FORMULASI PREDIKTIF IoT DALAM PEMANTAUAN DAN PENGOLAHAN AIR BERSIH

Angga Debby Frayudha[1)], Aris Puja Widikda. [2)], Nugrahadi Djazaul Mukhsinin.[3)]

[1]D3 Teknologi Informasi, Politeknik Semen Indonesia
[2,3]D3 Teknologi Mesin, Politeknik Semen Indonesia
E-mail: angga@polteksi.ac.id

Abstract

The quality of river water may change within a relatively short period, whereas chemical dosing in conventional treatment units is often determined after the change has occurred. This study develops a proof-of-concept predictive Internet of Things (IoT) model that links pH and total dissolved solids (TDS) monitoring with adaptive dosing of polyaluminium chloride (PAC) and chlorine. The system consists of pH and TDS sensors, an ESP32 acquisition unit, HTTP/MQTT communication, a virtual private server, predictive models, and dosing pumps operating in a closed loop. A dataset representing observations from 10 to 17 July 2026 was recorded at five-minute intervals, producing 2,304 observations. Long Short-Term Memory (LSTM), XGBoost, and SARIMA were compared for a 30-minute prediction horizon. The acquisition layer achieved 99.05% data completeness with an average transmission latency of 668.35 ms. LSTM produced the best prediction performance for both pH (RMSE 0.0557; R^2 0.9545) and TDS (RMSE 8.0473 mg/L; R^2 0.9501). After predictive dosing was applied, out-of-standard observations decreased from 8.81% to 0.78%, equivalent to a relative reduction of 91.13%. The PAC and chlorine pumps were activated 19 and 5 times, respectively, with no unnecessary or repeated activation detected. These results indicate that combining IoT monitoring, time-series prediction, and closed-loop dosing can improve pH-TDS stability while limiting chemical use. The findings remain a proof of concept and require validation using longer field observations, seasonal variation, and physical actuator testing.

Keywords: *Internet of Things, water treatment, pH, total dissolved solids, LSTM, predictive dosing*

Abstrak

Kualitas air sungai dapat berubah dalam waktu yang relatif singkat, sedangkan pemberian bahan kimia pada unit pengolahan konvensional sering kali ditentukan setelah perubahan tersebut terjadi. Studi ini mengembangkan model Internet of Things (IoT) prediktif sebagai proof-of-concept yang menghubungkan pemantauan pH dan total dissolved solids (TDS) dengan pemberian dosis poli Aluminium klorida (PAC) dan klorin yang adaptif. Sistem terdiri atas sensor pH dan TDS, unit akuisisi ESP32, komunikasi HTTP/MQTT, virtual private server, model prediktif, dan pompa pemberi dosis yang beroperasi secara closed loop. Dataset yang mewakili pengamatan dari 10 hingga 17 Juli 2026 dicatat setiap lima menit, menghasilkan 2.304 data pengamatan. Long Short-Term Memory (LSTM), XGBoost, dan SARIMA dibandingkan untuk horizon prediksi selama 30 menit. Lapisan akuisisi mencapai kelengkapan data sebesar 99,05% dengan rata-rata latensi transmisi 668,35 ms. LSTM menghasilkan performa prediksi terbaik baik untuk pH (RMSE 0,0557; R^2 0,9545) maupun TDS (RMSE 8,0473 mg/L; R^2 0,9501). Setelah pemberian dosis prediktif diterapkan, observasi yang berada di luar standar menurun dari 8,81% menjadi 0,78%, setara dengan penurunan relatif sebesar 91,13%. Pompa PAC dan klorin diaktifkan masing-masing sebanyak 19 dan 5 kali, tanpa terdeteksi aktivasi yang tidak perlu atau berulang. Hasil ini menunjukkan bahwa kombinasi pemantauan IoT, prediksi deret waktu, dan pemberian dosis closed-loop dapat meningkatkan stabilitas pH-TDS sekaligus membatasi penggunaan bahan kimia. Temuan ini masih merupakan proof of concept dan memerlukan validasi melalui pengamatan lapangan yang lebih panjang, variasi musiman, dan pengujian aktuator fisik.

Keywords: Internet of Things, pengolahan air, pH, total dissolved solids, LSTM, pemberian dosis prediktif

PENDAHULUAN

Kualitas air sungai dapat berubah dalam waktu singkat akibat perubahan debit, limpasan permukaan, cuaca, serta aktivitas domestik dan industri. Pada pengolahan yang masih reaktif, perubahan pH atau total dissolved solids (TDS) baru ditindak setelah nilai pengukuran keluar dari batas kendali. Integrasi sensor Internet of Things (IoT) dan pemodelan deret waktu menawarkan pendekatan yang lebih responsif karena perubahan mutu air dapat dipantau dan diprediksi secara kontinu (Kannan et al., 2025), (Chang et al., 2023) , (Annamalai et al., 2025) , (Jomjaiekachorn et al., 2025).

Sejumlah penelitian telah memanfaatkan IoT dan kecerdasan buatan untuk monitoring, estimasi parameter, dan deteksi anomali kualitas air (Grande et al., 2025), (Regula et al., 2025), (Wang et al., 2024) Perkembangan berikutnya mengarah pada penggunaan machine learning untuk prediksi dan optimasi proses (Shiraz et al., 2025), (Hamadi et al., 2025). Namun, integrasi pembacaan pH-TDS secara real-time, prediksi deret waktu, keputusan dosis PAC dan kaporit, serta aktuator pompa dalam satu mekanisme closed-loop masih memerlukan pembuktian pada skala eksperimen.

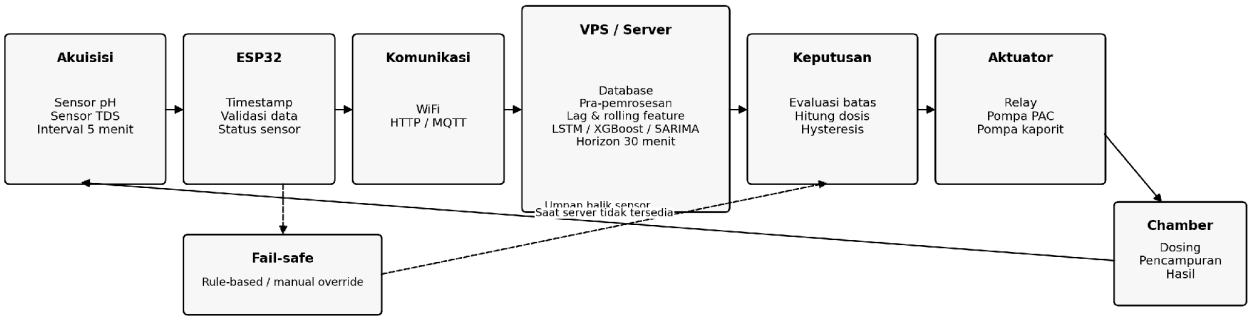
Penelitian ini mengembangkan proof of concept sistem prediktif IoT yang menghubungkan sensor pH-TDS, ESP32, VPS, model LSTM, XGBoost, dan SARIMA, serta pompa dosing. Model dengan performa terbaik digunakan sebagai dasar keputusan dosing, kemudian sensor membaca kembali kondisi air sebagai umpan balik. Tujuan penelitian adalah mengevaluasi kualitas akuisisi data, karakter temporal pH-TDS, performa ketiga model pada horizon 30 menit, dan pengaruh dosing prediktif terhadap kestabilan kualitas air serta respons pompa.

METODE PENELITIAN

Penelitian menggunakan pendekatan eksperimen dan rekayasa sistem pada chamber water treatment skala laboratorium. Objek uji berupa air sungai atau air permukaan. Sistem dirancang sebagai proof of concept agar variasi pH, TDS, dosis PAC, dosis kaporit, dan respons aktuator dapat diamati pada kondisi terkendali sebelum pengujian lapangan.

Arsitektur dan alur kerja sistem

Arsitektur sistem terdiri atas lapisan akuisisi (sensor pH, sensor TDS, ESP32), komputasi (VPS untuk penyimpanan, pra-pemrosesan, dan prediksi), serta aktuasi (relay dan pompa dosing PAC/kaporit). Data dikirim melalui HTTP/MQTT. Rancangan menyediakan rule-based/manual override saat koneksi server tidak tersedia. Arsitektur closed-loop yang direvisi dan diperbesar ditunjukkan pada Gambar 1.



Gambar 1. Arsitektur closed-loop model prediktif IoT dan kontrol dosing

Data dicatat setiap lima menit dengan timestamp. Variabel utama adalah pH dan TDS, sedangkan variabel pendukung meliputi waktu, suhu, debit, volume air, status pompa, dosis sebelumnya, latency komunikasi, dan nilai referensi laboratorium. Sensor dikalibrasi terhadap alat referensi; kehilangan data singkat ditangani dengan interpolasi dan pembacaan menyimpang ditandai sebagai outlier. Fitur model mencakup lag, rolling mean, rolling standard deviation, serta perubahan pH dan TDS.

Alur pemrosesan dimulai dari validasi data sensor, pengiriman ke VPS, pra-pemrosesan dan pembentukan fitur, prediksi pH-TDS, evaluasi terhadap batas kendali, perhitungan dosis, aktivasi pompa, dan pembacaan ulang sensor. Dengan demikian, keputusan tidak hanya bergantung pada threshold sesaat, tetapi menggunakan informasi prediksi sebelum kondisi diperkirakan keluar dari batas yang ditetapkan.

Pengembangan model dan logika kontrol

Tiga model dibandingkan pada horizon prediksi 30 menit: LSTM untuk ketergantungan temporal, XGBoost untuk hubungan nonlinier pada fitur tabular, dan SARIMA sebagai baseline statistik (Frayudha & Widikda, 2025), (Chola et al., 2024) ,(Rifqa Annisa et al., 2024) Kinerja dinilai dengan MAE, RMSE, MAPE, dan R^2; perbedaan performa diperiksa menggunakan uji Friedman dan uji lanjut berpasangan. Uji Diebold-Mariano tidak diterapkan karena deret error lengkap pada setiap titik waktu tidak tersedia dalam dataset analisis.

Keputusan dosing dibentuk dari prediksi pH dan TDS. Ketika TDS diperkirakan melewati batas kendali, sistem menghitung kebutuhan PAC; ketika pH diperkirakan keluar dari rentang, sistem menentukan tindakan koreksi kaporit sesuai rancangan eksperimen. Dosis dikonversi menjadi durasi nyala pompa dengan mempertimbangkan dosis target, debit, konsentrasi larutan, dan kapasitas pompa. Hysteresis, minimum on/off time, dan stable duration digunakan untuk mencegah switching berulang.

Dataset merepresentasikan periode 10–17 Juli 2026 dengan interval lima menit dan 2.304 observasi. Evaluasi mencakup akuisisi IoT, validasi sensor, karakteristik deret waktu, performa model, hasil dosing, dan respons kontrol. Karena data hanya berasal dari satu periode dan satu horizon prediksi, hasil dibatasi sebagai bukti awal (proof of concept) dan tidak digeneralisasi terhadap variasi musiman atau kondisi lapangan yang lebih luas.

HASIL DAN PEMBAHASAN

Kinerja akuisisi data dan validasi sensor

Dari 2.304 observasi, terdapat 22 data yang tidak diterima atau setara dengan packet loss 0,95%. Dengan demikian, keterisian data mencapai 99,05%. Rata-rata latency pengiriman dari ESP32 ke VPS sebesar 668,35 ms, dengan rentang 250-1.747 ms. Waktu tunda tersebut masih memadai untuk monitoring periodik lima menit dan pengambilan keputusan yang tidak menuntut respons pada skala milidetik. Untuk perbandingan sensor IoT dengan alat referensi disampaikan pada Tabel 1.

Tabel 1
Perbandingan sensor IoT dengan alat referensi

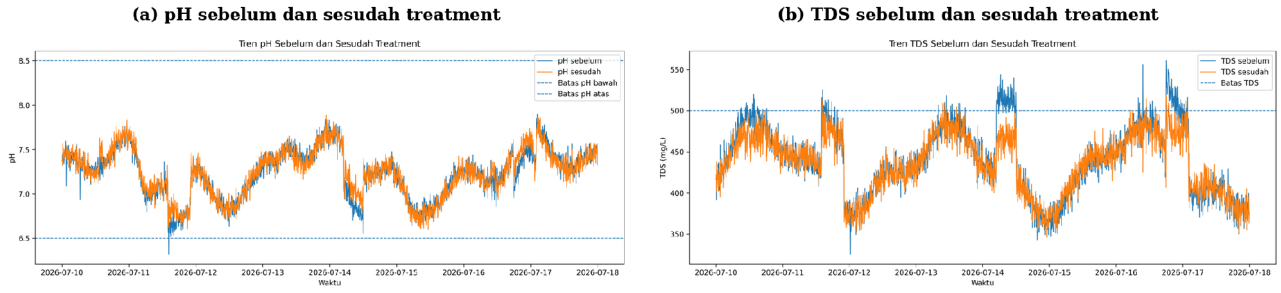
Indikator	pH	TDS	Interpretasi ringkas
Rata-rata referensi	7,2271	441,2293 mg/L	Nilai pembanding laboratorium

Rata-rata sensor IoT	7,2320	441,1129 mg/L	Rata-rata pembacaan sangat dekat dengan referensi
Bias IoT-referensi	0,0049	-0,1164 mg/L	Bias rata-rata relatif kecil
MAE	0,0352	5,5922 mg/L	Galat absolut rata-rata
RMSE	0,0467	7,3562 mg/L	Terdapat beberapa lonjakan galat sesaat
Rentang galat	-0,41 s.d. 0,30	-62 s.d. 73 mg/L	Outlier perlu diperhatikan saat kalibrasi
Pembacaan stabil	72,35%	90,23%	Sensor TDS lebih stabil
Rolling std 15 menit	0,0644	10,61 mg/L	Stabilitas memadai untuk monitoring kontinu

Rata-rata sensor pH berbeda 0,0049 dari alat referensi, sedangkan selisih rata-rata TDS sebesar -0,1164 mg/L. Kedekatan rerata menunjukkan data memadai untuk pemodelan proof of concept, tetapi rentang error dan stabilitas pH yang lebih rendah menegaskan perlunya kalibrasi berkala, pemeriksaan drift, dan penyaringan outlier. Literatur juga menunjukkan dosis PAC/klorin sangat dipengaruhi kondisi air baku, pH, debit, dan kebutuhan residu, sehingga nilai dosis tidak dapat digeneralisasi menjadi set-point tetap(Kannan et al., 2025) , (Shiraz et al., 2025a), (Hamadi et al., 2025), (Grande et al., 2025) , (Regula et al., 2025).

Karakteristik pH dan TDS sebagai deret waktu

Rata-rata pH sensor adalah 7,2320 (SD 0,2687; minimum 6,3170; maksimum 7,8970), sedangkan TDS 441,1129 mg/L (SD 42,6683 mg/L; minimum 325,1000; maksimum 560,7700 mg/L). Setelah treatment, rata-rata pH menjadi 7,2415 dan TDS 436,4370 mg/L; standar deviasi TDS turun menjadi 35,9938 mg/L.



Gambar 2. Pola pH dan TDS sebelum serta sesudah treatment

Sebelum treatment, 203 observasi (8,81%) berada di luar batas penelitian; setelah treatment turun menjadi 18 observasi (0,78%), sehingga 99,22% data dinyatakan stabil. Pada Gambar 2, perubahan paling jelas terjadi pada TDS ketika nilai mendekati atau melampaui 500 mg/L, dan variasinya menyempit setelah treatment.

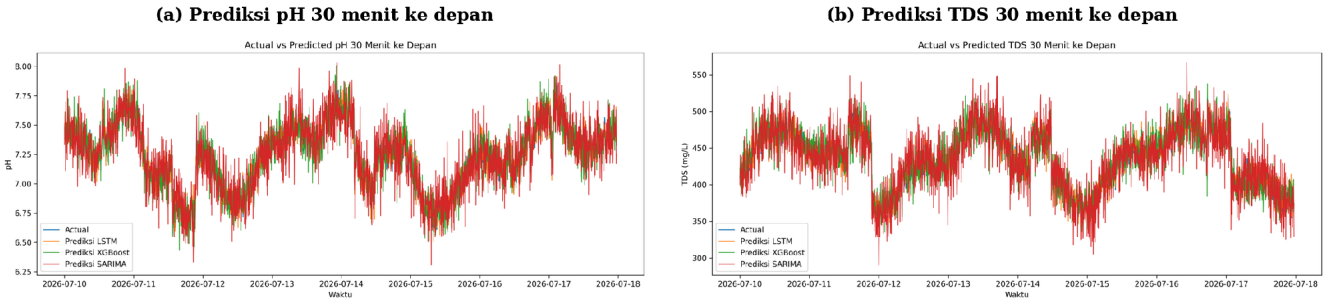
Uji Augmented Dickey-Fuller menghasilkan p-value 0,1291 untuk pH dan 0,1116 untuk TDS, sehingga kedua deret belum stasioner pada taraf 5%. ACF masih kuat hingga lag 60, sedangkan PACF menunjukkan pengaruh utama pada lag 1–8 untuk pH dan 1–9 untuk TDS. Karakter ini mendukung penggunaan model yang mempertimbangkan urutan waktu dan informasi historis.

Perbandingan LSTM, XGBoost, dan SARIMA

Tabel 2
Performa model pada horizon prediksi 30 menit

Parameter	Model	n	MAE	RMSE	MAPE (%)	R^2
pH	LSTM	2.298	0,0447	0,0557	0,6185	0,9545
pH	XGBoost	2.298	0,0699	0,0867	0,9666	0,8898
pH	SARIMA	2.298	0,1054	0,1338	1,4563	0,7375
TDS	LSTM	2.298	6,4298 mg/L	8,0473 mg/L	1,4885	0,9501
TDS	XGBoost	2.298	10,3669 mg/L	13,0915 mg/L	2,3876	0,8679
TDS	SARIMA	2.298	17,2387 mg/L	21,6799 mg/L	3,9789	0,6376

LSTM menghasilkan error terendah dan R^2 tertinggi untuk kedua parameter. RMSE pH adalah 0,0557 pada LSTM, dibandingkan 0,0867 pada XGBoost dan 0,1338 pada SARIMA. Untuk TDS, RMSE masing-masing 8,0473; 13,0915; dan 21,6799 mg/L. Gambar 3 memperlihatkan LSTM lebih konsisten mengikuti perubahan nilai aktual, khususnya pada bagian data yang berfluktuasi.



Gambar 3. Perbandingan nilai aktual dan prediksi pH-TDS

Uji Friedman menghasilkan statistik 16,0000 dengan p-value 0,0003. Uji lanjut berpasangan menghasilkan p-value 0,0078 untuk seluruh pasangan model, sehingga perbedaan performa dinilai signifikan. Berdasarkan metrik error dan pengujian statistik, urutan kinerja adalah LSTM, XGBoost, kemudian SARIMA. Keunggulan LSTM masih

perlu diuji menggunakan periode data yang lebih panjang, horizon berbeda, dan variasi musiman.

Efektivitas dosing prediktif

Kontrol prediktif menurunkan kondisi di luar standar dari 8,81% menjadi 0,78%, atau membaik relatif 91,13%. Jarak TDS dari batas standar turun dari 1,1978 menjadi 0,0569 mg/L, sedangkan jarak total terstandarisasi membaik 95,28%. Ringkasan kualitas dan penggunaan bahan kimia disajikan pada Tabel 3.

Tabel 3
Ringkasan kualitas air dan penggunaan bahan kimia

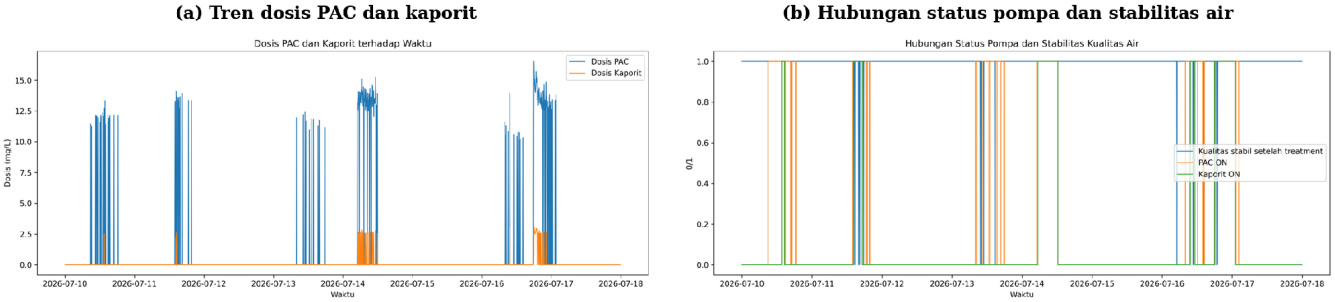
Indikator	Sebelum dosing	Sesudah dosing / hasil	Perubahan
Data di luar standar	8,81% (203 data)	0,78% (18 data)	Turun 8,03 poin; relatif 91,13%
Data stabil	91,19%	99,22%	Mayoritas kondisi sesudah treatment stabil
Jarak pH dari standar	0,000079	0,000000	Turun 100%
Jarak TDS dari standar	1,1978 mg/L	0,0569 mg/L	Turun 95,25%
Jarak total terstandarisasi	0,012057	0,000569	Turun 95,28%
Rata-rata TDS	441,1129 mg/L	436,4370 mg/L	Turun 4,6759 mg/L
Rata-rata dosis PAC	0 mg/L	1,1488 mg/L	Total 2.646,88 mg/L-interval
Rata-rata dosis kaporit	0 mg/L	0,0555 mg/L	Total 127,915 mg/L-interval
Overdosing	Belum ada dosing terkontrol	0 kejadian PAC; 0 kejadian kaporit	Tidak terdeteksi dosing yang tidak perlu

PAC digunakan lebih dominan daripada kaporit sesuai rancangan eksperimen yang menempatkan koreksi TDS sebagai kebutuhan utama. Tidak ditemukan overdosing berdasarkan logika kontrol yang digunakan, tetapi dataset belum memuat waktu menuju kondisi stabil dalam satuan menit sehingga kecepatan stabilisasi sebelum dan sesudah dosing belum dapat dibandingkan secara langsung.

Respons kontrol otomatis pompa

Pompa PAC aktif 19 kali dengan total durasi ON 589,55 menit dan duty cycle rata-rata 5,12%; pompa kaporit aktif 5 kali dengan total durasi ON 90,44 menit dan duty cycle 0,79%. Terdapat 24 penghentian ON-ke-OFF dan seluruhnya terjadi ketika indikator kualitas kembali stabil; tidak ditemukan aktivasi berulang yang tidak diperlukan. Pola

dosis dan hubungan status pompa dengan kestabilan kualitas air ditunjukkan pada Gambar 4.



Gambar 4. Tren dosis serta hubungan status pompa dengan kestabilan kualitas air

Secara keseluruhan, mekanisme closed-loop bekerja sesuai rancangan proof of concept: sensor menghasilkan data, server memprediksi perubahan, keputusan diterjemahkan menjadi tindakan pompa, lalu sensor memeriksa kembali hasil treatment. Namun, reliabilitas aktuator, fail-safe, perubahan debit mendadak, komposisi air baku ekstrem, gangguan jaringan, dan drift sensor jangka panjang belum seluruhnya terwakili.

SIMPULAN

Model prediktif IoT berhasil menghubungkan akuisisi pH-TDS, komputasi VPS, prediksi deret waktu, dan pompa dosing dalam mekanisme closed-loop. Keterisian data mencapai 99,05% dengan latency rata-rata 668,35 ms; pembacaan sensor secara rata-rata dekat dengan alat referensi, meskipun kalibrasi berkala tetap diperlukan.

Pada horizon 30 menit, LSTM memberi performa terbaik dengan RMSE 0,0557 dan R^2 0,9545 untuk pH serta RMSE 8,0473 mg/L dan R^2 0,9501 untuk TDS. Dosing prediktif menurunkan data di luar standar dari 8,81% menjadi 0,78% (perbaikan relatif 91,13%). Pompa PAC dan kaporit masing-masing aktif 19 dan 5 kali tanpa aktivasi berulang yang tidak diperlukan.

Implementasi sistem dosing tetap harus memperhatikan keselamatan penanganan kaporit/klorin karena bahan tersebut bersifat reaktif dan dapat menimbulkan risiko kesehatan pada paparan yang tidak terkendali (Stolecka, 2019) , (Khalid et al., 2025).

Temuan menunjukkan bahwa integrasi IoT, LSTM, dan kontrol dosing berpotensi meningkatkan kestabilan pH-TDS sekaligus membatasi tindakan dosing yang tidak diperlukan. Kesimpulan masih bersifat proof of concept karena dataset hanya mencakup satu periode dan satu horizon prediksi. Penelitian lanjutan perlu menambah data lintas

musim/lokasi, mengukur waktu stabilisasi, serta melakukan pengujian fisik pompa dan mekanisme fail-safe pada kondisi lapangan.

UCAPAN TERIMA KASIH

Penulis menyampaikan rasa terima kasih yang tulus dan apresiasi yang mendalam kepada Kementerian Pendidikan Tinggi, Sains, dan Teknologi (Kemdiktisaintek) Republik Indonesia atas kepercayaan dan dukungan finansial yang diberikan melalui Hibah Program BIMA Tahun 2026 (Keputusan No. 196/KPA/C3/KPT/2026 dan Kontrak Penelitian No. 286/C3/DT.05.00/PL-BARU/2026). Penulis juga mengucapkan terima kasih kepada PT SIG (Pabrik Gresik) atas akses lokasi dan informasi operasional yang diberikan serta dukungan mereka selama pengujian perangkat.

DAFTAR PUSTAKA

S. R. Kannan, L. M. Sundari, V. S. G. Akula, A. Mythili, D. Yobu, and C. Srinivasan, "LSTM-based Detection and Management of Emerging Waterborne Contaminants in IoT System," in *3rd International Conference on Emerging Applications of Material Science and Technology, ICEAMST 2025*, Institute of Electrical and Electronics Engineers Inc., 2025, pp. 1511–1516. doi: 10.1109/ICEAMST67459.2025.11335924.

C.-C. Chang, C.-H. Wei, M.-T. Lin, and S.-C. J. Hwang, "Machine Learning Approach to IoT-Based Water Quality Monitoring," in *2023 IEEE 5th Eurasia Conference on Biomedical Engineering, Healthcare and Sustainability, ECBIOS 2023*, M. T.-H., Ed., Institute of Electrical and Electronics Engineers Inc., 2023, pp. 182–186. doi: 10.1109/ECBIOS57802.2023.10218420.

P. Annamalai, A. R. Raju, P. Ranjith, T. Buvaneswari, C. Srinivasan, and J. P. Adlin Jenisha, "IoT-Driven Water Treatment Systems for Real-Time Quality Assurance and Control Using Logistic Regression Model," in *Proceedings of the 2025 11th International Conference on Communication and Signal Processing, ICCSP 2025*, Institute of Electrical and Electronics Engineers Inc., 2025, pp. 1247–1252. doi: 10.1109/ICCSP64183.2025.11089475.

T. Jomjaiekachorn, T. Anuwongpinit, and B. Purahong, "IoT-based Water Quality Monitoring Station and Forecasting System with Machine Learning," in *2025 13th International Electrical Engineering Congress (iEECON)*, IEEE, Mar. 2025, pp. 1–6. doi: 10.1109/iEECON64081.2025.10987795.

Ma. E. A. Grande, R. Reyes, G. V. Rolluqui, and L. C. M. De Jesus, "IoT-Based Real-Time Effluent Monitoring and Biochemical Oxygen Demand Estimation Using Raspberry Pi," Institute of Electrical and Electronics Engineers (IEEE), Dec. 2025, pp. 1187–1189. doi: 10.1109/gcce65946.2025.11274772.

T. Regula, S. G. Kiran Kumar, M. Rao Battina, S. Al-Amri, K. N. B. Rao, and S. M. R. Regula, "Artificial Intelligence and Internet of Things-Enabled Framework for Sustainable, Real-Time Water Quality Management and Predictive Resource Optimization in Arid Regions," Institute of Electrical and Electronics Engineers (IEEE), Nov. 2025, pp. 160–165. doi: 10.1109/iccbe65177.2025.11255687.

S. Shiraz, K. Karunasena, H. Mudelige, O. Kumarasinghe, D. Nawinna, and J. Perera, "Intelligent Water Quality Monitoring and Prediction System," in *Proceedings of the 6th International Conference on Inventive Research in Computing Applications, ICIRCA 2025*, Institute of Electrical and Electronics Engineers Inc., 2025, pp. 429–434. doi: 10.1109/ICIRCA65293.2025.11089780.

Y. A. Hamadi, R. J. Juma, Z. M. Hussein, and N. R. Lakkimsetty, "Harnessing Artificial Intelligence in Wastewater Treatment: A Comprehensive Analysis of Emerging Research Trends and Innovations," Institute of Electrical and Electronics Engineers (IEEE), Nov. 2025, pp. 1–7. doi: 10.1109/inista68122.2025.11249526.

L. Y. K. Wang, J. C. H. Loo, Y. X. Wong, and Y. Y. Lai, "IoT Based Wastewater Temperature, pH And Turbidity Monitoring with Data Analytics and Visualisation," in *Proceedings of the 2024 the 12th International Conference on Information Technology (ICIT)*, New York, NY, USA: ACM, Dec. 2024, pp. 213–218. doi: 10.1145/3718391.3718428.

A. D. Frayudha and A. P. Widikda, "IoT-Based Predictive Maintenance for AC Motors in Water Treatment Plants Using Multi-Sensor Data and LSTM Networks with GAN Augmentation," *Elinvo (Electronics, Informatics, and Vocational Education)*, vol. 10, no. 2, pp. 191–204, Dec. 2025, doi: 10.21831/elinvo.v10i2.89410.

A. Chola, R. Rastogi, P. Kaur, A. Chaudhary, and D. Biswas, "Predictive Analytics beyond the Hype: A Comprehensive Comparison of LSTM, XGBoost and LightGBM with Emphasis on RMSE and CPU Utilization," in *2024 3rd International Conference on Power, Control and Computing Technologies, ICPC2T 2024*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 179–184. doi: 10.1109/ICPC2T60072.2024.10474875.

T. Rifqa Annisa, D. Pramesti, H. Fakhrurroja, B. Pradika Putranto, and F. Anggriantaka, "Smart Dashboard for Water Quality Monitoring and Predicting in Koi Fish Farming Using IoT and Sarima Modeling," in *2024 12th International Conference on Information and Communication Technology, ICoICT 2024*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 578–584. doi: 10.1109/ICoICT61617.2024.10698719.

A. D. Frayudha and T. Mulyono, "Predictive Analytics with IoT: Research Trends, Methods, and Architectures Using Systematic Literature Review," *International Journal of Advanced Engineering and Management Research*, vol. 08, no. 06, pp. 25–37, 2023, doi: 10.51505/ijaemr.2023.8603.

M. E. A. Grande, R. Reyes, G. V. Rolluqui, and L. C. M. De Jesus, "IoT-Based Real-Time Effluent Monitoring and Biochemical Oxygen Demand Estimation Using Raspberry Pi," in *GCCE 2025 - 2025 IEEE 14th Global Conference on Consumer Electronics*, Institute of Electrical and Electronics Engineers Inc., 2025, pp. 1187–1189. doi: 10.1109/GCCE65946.2025.11274772.

T. Regula, S. G. K. Kumar, M. R. Battina, S. Al-Amri, K. N. B. Rao, and S. M. R. Regula, "Artificial Intelligence and Internet of Things-Enabled Framework for Sustainable, Real-Time Water Quality Management and Predictive Resource Optimization in Arid Regions," in *Proceedings of the 2025 IEEE International Conference on Computation, Big-Data and Engineering, ICCBE 2025*, Institute of Electrical and Electronics Engineers Inc., 2025, pp. 160–165. doi: 10.1109/ICCBE65177.2025.11255687.

K. Stolecka, "ANALYSIS OF THE ACCIDENTAL RELEASE OF CHLORINE," in *System Safety: Human - Technical Facility - Environment*, Sciendo, 2019, pp. 149–155. doi: 10.2478/czoto-2019-0019.

R. Khalid, M. I. Rosli, N. A. Zulkarnain, S. R. Sheikh Abdullah, M. I. Idris, and J. Buhari, "Assessing risks of chlorine usage as a disinfectant in drinking water treatment plant," *Model. Earth Syst. Environ.*, vol. 11, no. 4, Aug. 2025, doi: 10.1007/s40808-025-02431-x.