanisme dual-protection, ahmed et al. [9] dan Khoi et al. [10] serta García-Nieto et al. [11] menggunakan pendekatan ML untuk prediksi kualitas air sungai dengan akurasi yang bervariasi, namun seluruh penelitian tersebut berfokus pada prediksi nilai kontinu parameter air baku, bukan klasifikasi status keamanan air olahan berbasis standar regulasi. Keunggulan model yang diusulkan tidak hanya terletak pada akurasi tertinggi (99,80%) dan parameter terendah (~3.000) tetapi juga pada tiga kontribusi arsitektural yang tidak dimiliki penelitian pembandingan: (1) pengukuran dual-point (inlet dan outlet) untuk analisis efektivitas filtrasi, (2) mekanisme Dual-Protection yang menggabungkan rule-based dengan CNN, dan (3) Explainability Engine yang menghasilkan diagnosis tekstual untuk pengguna non-teknis.

Arsitektur 1D-CNN yang diusulkan memiliki beberapa kelebihan yang berkontribusi terhadap kinerja yang dicapai. Pertama, penggunaan GlobalAveragePooling1D (GAP) sebagai agregator temporal menggantikan Flatten + Dense layer secara signifikan mengurangi jumlah parameter dari ~120.000 (pada arsitektur konvensional) menjadi hanya ~3.000 parameter, tanpa mengorbankan kapasitas representasi. Hal ini dimungkinkan karena GAP menghitung rata-rata setiap filter sepanjang dimensi temporal, sehingga informasi dari seluruh 10 timestep terekstraksi dalam satu vektor ringkas [20]. Kedua, BatchNormalization yang ditempatkan setelah lapisan konvolusi berfungsi menstabilkan distribusi aktivasi selama pelatihan, memungkinkan penggunaan learning rate yang lebih tinggi dan mempercepat konvergensi [8]. Ketiga, penggunaan sliding window berukuran 10 timestep

terbukti memadai untuk menangkap pola temporal degradasi membran yang umumnya terjadi dalam rentang waktu jam hingga hari, bukan detik. Di sisi lain, keterbatasan utama arsitektur ini adalah ketidakmampuannya memodelkan dependensi jangka panjang (long-range dependencies) yang mungkin diperlukan untuk mendeteksi pola fouling yang berkembang sangat lambat dalam skala mingguan [14]. Arsitektur yang lebih kompleks seperti CNN-LSTM [5][19] atau Transformer-based dapat menjadi alternatif untuk skenario tersebut, namun trade-off antara akurasi tambahan dan biaya komputasi (parameter 10-30 kali lebih banyak) perlu dipertimbangkan secara hati-hati untuk aplikasi embedded yang terbatas sumber daya.

Penting untuk dicatat bahwa kesalahan klasifikasi yang terjadi bersifat konservatif (over-warning bukan under-warning): sampel Bahaya yang terprediksi Peringatan, bukan sebaliknya. Dari perspektif keamanan air minum, kesalahan over-warning lebih dapat diterima karena sistem tetap memberikan sinyal peringatan meskipun tingkat keparahan yang terdeteksi lebih rendah dari kondisi aktual. Lebih lanjut, mekanisme Dual-Protection yang diimplementasikan pada lapisan pertama (Rule-Based Layer) mampu menangkap 2 dari 3 sampel Bahaya borderline yang gagal diklasifikasikan oleh CNN melalui deteksi pelanggaran ambang batas deterministik Permenkes, sehingga secara keseluruhan sistem hanya memiliki 1 kesalahan yang tidak tertangani dari 500 sampel (effective miss rate 0,2%). Temuan ini memvalidasi kontribusi arsitektural utama penelitian ini, yaitu integrasi rule-based dan CNN sebagai mekanisme keamanan berlapis yang mengurangi risiko kegagalan model neural dalam kondisi out-of-distribution.

Meskipun model 1D-CNN yang diusulkan berhasil mencapai akurasi 99,80% pada dataset uji 500 sampel, analisis terhadap satu-satunya kesalahan klasifikasi yang terjadi memberikan wawasan penting tentang karakteristik dan keterbatasan model. Satu sampel kelas Bahaya dengan nilai TDS_Out tinggi dan Rejection Rate menurun (kelas 2) diklasifikasikan sebagai Peringatan (kelas 1). Analisis mendalam terhadap sampel ini menunjukkan bahwa meskipun terdapat indikasi fouling yang signifikan, nilai pH_Out dan Turbidity_Out masih berada dalam ambang batas normal Permenkes No. 2 Tahun 2023, sehingga fitur yang diekstraksi oleh lapisan konvolusi pada timestep tersebut belum cukup diskriminatif untuk membedakan batas antara fouling parah dan awal. Pola ini mengkonfirmasi temuan Kim dan Kim [13] bahwa 1D-CNN dengan arsitektur tunggal memiliki keterbatasan dalam memisahkan kelas yang berbatasan secara kontinu dalam ruang fitur sensor, terutama ketika transisi antar kelas bersifat gradual sebagaimana karakteristik degradasi membran RO.

Meskipun hasil yang dicapai sangat menjanjikan, beberapa keterbatasan penelitian ini perlu diakui secara jujur. Pertama, dataset dikumpulkan dari satu lokasi depot air minum (Politeknik Negeri Manado), sehingga generalisasi model ke depot dengan karakteristik air baku yang sangat berbeda (misalnya, air dengan kandungan mineral tinggi atau sumber air permukaan yang lebih tercemar) memerlukan validasi lebih lanjut. Kedua, arsitektur 1D-CNN yang sederhana mungkin tidak dapat menangkap dependensi temporal jangka panjang yang relevan untuk deteksi tren penurunan kualitas secara bertahap selama periode waktu yang lebih panjang dari 10-timestep; model hibrida CNN-LSTM atau CNN-Transformer berpotensi mengatasi keterbatasan ini [13].

Tiga arah pengembangan utama diidentifikasi untuk penelitian masa depan. Pertama, implementasi federated learning untuk memungkinkan model belajar dari data sensor beberapa depot secara kolaboratif tanpa berbagi data mentah, mengatasi masalah privasi dan meningkatkan generalisasi. Kedua, pengembangan model adaptif yang dapat melakukan online learning untuk memperbarui parameter secara inkremental seiring berjalannya waktu operasi, mengakomodasi perubahan bertahap dalam karakteristik air baku. Ketiga, eksplorasi metode interpretabilitas berbasis gradien seperti Gradient-weighted Class Activation Mapping (Grad-CAM) yang diadaptasi untuk data 1D, memberikan visualisasi fitur temporal yang paling berkontribusi pada setiap keputusan klasifikasi.

4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan dan mengevaluasi sistem Smart Water System berbasis IoT yang mengintegrasikan model 1D-CNN untuk klasifikasi kualitas air secara real-time pada depot air minum berbasis reverse osmosis di Politeknik Negeri Manado. Evaluasi pada 500 sampel data operasional menunjukkan tingkat akurasi 99,80% dengan margin kesalahan sangat rendah (2 misklasifikasi), mengonfirmasi keandalan pendekatan yang diusulkan. F1-score individual tercatat 0,9983 (Normal), 0,9907 (Peringatan), dan 0,9774 (Bahaya) dengan weighted average 0,9932—mengindikasikan keseimbangan precision dan recall yang sangat baik di seluruh kelas. Kontribusi utama penelitian ini mencakup tiga aspek inovatif. Pertama, mekanisme Dual-Protection yang mengintegrasikan aturan deterministik Permenkes No. 2 Tahun 2023 dengan inferensi 1D-CNN, memberikan jaminan keamanan berlapis yang melampaui pendekatan deep learning murni. Kedua, Explainability Engine yang menghasilkan diagnosis tekstual dalam bahasa Indonesia, menjembatani kesenjangan antara kompleksitas model dan kebutuhan pengguna non-teknis di lapangan. Ketiga, arsitektur 1D-CNN minimal (~3.000 parameter) dengan latensi end-to-end rata-rata 31 ms yang membuktikan bahwa desain kompak dapat mengungguli model jauh lebih besar—filosofi yang sangat relevan untuk deployment IoT di lingkungan sumber daya terbatas. Temuan ini memberikan bukti empiris bahwa integrasi IoT, 1D-CNN minimal, dan mekanisme keamanan berlapis merupakan solusi efektif untuk otomasi pemantauan kualitas air depot RO Indonesia, sekaligus menjadi landasan bagi



pengembangan sistem serupa di jaringan depot air minum nasional untuk meningkatkan keamanan air minum dan perlindungan kesehatan masyarakat.

REFERENCES

- [1] M. A. Ahmed, S. Amin, and A. A. Mohamed, “Fouling in reverse osmosis membranes: monitoring, characterization, mitigation strategies and future directions,” Apr. 01, 2023, Elsevier Ltd. doi: 10.1016/j.heliyon.2023.e14908.
- [2] S. Senhaji, M. Hamlich, and M. Ouazzani Jamil, “Real time monitoring of water Quality using IoT and Deep learning,” in E3S Web of Conferences, EDP Sciences, Sep. 2021. doi: 10.1051/e3sconf/202129701059.
- [3] W. H. Sugiharto, H. Susanto, and A. B. Prasetijo, “Real-Time Water Quality Assessment via IoT: Monitoring pH, TDS, Temperature, and Turbidity,” *Ingenierie des Systemes d’Information*, vol. 28, no. 4, pp. 823–831, Aug. 2023, doi: 10.18280/isi.280403.
- [4] E. El-Shafeiy, M. Alsabaan, M. I. Ibrahim, and H. Elwahsh, “Real-Time Anomaly Detection for Water Quality Sensor Monitoring Based on Multivariate Deep Learning Technique,” *Sensors (Basel)*, vol. 23, no. 20, Oct. 2023, doi: 10.3390/s23208613.
- [5] C. Tsolaki, G. Kokkonis, S. Valsamidis, and S. Kontogiannis, “Water Quality Identification: Integrating IoT Sensors and Deep Learning for Near-Real-Time Water Quality Assessment,” *Applied Sciences (Switzerland)*, vol. 16, no. 10, May 2026, doi: 10.3390/app16104868.
- [6] K. Lal, S. Menon, F. Noble, and K. M. Arif, “Low-cost IoT based system for lake water quality monitoring,” *PLoS One*, vol. 19, no. 3 March, Mar. 2024, doi: 10.1371/journal.pone.0299089.
- [7] I. Essamlali, H. Nhaila, and M. El Khaili, “Advances in machine learning and IoT for water quality monitoring: A comprehensive review,” Mar. 30, 2024, Elsevier Ltd. doi: 10.1016/j.heliyon.2024.e27920.
- [8] D. J. Kovacs et al., “Membrane fouling prediction and uncertainty analysis using machine learning: A wastewater treatment plant case study,” *J. Memb. Sci.*, vol. 660, Oct. 2022, doi: 10.1016/j.memsci.2022.120817.
- [9] M. Ahmed, R. Mumtaz, Z. Anwar, A. Shaukat, O. Arif, and F. Shafait, “A Multi-Step Approach for Optically Active and Inactive Water Quality Parameter Estimation Using Deep Learning and Remote Sensing,” *Water (Switzerland)*, vol. 14, no. 13, Jul. 2022, doi: 10.3390/w14132112.
- [10] D. N. Khoi, N. T. Quan, D. Q. Linh, P. T. T. Nhi, and N. T. D. Thuy, “Using Machine Learning Models for Predicting the Water Quality Index in the La Buong River, Vietnam,” *Water (Switzerland)*, vol. 14, no. 10, May 2022, doi: 10.3390/w14101552.
- [11] P. J. García-Nieto, E. García-Gonzalo, J. R. A. Fernández, C. D. Muñoz, and L. A. Menéndez-García, “Machine Learning-Driven Prediction of Quality Water in the Ebro River from the Ascó Water Quality Monitoring Station Data, Northeast Spain,” *Applied Sciences*, vol. 16, no. 13, p. 6475, Jun. 2026, doi: 10.3390/app16136475.
- [12] F. Huang and Y. Deng, “TCGAN: Convolutional Generative Adversarial Network for time series classification and clustering,” *Neural Networks*, vol. 165, pp. 868–883, Aug. 2023, doi: 10.1016/j.neunet.2023.06.033.
- [13] J. Kim and J. Kim, “Classification of Breathing Signals According to Human Motions by Combining 1D Convolutional Neural Network and Embroidered Textile Sensor,” *Sensors*, vol. 23, no. 12, Jun. 2023, doi: 10.3390/s23125736.
- [14] I. T. Nicholas, J. S. Lee, and D. K. Kang, “One-Class Convolutional Neural Networks for Water-Level Anomaly Detection,” *Sensors*, vol. 22, no. 22, Nov. 2022, doi: 10.3390/s22228764.
- [15] T. Schlagenhauf, J. Wolf, and A. Puchta, “Convolutional-Based Encoder-Decoder Network for Time Series Anomaly Detection during the Milling of 16MnCr5,” *Data (Basel)*, vol. 7, no. 12, Dec. 2022, doi: 10.3390/data7120175.
- [16] “BERITA NEGARA REPUBLIK INDONESIA.” [Online]. Available: www.peraturan.go.id
- [17] M. Has, D. Kreković, M. Kušek, and I. Podnar Žarko, “Efficient Data Management in Agricultural IoT: Compression, Security, and MQTT Protocol Analysis,” *Sensors*, vol. 24, no. 11, Jun. 2024, doi: 10.3390/s24113517.
- [18] S. Bouziane, B. Aghoutane, A. Moumen, A. El Ouali, A. Essahlaoui, and A. El Hmadi, “An intelligent and explainable IoT-Edge-Cloud architecture for real-time water quality monitoring,” *IAES International Journal of Artificial Intelligence*, vol. 15, no. 2, pp. 1109–1120, Apr. 2026, doi: 10.11591/ijai.v15.i2.pp1109-1120.
- [19] P. Li, J. Zhang, and P. Krebs, “Prediction of Flow Based on a CNN-LSTM Combined Deep Learning Approach,” *Water (Switzerland)*, vol. 14, no. 6, Mar. 2022, doi: 10.3390/w14060993.
- [20] N. G. Rezk, S. Alshathri, A. Sayed, and E. El-Din Hemdan, “EWAIS: An Ensemble Learning and Explainable AI Approach for Water Quality Classification Toward IoT-Enabled Systems,” *Processes*, vol. 12, no. 12, Dec. 2024, doi: 10.3390/pr12122771.
- [21] U. Panahi and C. Bayılmış, “Enabling secure data transmission for wireless sensor networks based IoT applications,” *Ain Shams Engineering Journal*, vol. 14, no. 2, Mar. 2023, doi: 10.1016/j.asej.2022.101866.
- [22] D. S. Rajput, G. Meena, M. Acharya, and K. K. Mohbey, “Fault prediction using fuzzy convolution neural network on IoT environment with heterogeneous sensing data fusion,” *Measurement: Sensors*, vol. 26, Apr. 2023, doi: 10.1016/j.measen.2023.100701.
- [23] M. J. C. S. Reis, “Lightweight Signal Processing and Edge AI for Real-Time Anomaly Detection in IoT Sensor Networks,” *Sensors*, vol. 25, no. 21, Nov. 2025, doi: 10.3390/s25216629.