

〈研究発表〉

下水処理場における AI 予測モデルの自動制御への適用

藤 原 翔¹⁾, 平 林 和 也²⁾, 山 本 明 広³⁾, 糸 川 浩 紀⁴⁾

¹⁾ 安川オートメーション・ドライブ(株) システム技術本部
(〒141-0032 東京都品川区大崎1-11-1 ゲートシティウエストタワー 7F
E-mail: sho.fujiwara@yaskawa.co.jp)

²⁾ 安川オートメーション・ドライブ(株) システム技術本部
(〒141-0032 東京都品川区大崎1-11-1 ゲートシティウエストタワー 7F
E-mail: kazuya.hirabayashi@yaskawa.co.jp)

³⁾ 日本下水道事業団 技術開発室
(〒113-0034 東京都文京区湯島2-31-27 湯島台ビル E-mail: yamamotoa@jswa.go.jp)

⁴⁾ 日本下水道事業団 技術開発室
(〒113-0034 東京都文京区湯島2-31-27 湯島台ビル E-mail: itokawah@jswa.go.jp)

概 要

下水処理場の運転管理に係る職員の減少や技術継承などの対策が課題となっている。筆者らはこの課題を解決する方法として AI 技術に着目し、AI の予測アルゴリズムの1つであるランダムフォレスト法を用いて水処理の制御設定値を予測する「水処理制御支援システム」を開発した。本研究では、この支援システムをパイロット規模の実験プラントに実装し、曝気風量の予測値をリアルタイムに操作量として返す自動制御運転を行った結果を基に、AI モデルによる自動制御の適用性を評価した。

キーワード：人工知能、自動制御、曝気風量、ランダムフォレスト

原稿受付 2022.7.22

EICA: 27(2・3) 19-22

1. は じ め に

昨今、下水処理事業に係る職員数減少やそれに伴う技術継承問題などへの対策が課題となっている。筆者らはこの課題の解決方法の1つとして、AI のアルゴリズムであるランダムフォレスト法¹⁾を用いて水処理の制御設定値を予測し、運転支援を行う水処理制御支援技術²⁾を B-DASH プロジェクトで提案し、システムの開発を行ってきた。本稿では、このシステムを活性汚泥法のパイロットプラントに実装し、AI から出力された予測値をリアルタイムの操作量として曝気風量の自動制御を行う「AI 自動制御」の試行により、その制御特性などについて得られた結果を報告する。

2. 実 験 方 法

2.1 実験プラント

本実験は、2系列からなる活性汚泥法のパイロットプラント(処理能力: 約 50 m³/(d・系列))で行った。反応タンクは等容量の4区画に分割されており、第1区画を嫌気、残りの3区画を好気(風量は等量分配)として運転した。2系列のうち1系を AI 制御系、2系を対照系とし、AI 制御系の学習期間と対照系の全期間では共に DO 濃度目標値 1.0 mg/L の DO 一定制

御で運転した。本プラントで使用した実験原水は隣接する下水処理場の実下水(初沈越流水)である。

2.2 収集データ

実験プラントの各系列においてオンラインで自動収集した計測データは、流入水量、曝気風量、反応タンク第4区画の DO 濃度と MLSS 濃度、返送汚泥濃度および流量、引抜汚泥濃度および流量、積算引抜汚泥量、電力使用量の各10項目である。これらのデータはコントローラを経由して、AI のモデル生成用データベースに5分周期で保存した。このとき、DO 濃度、MLSS 濃度、返送汚泥濃度および引抜汚泥濃度については5分間の平均値、電力使用量は積算値で、その他は全て瞬時値である。以降の検討ではこの5分周期データを用い、AI のモデル生成や予測を実施した。

2.3 オフラインでの AI モデル構築による精度検証

曝気風量の予測アルゴリズムにはランダムフォレスト法を用いた。本手法の特長は、入力信号のノイズに強く安定的に予測値を出力できることや、モデル生成時に「重要度」という係数により計測データ項目ごとの予測値への影響度が確認できることである。

AI の学習に使用する教師データは 2021/6/1 ~ 2021/8/31 の3か月間、精度検証データは 2021/9/1 ~ 2021/

9/16 の 16 日間のデータを使用した。また、教師データ期間と検証データ期間のプラントへの流入水量は、2021/6/1 ～ 2021/6/28 では一定流入 ($40 \text{ m}^3/\text{d}$)、以降は入力データに多様性を持たせるため、Fig. 1 に示す流入パターンの内、パターン 1 による時間変動 (日量として $50 \text{ m}^3/\text{d}$) を与えた。

ランダムフォレストのパラメータとして、決定木の本数を 10, 50, 100, 500, 階層を 3, 5, 10, 20 の各 4 通りの組合せで計 16 個の AI モデルを生成した。また、この中から精度検証データにおける曝気風量の予測値が実績値を下回る条件の発生割合が最小となるパラメータを選択し、以降の実験で使用するものとした。具体的には、実測値に対する予測誤差率を計算し、 -10% 超となる予測値の割合が最小となるパラメータを選択した。ここで、誤差率 -10% としたのは B-DASH プロジェクト開始時の維持管理者へのヒアリングにて許容可能な誤差率が 10% 程度だったためである。また、下振れの誤差のみを対象としたのは曝気風量の予測値が実績値に対し 10% 未満である場合、曝気風量不足によりプラントの活性汚泥処理に悪影響を及ぼす恐れがあると考えたためである。なお、送風機の実用上限値は $0.5 \text{ Nm}^3/\text{min}$ であるため、1, 2 系どちらかがこれと一致した時間帯は誤差率の算定から除外した。

2.4 オンラインでの AI の予測値を適用した曝気風量制御検証

2.3 で見出したパラメータと 2021/6/1 以降のデータを用いて、2022/11/1 ～ 2022/12/3 の期間で、曝気風量の自動制御運転を行った。また、AI のモデルは週 1 回、最新の 1 週間分のデータを追加して更新した。このモデルを用いて、5 分周期で曝気風量の設定値をオンラインで予測し、この予測値を制御設定値として曝気風量を制御した。このときのプラントへの流入水量は既に学習済みの Fig. 1 の流入パターン 1 以外に、12:00 ～ 20:00 の流入水量を 1.3 倍に増加させて日量

を $54 \text{ m}^3/\text{d}$ とした流入パターン 2, 2:00 ～ 7:00 の流入水量を 0.8 倍に減少させて日量を $47 \text{ m}^3/\text{d}$ とした流入パターン 3 を設定し、週毎に切り替えた。流入パターン 2, 3 の上述以外の時間帯は流入パターン 1 と同一である。

検証は流入水量のパターンを 1 ～ 3 に変更した場合の、AI 制御系と対照系の DO 濃度の平均値と標準偏差を比較することで行った。

3. 結果と考察

3.1 オフラインでの AI モデル構築による精度検証

決定木本数と階層を総当たりで検証した結果、検証データ期間における誤差率 10% の超過割合が最小となる組合せは、決定木本数 100, 階層 10 の場合となった。このときの予測結果を 1 日分抽出して Fig. 2 に示す。検証データ期間での誤差率の平均は 3.31% と、曝気風量の実績値に対し、予測値がほぼ同様の変化をしていることが確認できることから、本パラメータで AI モデルを生成することで、DO 一定制御を模倣した曝気風量の自動制御が可能であると推測された。

3.2 AI の予測値を適用した曝気風量制御検証

(1) 流入パターン 1 での検証

流入パターン 1 での AI 曝気風量制御を実施した結果を Fig. 3 に示す。AI 制御系において DO 濃度が過剰に上昇・減少するような現象は発生せず、DO 濃度の平均値は 1.01 mg/L 、標準偏差は 0.14 mg/L となった。対照系の DO 濃度の平均値は 0.98 mg/L 、標準偏差は 0.23 mg/L となっており、流入パターン 1 においては DO 一定制御を模倣した制御ができていることが確認できた。

(2) 流入パターン 2 での AI 曝気風量制御検証

流入パターン 2 での AI 曝気風量制御を実施した結果を Fig. 4 に示す。AI 制御系において DO 濃度が過




Fig. 1 Inflow patterns in test plant




Fig. 2 Predicted and measured airflow rates in the train No.1




Fig. 3 Transition of airflow rate and DO concentration under the inflow pattern 1




Fig. 4 Airflow and DO of a time-series relation graph in sewage inflow pattern 2

剰に上昇・減少するような現象は発生せず、AI制御系のDO濃度の平均値は0.97 mg/L、標準偏差は0.16 mg/Lとなり、対照系のDO濃度の平均値は0.93 mg/L、標準偏差は0.17 mg/LとDO一定制御を模倣できていることが確認できた。教師データとは異なる流入パターンであっても制御が可能だったのは、流入水量

以外のその他項目から必要風量が予測できたためであると推測される。

(3) 流入パターン3でのAI曝気風量制御検証

流入パターン3でのAI曝気風量制御を実施した結果をFig.5に示す。本期間では、流入パターン1, 2では見られなかったDO濃度が過剰に上昇する現象が




Fig. 5 Airflow and DO of a time-series relation graph in sewage inflow pattern 3

AI 制御系において複数回発生した。これにより AI 制御系の DO 濃度の平均値は 1.13 mg/L、標準偏差は 0.42 mg/L となり、対照系の DO 濃度（平均値 1.00 mg/L、標準偏差 0.07 mg/L）と比較すると AI 制御系の DO 濃度のばらつきが大きい結果となった。流入水量が減少した時間帯に DO 濃度が上昇していることから過曝気になったためと推測されるが、同時時間帯の対照系では DO 濃度は上昇していない。曝気風量を確認すると同時時間帯の対照系の曝気風量が $0.25 \text{ Nm}^3/\text{min}$ 程度まで低下しているにもかかわらず、AI 制御系では $0.28 \text{ Nm}^3/\text{min}$ 程度で下げ止まっていることから、AI の制御方法に起因する現象の可能性が考えられた。

以上の実験結果から、流入変動があった場合でも、一部の条件を除いて大幅な DO 濃度の逸脱がなかったことから、AI を活用した自動曝気風量制御はおおむね可能であると確認された。一方で、DO 濃度に大幅な超過が見られた期間については、これらの原因と対処方法について追加検討が必要である。

4. ま と め

AI を用いた自動制御の適用可能性について、ランダムフォレスト法を用いた曝気風量の AI 自動制御をパイロットプラントに実装し、自動制御の特性等に関

する実験を行った。DO 一定制御での運転を学習した AI モデルにより、目標 DO 濃度 1.0 mg/L の制御を模倣する制御を実施し、流入パターンによっては自動制御が可能であることが確認された。一方で、流入パターン 3 で発生したような AI の制御方法に起因すると推測される DO 濃度の上昇する現象が発生したことから、今後これらの原因追究と対処方法の検討を実施すると共に、曝気風量以外の操作因子への適用も検討していく。

参 考 文 献

- 1) Breiman, L.: Random forests, Machine Learning, Vol. 45, pp. 5-32 (2001)
- 2) 藤原翔, 平林和也, 大場正隆, 綿引綾一郎, 石川進, 張亮, グェンタンフォン, 糸川浩紀, 山下洋正, 矢本貴俊: AI を活用した水処理制御支援技術による処理場運転管理設定値の予測誤差の検証, 第 56 回下水道研究発表会講演集, pp. 1016-1018 (2019)