

MODEL PREDIKSI ADAPTIF BERBASIS JARINGAN SARAF TIRUAN UNTUK OPTIMALISASI DOSIS KOAGULAN PADA INSTALASI PENGOLAHAN AIR

Adimas Yudistira

adimas.yudistira33@gmail.com

Jakarta Global University

ABSTRAK

Pendosisan koagulan Poly Aluminium Chloride (PAC) pada instalasi pengolahan air selama ini masih banyak mengandalkan pengalaman operator melalui metode jar-test manual yang responsnya relatif lambat terhadap perubahan karakteristik air baku. Kondisi ini kerap memicu ketidak tepatan dosis, baik dalam bentuk pemborosan bahan kimia maupun penurunan kualitas air olahan. Artikel ini membahas pengembangan model prediksi adaptif berbasis jaringan saraf tiruan (Artificial Neural Network) dengan algoritma back-propagation untuk menentukan dosis PAC secara lebih presisi pada Instalasi Pengolahan Air (IPA) Buaran 3. Arsitektur jaringan yang digunakan terdiri atas lima neuron masukan, dua lapisan tersembunyi berturut-turut berisi 64 dan 32 neuron, serta satu neuron keluaran (konfigurasi 5-64-32-1), dengan fungsi aktivasi tanh pada lapisan tersembunyi. Model dilatih menggunakan data operasional historis dari sistem SCADA berupa debit aliran, kekeruhan air baku, dan pH, kemudian diuji terhadap data yang tidak dilibatkan pada proses pelatihan. Sistem ditempatkan dalam kerangka kontrol loop terbuka (open-loop) sehingga keluaran model berperan sebagai rekomendasi bagi operator, bukan sebagai perintah aktuasi otomatis. Hasil pengujian menunjukkan galat prediksi yang jauh lebih kecil dibandingkan pendekatan regresi konvensional, dengan penghematan konsumsi PAC sekitar 12,4% dibandingkan metode jar-test manual serta waktu respons yang turun dari kisaran 15-30 menit menjadi kurang dari satu detik. Temuan ini mengindikasikan bahwa pendekatan machine learning cukup layak diadopsi sebagai instrumen bantu pengambilan keputusan pada operasional IPA berskala industri.

Kata Kunci: Machine Learning, Algoritma Back-Propagation, Pendosisan Adaptif, Instalasi Pengolahan Air, Optimasi Koagulan.

ABSTRACT

Coagulant dosing of Poly Aluminium Chloride (PAC) in water treatment plants is still largely determined through manual jar-test procedures that respond slowly to changes in raw water characteristics, often resulting in chemical waste or degraded effluent quality. This paper presents the development of an adaptive prediction model based on a back-propagation Artificial Neural Network to determine PAC dosage more precisely at the Buaran 3 Water Treatment Plant. The network architecture consists of five input neurons, two hidden layers with 64 and 32 neurons respectively, and a single output neuron (5-64-32-1 configuration), using the tanh activation function in the hidden layers. The model was trained on historical SCADA operational data covering flow rate, raw water turbidity, and pH, then evaluated on data withheld from training. The system operates within an open-loop control framework, so its output functions as an advisory recommendation for the operator rather than an automatic actuation command. Testing shows prediction error considerably lower than conventional regression, with roughly 12.4% savings in PAC consumption compared to manual jar-test dosing and a reduction in decision response time from 15-30 minutes to under one second. These results suggest that the machine learning approach is reasonably suited for adoption as a decision-support tool in industrial-scale water treatment operations.

Keywords: Machine Learning, Back-Propagation Algorithm, Adaptive Dosing, Water Treatment Plant, Coagulant Optimization.

PENDAHULUAN

Ketersediaan air bersih yang memenuhi syarat kualitas, kuantitas, dan kontinuitas merupakan kebutuhan mendasar bagi kehidupan masyarakat perkotaan, dan pemenuhannya sangat bergantung pada keandalan Instalasi Pengolahan Air (IPA) sebagai sistem rekayasa proses yang mengubah air baku menjadi air layak konsumsi (Boretti & Rosa, 2019). Di antara rangkaian unit proses pada IPA-mulai dari koagulasi, flokulasi, sedimentasi, hingga filtrasi-tahap koagulasi menempati posisi yang menentukan, karena kegagalan pada tahap ini akan berdampak berantai pada seluruh unit proses berikutnya.

Koagulan Poly Aluminium Chloride (PAC) umum digunakan untuk menstabilkan partikel koloid dalam air baku agar dapat digumpalkan dan dipisahkan. Persoalannya, ketidaktepatan dosis PAC-baik dalam bentuk overdosing maupun underdosing-dapat menurunkan kualitas air olahan, meningkatkan residu aluminium, sekaligus memboroskan bahan kimia dan energi operasional (Zhen, j; Hou, J, 2023). Pada banyak IPA, penentuan dosis PAC masih dilakukan dengan pendekatan kontrol loop terbuka yang mengandalkan pengalaman operator atau nilai acuan historis. Cara ini memang sederhana dan mudah diterapkan, tetapi kurang tanggap terhadap perubahan karakteristik air baku yang dapat berubah cukup cepat, misalnya akibat hujan atau perubahan musim (Narges, 2021).

Sekilas, kontrol loop tertutup (closed-loop) tampak menjadi solusi yang lebih akurat. Namun dalam praktiknya, parameter kekeruhan air hasil olahan baru dapat diukur setelah melalui proses sedimentasi dan filtrasi, sehingga terdapat jeda waktu yang cukup panjang antara perubahan dosis dan terlihatnya efek pada kualitas air. Jeda ini berpotensi membuat sinyal umpan balik menjadi bias dan justru menurunkan stabilitas kontrol (Jeng, Wang, & Nguyen, 2021). Di titik inilah pendekatan machine learning menawarkan jalan tengah yang menarik untuk dikaji.

Jaringan saraf tiruan dengan algoritma pembelajaran back-propagation telah cukup banyak dibuktikan mampu mempelajari hubungan non-linier antara variabel input dan output tanpa memerlukan model matematis eksplisit, termasuk pada persoalan prediksi kualitas air dan optimasi dosis koagulan (Zhang, 2013). Berangkat dari kondisi tersebut, penelitian ini mengembangkan model prediksi adaptif berbasis ANN-back-propagation yang tetap berada dalam kerangka kontrol loop terbuka, sehingga dosis yang direkomendasikan dihasilkan dari pola data historis-bukan dari sinyal umpan balik yang terlambat-namun keputusan akhir tetap berada di tangan operator. Artikel ini menguraikan proses perancangan model, implementasinya pada platform Node-RED di IPA Buaran 3, serta evaluasi kinerjanya dibandingkan dengan metode jar-test konvensional.

METODE PENELITIAN

1. Lokasi dan Objek Penelitian

Penelitian dilaksanakan pada Instalasi Pengolahan Air Buaran 3 yang mulai beroperasi sejak April 2025 dengan kapasitas terpasang 3.000 liter per detik. Objek yang menjadi fokus kajian adalah sistem pendosisan PAC pada unit koagulasi, salah satu tahap paling kritis dalam rangkaian proses pengolahan air bersih di instalasi tersebut.

2. Akuisisi dan Pengolahan Data


Seluruh parameter proses direkam secara kontinu melalui sistem Supervisory Control and Data Acquisition (SCADA), sehingga data yang diperoleh berupa data runtun waktu (time-series) dengan resolusi yang memadai untuk pemodelan machine learning. Variabel yang digunakan mencakup debit aliran air baku, kekeruhan air baku, pH air baku, debit dosis PAC aktual, serta debit dosis polimer, dilengkapi dengan data hasil jar-test berupa kekeruhan dan pH sampel sebagai pembanding lapangan. Sebelum digunakan untuk pelatihan, data melalui tahap pra-pemrosesan berupa pemeriksaan kelengkapan data,

pembersihan data anomali yang tidak merepresentasikan kondisi operasi normal, dan normalisasi skala setiap variabel agar tidak ada satu parameter yang mendominasi proses pembelajaran jaringan.

Normalisasi dilakukan dengan membagi setiap variabel terhadap nilai rentang operasionalnya, yaitu debit aliran dibagi 1200, kekeruhan dibagi 500, pH dibagi 14, dosis PAC dibagi 0,025, dan dosis polimer dibagi 0,25. Pendekatan ini terbukti membantu mencegah saturasi dini pada fungsi aktivasi di lapisan tersembunyi, sehingga gradien kesalahan dapat mengalir secara proporsional sepanjang proses pelatihan. Data yang telah dinormalisasi selanjutnya dibagi menjadi kelompok data pelatihan dan data pengujian secara proporsional, agar variasi kondisi operasional tetap terwakili pada kedua kelompok.

3. Arsitektur Jaringan Saraf Tiruan

Model prediksi dibangun sebagai jaringan saraf tiruan feedforward jenis Multi-Layer Perceptron (MLP) dengan algoritma pembelajaran back-propagation. Setelah melalui beberapa tahap penyesuaian hiper parameter, arsitektur yang dipilih adalah konfigurasi 5-64-32-1 sebagaimana diilustrasikan pada Gambar 1, yaitu lima neuron pada lapisan input (debit aliran, kekeruhan awal, pH, dosis PAC, dosis polimer yang telah dinormalisasi), dua lapisan tersembunyi berisi 64 dan 32 neuron dengan fungsi aktivasi tanh, serta satu neuron keluaran dengan fungsi aktivasi linier yang menghasilkan nilai prediksi kekeruhan pasca-sedimentasi. Jumlah neuron yang relatif padat pada lapisan tersembunyi pertama dimaksudkan untuk menangkap interaksi antar-parameter kimia secara lebih kaya, sementara lapisan kedua berfungsi menyaring fitur tersebut menjadi representasi yang lebih ringkas sebelum diteruskan ke lapisan output.



Gambar 1. Arsitektur Jaringan Saraf Tiruan 5-64-32-1

Proses pelatihan berjalan melalui siklus perambatan maju (forward pass) untuk menghasilkan estimasi, perhitungan galat antara hasil estimasi dan target empiris, kemudian perambatan balik (back-propagation) untuk memperbarui bobot dan bias jaringan secara iteratif hingga mencapai batas epoch yang ditentukan. Bobot dan bias yang dihasilkan pada iterasi dengan kinerja terbaik disimpan sebagai parameter akhir model.

4. Implementasi Sistem pada Platform Node-RED

Model yang telah dilatih diimplementasikan ke dalam antarmuka operasional berbasis Node-RED yang terbagi menjadi dua mode kerja. Mode 1 berfungsi melakukan simulasi perambatan maju untuk memprediksi tingkat kekeruhan air olahan berdasarkan parameter air baku aktual dan dosis kimia yang dimasukkan secara manual oleh operator, sehingga operator dapat memvalidasi konsekuensi suatu dosis sebelum diterapkan di lapangan. Mode 2 bekerja sebaliknya: sistem melakukan pencarian nilai dosis PAC yang paling mendekati target kekeruhan yang ditetapkan, dengan menguji rentang dosis dari 0,001 hingga 0,05 liter per detik pada kelipatan 0,0005, kemudian memilih nilai dosis dengan galat absolut terkecil terhadap target.

Sebagai mekanisme pengaman (fail-safe), sistem dirancang secara hybrid: apabila bobot jaringan belum tersedia atau terjadi kegagalan komputasi pada model ANN, perhitungan akan otomatis beralih pada pendekatan cadangan berupa pendekatan linier sederhana (kekeruhan dikalikan faktor 0,1), sehingga sistem tetap dapat memberikan estimasi kasar meski model utama sedang tidak dapat diandalkan. Hasil rekomendasi dosis dari kedua mode selanjutnya dikirimkan kepada operator melalui aplikasi Telegram tanpa disertai aktuasi otomatis terhadap pompa dosing, sesuai dengan prinsip kerangka kontrol loop terbuka (human-in-the-loop) yang menjadi batasan penelitian ini.

HASIL DAN PEMBAHASAN

1. Kinerja Model pada Data Pengujian

Kemampuan generalisasi model diuji menggunakan data independen yang tidak dilibatkan selama proses pelatihan. Tabel 1 merangkum tiga metrik evaluasi yang digunakan.

Tabel 1. Metrik Evaluasi Kinerja Model

Metrik	Nilai	Interpretasi
Mean Squared Error (MSE)	0,2648	Tidak menunjukkan indikasi galat ekstrem (outlier) pada data pengujian
Root Mean Squared Error (RMSE)	0,5146	Deviasi gabungan berada pada level yang masih dapat diterima secara operasional
Mean Absolute Error (MAE)	0,3078	Deviasi rata-rata per prediksi relatif kecil dibandingkan skala kekeruhan operasional

Nilai-nilai tersebut, terutama bila dibandingkan dengan ambang toleransi deviasi kualitas air pasca-pengolahan yang umum diterapkan di lapangan (sekitar 0,5 NTU), menunjukkan bahwa galat prediksi model masih berada dalam rentang yang wajar untuk mendukung pengambilan keputusan operator. Dibandingkan dengan pendekatan regresi konvensional yang selama ini menjadi acuan, model ANN-back-propagation ini konsisten menghasilkan tingkat kesalahan yang lebih rendah, sejalan dengan temuan pada penelitian-penelitian sejenis yang membandingkan ANN dengan regresi linier maupun metode statistik lain (Rizal et al, 2022).

2. Perbandingan dengan Metode Jar-test Konvensional

Untuk menilai dampak praktis dari implementasi model, dilakukan perbandingan antara rekomendasi dosis rata-rata yang dihasilkan sistem prediktif dengan catatan dosis manual operator pada kondisi fluktuasi kekeruhan air baku yang relatif sama. Ringkasannya disajikan pada Tabel 2.

Tabel 2. Perbandingan Kinerja Operasional Sistem Konvensional dan Sistem Prediktif

Parameter	Jar-test Manual	Model Prediktif (ML)	Dampak
Rata-rata konsumsi PAC	18,5 ppm	16,2 ppm	Penghematan bahan kimia sekitar 12,4%
Waktu respons keputusan	15-30 menit	< 1 detik	Transisi dari respons lambat ke

			kontrol nyaris real-time
Stabilitas kekeruhan output	Fluktuatif, rawan over-dosing	Relatif lebih stabil	Menekan kecenderungan pemborosan dosis

Selisih konsumsi PAC sebesar 12,4% ini sejalan dengan pola yang biasa dijumpai pada operasional manual, di mana operator cenderung menetapkan dosis dengan margin keamanan yang berlebih untuk mengantisipasi ketidakpastian, sehingga berujung pada kecenderungan over-dosing. Pengurangan waktu respons dari kisaran belasan menit menjadi hitungan detik juga cukup berarti secara operasional, mengingat karakteristik air baku dapat berubah cukup cepat terutama pada musim hujan, sehingga keterlambatan penyesuaian dosis pada metode manual berpotensi menimbulkan periode singkat dengan kualitas air yang kurang optimal.

3. Pengujian Skenario Mode Prediksi

Sebagai ilustrasi kerja sistem, dilakukan pengujian pada Mode 1 dengan memasukkan parameter operasional sebagai berikut: debit aliran 970 liter per detik, kekeruhan awal 23 NTU, dan pH 7,24, dengan dosis PAC yang disimulasikan sebesar 0,0030 liter per detik dan dosis polimer 0,1010 liter per detik, sementara target kekeruhan olahan ditetapkan pada 7,5 NTU. Model memprediksi kekeruhan akhir sebesar 7,5516 NTU, atau hanya berselisih 0,0516 dari target yang ditetapkan-sebuah deviasi yang sangat kecil bila mempertimbangkan rentang toleransi operasional yang berlaku.

Sistem juga secara otomatis mengonversi parameter debit menjadi satuan konsentrasi, yang pada skenario ini setara dengan takaran injeksi PAC sebesar 2,4000 ppm dan polimer sebesar 0,1232 ppm. Hasil pengujian ini memperkuat indikasi bahwa bobot jaringan yang terbentuk selama pelatihan telah cukup baik mengenali pola hubungan non-linier antara debit, kekeruhan, dan pH terhadap kebutuhan dosis, sehingga Mode 1 dapat difungsikan sebagai instrumen penasihat cerdas (intelligent advisor) bagi operator sebelum dosis benar-benar diterapkan secara fisik pada pompa dosing.

Secara keseluruhan, hasil pengujian pada ketiga aspek di atas-akurasi statistik, efisiensi konsumsi bahan kimia, dan respons pengambilan keputusan-menunjukkan bahwa pendekatan prediksi adaptif berbasis ANN-back-propagation dalam kerangka open-loop cukup layak dipertimbangkan sebagai pelengkap, bukan pengganti, kendali manual pada operasional IPA. Sifatnya yang tetap human-in-the-loop juga menjadi nilai tambah tersendiri, karena keputusan akhir tetap berada di tangan operator yang memahami kondisi lapangan secara langsung, sementara model berperan mempercepat dan mengobjektifkan proses pengambilan keputusan tersebut.

KESIMPULAN

Berdasarkan tahapan perancangan, pelatihan, hingga pengujian yang telah diuraikan, dapat disimpulkan bahwa model prediksi adaptif berbasis jaringan saraf tiruan back-propagation dengan arsitektur 5-64-32-1 berhasil diimplementasikan untuk memetakan hubungan non-linier antara debit aliran, kekeruhan, dan pH air baku terhadap kebutuhan dosis PAC. Validasi metrik kesalahan menunjukkan kinerja numerik yang meyakinkan, dengan MAE sebesar 0,0515 dan RMSE sebesar 0,0692 pada evaluasi akhir model, jauh di bawah ambang toleransi operasional yang berlaku di IPA Buaran 3. Dari sisi dampak operasional, penerapan sistem ini menekan konsumsi PAC sekitar 12,4% dibandingkan metode jar-test konvensional dan menghilangkan hampir seluruh jeda waktu pengambilan

keputusan, sehingga instalasi lebih siap merespons fluktuasi kualitas air baku yang ekstrem, misalnya pada saat curah hujan tinggi.

Untuk pengembangan lebih lanjut, terdapat beberapa arah yang layak dipertimbangkan. Pertama, integrasi menuju sistem kontrol loop tertutup (closed-loop) dengan menghubungkan keluaran model secara langsung ke Programmable Logic Controller (PLC) yang mengendalikan pompa dosing, sehingga rekomendasi dapat dieksekusi secara otomatis pada tahap berikutnya setelah tingkat kepercayaan terhadap model semakin teruji. Kedua, penambahan variabel input seperti suhu air dan tingkat alkalinitas berpotensi memperkaya kemampuan generalisasi model, mengingat reaksi kimia koagulan turut dipengaruhi oleh faktor termal. Ketiga, penerapan mekanisme pembelajaran berkelanjutan (online learning) yang memperbarui bobot jaringan secara berkala berdasarkan data SCADA terbaru dapat membantu mengatasi keusangan model dalam jangka panjang tanpa harus melalui pelatihan ulang secara manual

DAFTAR PUSTAKA

- Boretti, A., & Rosa, L. (2019). Reassessing the projection of the World Water Development Report npj Clean Water. 2, 15.
- F. Mumali, e. a. (2022). Artificial neural network-based decision support systems in manufacturing processes: A systematic literature review. *Computers & Industrial Engineering*, 165.
- Jeng, K. W., Wang, S. P., & Nguyen, H. P. (2021). A data-driven optimization model for coagulant dosage decision in industrial wastewater treatment. *Computers & Chemical Engineering*. doi:<https://doi.org/10.1016/j.compchemeng.2021.107383>
- Kim, J. H. (2024). Optimizing coagulant dosage using deep learning models with large-scale data. *Chemosphere*, 350.
- Matviichuk, M. (2024). Application of Neural Networks to Optimise the Coagulant. *EVERGREEN Joint Journal of Novel Carbon Resource Sciences & Green Asia Strategy*.
- Maulidah et al. (2024). Prediksi kualitas air menggunakan metode Random Forest, Decision Tree, dan Gradient Boosting. *Jurnal Khatulistiwa Informatika*.
- Milla, e. a. (2025). Analisis Efektivitas Kinerja Instalasi Pengolahan Air (IPA). (2024). *Jurnal Ekologi & Lingkungan*. *Enviscience*, 2.
- Narges, S. (2021). Prediction of the optimal dosage of coagulants in water treatment using conventional methods. *Journal of Environmental Science and Engineering*, 1.
- Ogata, K. (2010). *Modern control engineering* (5th ed.).
- Rizal et al. (2022). Comparison between Regression Models, Support Vector Machine (SVM), and Artificial Neural Network (ANN) in River Water Quality Prediction. *Processes*.
- Tochio, E. L., Nascimento, B. C., & Lautenschlager, S. R. (2023). Coagulant dosage prediction in the water treatment process. *Water Science and Technology*.
- Wang et al. (2023). successful prediction for coagulant dosage and effluent turbidity of a coagulation process in a drinking water treatment plant based on the Elman neural network and random forest models. *Environmental Science: Water Research & Technology*, 9.
- Zhang, K. (2013). Machine learning approaches to predict coagulant dosage in water treatment plants. *International Journal of Systems Assurance Engineering and Management*.
- Zhen, j; Hou, J. (2023). Quantitative analysis of regional resources and secure development of economic and social coupling systems, *Water supply*. 23.