

〈研究発表〉

AIの予測値を用いた自動曝気風量制御の特徴解析

藤原 翔¹⁾, 平林 和也²⁾, 糸川 浩紀³⁾, 山本 明広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
(〒824-8511 福岡県行橋市西宮市2-13-1 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
(〒824-8511 福岡県行橋市西宮市2-13-1 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:itokawah@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:yamamotoa@jswa.go.jp)

概要

下水処理場の運転管理に携わる職員の減少による運転管理ノウハウの継承などが問題となっている。本報では標準活性汚泥法のテストプラントに筆者らの開発した曝気風量のAI自動制御を適用し、教師データとしたDO一定制御(PID制御)の運転時と異なる流入水量の時間変動を与えた場合の挙動を解析した結果を報告する。曝気風量の予測値が下げ止まった箇所では未学習の影響と考えられる挙動があったが、送風機能力の下限まで低下した箇所では未学習ではなく、プラント停止期間のデータの影響を受けていたことが確認された。

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 2024.7.1

EICA: 29(2・3) 19-23

1. はじめに

下水処理場では運転管理に携わる職員数の減少やノウハウなどの継承に関する課題の対策が必要となっている。筆者らはこの課題の解決方法の1つとして、B-DASHプロジェクト¹⁾にて、ランダムフォレスト²⁾というAIのアルゴリズムを適用した下水処理場の制御設定値の推奨値を予測しガイダンスを行う「水処理制御支援技術³⁾」を開発した。既報⁴⁾にて、パイロットスケールの標準活性汚泥法の実験プラントを用い、本ガイダンス値をSV(設定値)に適用した曝気風量の自動制御(AI自動制御)が可能であったことを報告している。しかしながら、AIは教師データを基に予測する性質上、教師データ範囲の上限を上回ったあるいは下限を下回った領域での予測が困難である。よって、教師データ範囲外となる条件を未学習条件と定義し、この未学習条件下で本ガイダンス値による曝気風量の自動制御を行った際の挙動を確認する実験を行った。本報では教師データに含まれない実験プラントの流入水量の時間変動パターンを与えた場合を未学習条件として、曝気風量のAI自動制御で生じる特徴について解析を行った結果を報告する。

2. 実験方法

2.1 実験プラント

実験で使用したのは約50 m³/dの処理能力を持つ標準活性汚泥法のパイロットプラントである。反応タンクは等容量の4区画で、第1区画を嫌気、残りの3区画を好気で運転し、風量は好気の3区画で等量配分した。また、実験原水は隣接する分流式の下水処理場の初沈越流水を使用した。

2.2 検討の手順

今回の実験は連続した約3週間でいった。まず、2023/6/28~2023/7/11の2週間、DO一定制御(目標値:1.0 mg/L)で運転し、これを教師データとして、AIの予測モデルの生成を行った。続いて7/12 12:00~7/18 12:00の6日間で未学習条件下におけるAIの予測モデルによる曝気風量の自動制御を行った。ここで、未学習条件とは24時間流入水量一定である教師データに対して、午後から夜間の流入水量を減少させた時間変動パターンのこととした。教師データと未学習条件での時間変動パターンはFig. 1の通りである。

また、この実験での曝気風量制御結果を、(a) DO濃度の実験期間の平均値と標準偏差、(b)現在のDO濃度に対するAIの予測値が適正であった割合(以下、

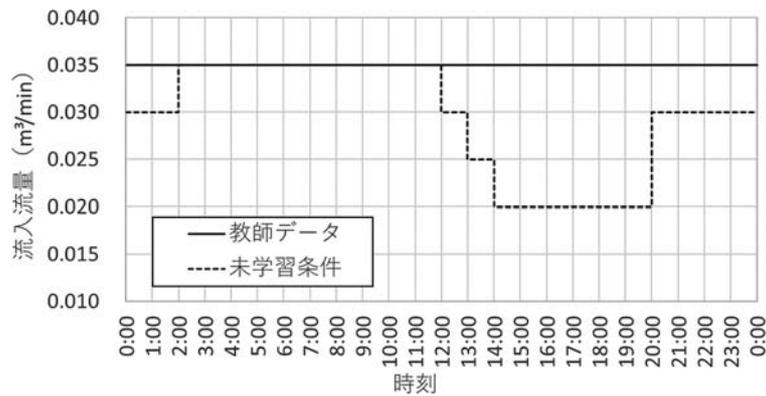


Fig. 1 Diurnal patterns of inflow in test plant

「適正制御割合」), の2つの指標で確認した。適正制御割合とは DO 濃度が 1.0 ± 0.2 mg/L を逸脱した範囲の制御において, 制御の良否確認を行うために導入した概念である。この概念は AI の予測モデルに入力された DO 濃度を基準に, AI により曝気風量の増減が適切に行われた割合である。具体的には, DO 一定制御 (目標 DO 濃度 1.0 mg/L) で運転した際の DO 濃度の変動実績から, DO 濃度が 1.0 ± 0.2 mg/L の範囲内での制御出力は全て適正とし, 加えてこの範囲を外れた DO 濃度となった場合に, 曝気風量が DO 濃度 1.0 mg/L に近づく方向に変化していれば適正とした。なお, 曝気風量が送風機能力の上下限 (約 $0.25 \sim 0.50$ m³/min) に達し, 制御外となった期間は判断の対象外とした。

2.3 教師データの収集

AI の予測モデルの生成で使用する教師データ取得のために, 曝気風量制御に DO 一定制御 (PID 制御) を適用して実験プラントの運転を行った。教師データとして, 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, 余剰汚泥引抜汚泥濃度および流量, 積算引抜汚泥量, 電力使用量の 10 項目を全てオンラインで収集した。これらのデータはコントローラを経由して, AI のモデル構築用データベースに 5 分周期で保存した。ここで, 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, 電力使用量および積算引抜汚泥量は 5 分間の積算値, その他は全て瞬時値である。以降の検討ではこのデータベースに保存した 5 分周期のデータを用い, AI の予測モデルの構築を実施した。

2.4 未学習条件下の AI の予測モデルによる自動制御

(1) 予測モデルの構築

AI の予測モデルの構築条件は **Table 1** の通りである。教師データ期間では, 反応タンクへの流入水量を 0.035 m³/min で時間変動なしで一定 (日量 50.4 m³/d)

Table 1 Generation conditions for AI model

項目	条件	
教師データ	流入水量	50.4 m ³ /日 (0.035 m ³ /min で 時間変動なし)
	曝気運転	DO 一定制御 (目標 DO 濃度: 1 mg/L)
	データ収集期間	2023/6/28~2023/7/11 (14 日間)
ランダムフォレスト パラメータ	決定木本数	100
	階層数	10

とし, 目標 DO 濃度 1.0 mg/L の DO 一定制御で実験プラントを運転した。なお, コントローラから収集した流入水量の PV (測定値) は ± 0.001 m³/min 程度の変動が発生していた。教師データ期間は 2023/6/28~2023/7/11 までの 14 日間で, ランダムフォレストパラメータの決定木の本数と階層数は, これまでの実験⁴⁾と同様に 100 本, 10 階層で固定した。

(2) 予測モデルによる自動制御方法

構築したモデルによる AI 自動制御は **Fig. 1** の未学習条件の流入パターンを用い, 前記収集データの 10 項目のリアルタイムデータを 5 分間隔で AI の予測モデルに入力して, 出力された予測値を送風機の SV として曝気風量を制御した。この SV は 5 分間固定値で継続し, 5 分後に AI の予測モデルが新たに出力した予測値に更新される。

3. 結果と考察

3.1 教師データ期間の DO 一定制御結果

DO 一定制御での曝気風量制御結果は **Fig. 2** の通りである。教師データ期間において各指標の値は, DO 濃度: 0.99 ± 0.10 mg/L (平均値 \pm 標準偏差: 以下同様), 適正制御割合: 93.0% (全データ件数: 4,033 件, 適正制御データ件数: 3,370 件), となった。DO の平均値は目標値の 1 mg/L と概ね等しくなったが, 標準偏差は DO 濃度の目標値に対して 10% 程度となった。これは 6/28~7/1 の DO 濃度の超過や 7/6, 7/10 の DO 濃度の低下によるが, これらは実験プラントの送

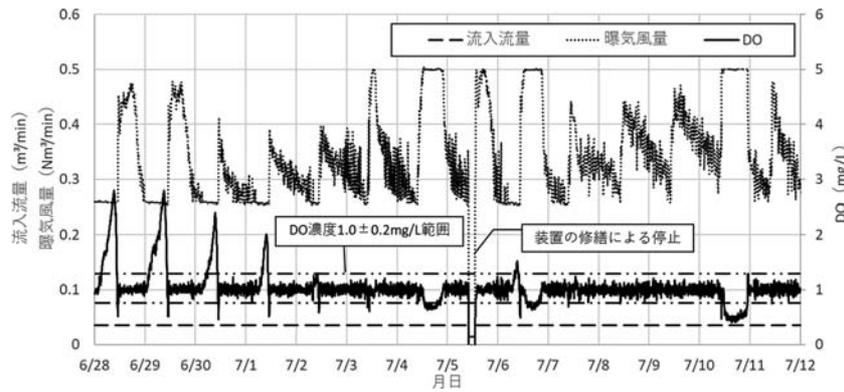


Fig. 2 Transition of inflow rate, airflow rate, and DO concentration in constant DO control operation

風機能力の上下限に達しているため、DO濃度を適切に保てなかったことによると考えられる。

また、7/5に流入水量および曝気風量が一時的にゼロ(10:05~13:00)になっているが、これは装置の修繕で運転を停止したことによるものである。AIの予測モデルはこれらのDO濃度が 1.0 ± 0.2 mg/Lを逸脱した期間や修繕による停止期間も含むデータを用いて構築した。

3.2 未学習条件下におけるAI自動制御の結果

未学習条件下におけるAI自動制御での曝気風量制御結果はFig. 3の通りである。実験期間において各指標の値は、DO濃度： 1.15 ± 0.36 mg/L、適正制御割合：84.0% (全データ件数：1,728件、適正制御データ件数：1,364件)、となった。DO濃度の平均値、標準偏差共に教師データと乖離した主たる原因は、流入水量を減少させた時間帯のDO濃度の上昇であると考えられた。

また、適正制御割合も教師データより約10ポイント低くなった。不適正な制御となった場合のデータを確認すると、0.8 mg/Lを下回った場合のデータ数が46件、1.2 mg/Lを上回った場合のデータ数が214件と、DO濃度が超過した場合に多く発生していることから、前述のDO濃度超過時の影響が大きいことが確認された。

3.3 AI自動制御特有の挙動の解析

未学習条件下でのAI自動制御について、AIの自動制御で特徴的な挙動を示した部分として、Fig. 3の(1)目標DO濃度超過時に送風能力下限とならない箇所、(2)一度曝気風量の減少が停止した後に再度減少した箇所、について確認した。

(1) 目標DO濃度超過時に送風能力下限とならない箇所

Fig. 2の教師データであるDO一定制御では6/28~7/1のDO濃度超過時、速やかに曝気風量が送風機能力の下限値である 0.25 m³/min付近まで減少していることが確認できる。一方でFig. 3の、例えば7/14 1:00頃のAI自動制御では同様のDO濃度超過が発生した場合、 0.267 m³/min付近までしか減少していない。Fig. 4の2023/7/14 1:00における各決定木が出力した曝気風量のヒストグラムを確認すると、 $0.265 \sim 0.269$ m³/minの範囲の予測値を出力した決定木が100本中53本となった。また、各決定木の予測値で $0.255 \sim 0.259$ m³/minを出力した本数は3本と少ないことが確認された。つまり、一部の決定木の予測値による影響ではなく、各決定木が概ね最終的な予測値と近い予測値を出力していることが確認された。

上記結果の原因が未学習条件による影響であるか調査するため、流入水量が 0.035 ± 0.001 m³/minのときの制御性能とそれ以下の流入水量でのDO濃度の平均値、標準偏差や適正制御割合が変化するか確認した。

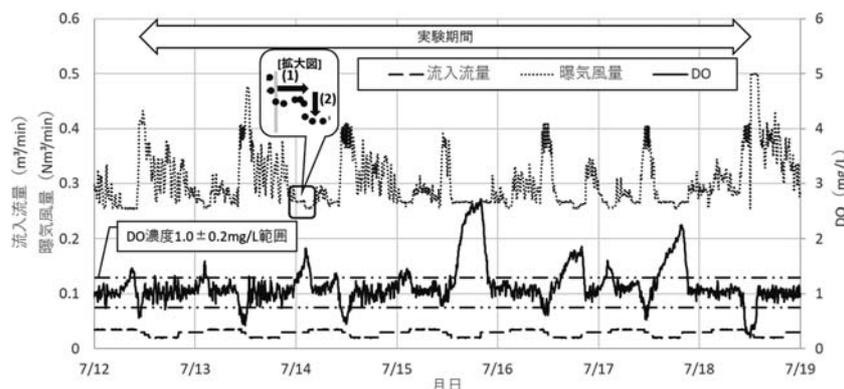


Fig. 3 Transition of inflow rate, airflow rate, and DO concentration in AI-based control operation

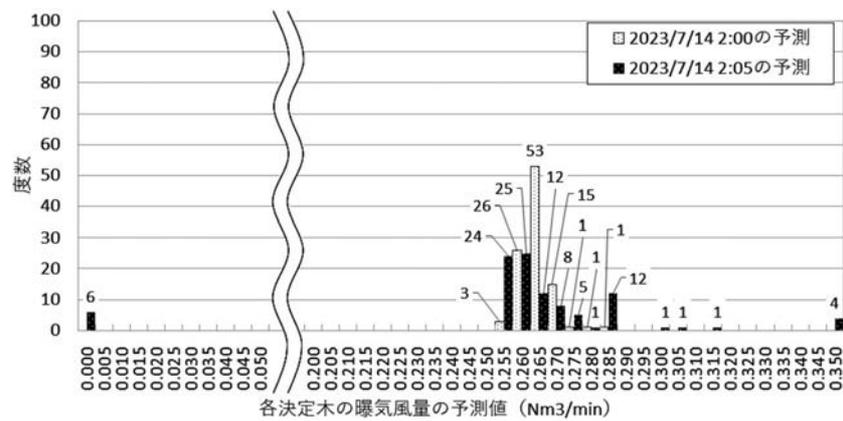


Fig. 4 Histogram of predicted airflow rate at each decision tree at 2:00 and 2:05 on 2023/7/14

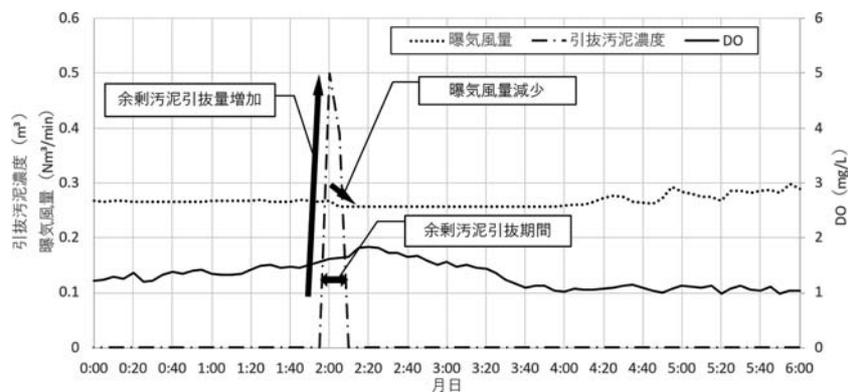


Fig. 5 Transition of waste activated sludge concentration, airflow rate, and DO concentration in automatic control of airflow rate by AI in 2023/7/14

まず、流入水量が $0.035 \pm 0.001 \text{ m}^3/\text{min}$ のときの DO 濃度の平均と標準偏差は $1.06 \pm 0.13 \text{ mg/L}$ 、適正制御割合が 94.7% となった。続いて、流入水量がそれ以下の流入水量では $1.24 \pm 0.44 \text{ mg/L}$ 、適切制御割合は 69.7% となった。前述の通り、流入水量が減少した場合に DO 濃度の超過が多いことから、本指標を用いた評価では、速やかに送風機下限まで下がらなかった箇所について未学習による影響が示唆された。

(2) 一度曝気風量の減少が停止した後に再度減少した箇所

2023/7/14 2:00 まではガイダンス値は $0.265 \text{ m}^3/\text{min}$ 前後を推移しているが、2023/7/14 2:05 では $0.257 \text{ m}^3/\text{min}$ まで大幅に低下していることが確認できた。同様に Fig. 4 のヒストグラムを確認すると、決定木 100 本中 6 本で曝気風量の予測値が $0 \text{ m}^3/\text{min}$ になっている。教師データ内で曝気風量が $0 \text{ m}^3/\text{min}$ となる部分は 7/5 の運転停止期間以外にないことから、この期間の影響を強く受けていると考えられた。そこで、7/14 のデータを対象に曝気風量と他のデータ項目の時系列変化を確認したところ、余剰汚泥引抜きが開始された後に曝気風量が下がっていることが確認できた (Fig. 5)。本実験プラントでは、余剰汚泥を 1 日 3 回 (2:00, 10:00, 18:00)、各 10 分間引抜いて

いるが、10:00 の余剰汚泥引抜きが修繕による実験プラントの停止期間内 (10:05~13:00) と重なっていた。そのため、余剰汚泥引抜きが実施された場合のみ、一部の決定木が 0 mg/L を出力することで予測値が小さくなったといえる。よって、この変動については未学習の影響ではないと判断した。

4. ま と め

パイロットスケールの標準活性汚泥法の実験プラントを用いて、流入水量を時間変動なしで運転した計測データを教師データとした AI の予測モデルを生成し、流入水量を時間変動させた条件 (未学習条件) で曝気風量の AI 自動制御を行った。平均値と標準偏差、適正制御割合 (DO 濃度の目標値に対して曝気風量の増減が適正だった割合) を用いて確認したところ、今回の未学習条件では教師データに比べ、AI 自動制御の方が DO 一定制御時の目標値から乖離した。また、AI 自動制御運転を行った際、曝気風量の予測値が特徴的な変化 (送風機能力の下限まで到達せずに風量の減少が一度停止し、再度風量が減少した箇所) を示した箇所について解析した。送風機能力の下限まで低下

しなかった箇所について、今回指標では未学習による影響が示唆された。一方で、更に曝気風量が低下した箇所については、AIの予測モデルを構成している決定木の一部が0 mg/Lの予測値を出力した結果であることが確認された。また、この0 mg/Lの予測値が出力された原因は、余剰汚泥引抜きおよび教師データに含まれた実験プラント修繕時の運転停止時のデータが関係していたことが確認された。今後は予測モデルに使用する項目数の変更や異なる未学習条件下での制御、今回使用した「適正制御割合」以外の評価指標での評価などを検討している。

参考文献

- 1) 国土交通省国土技術政策総合研究所 上下水道研究部下水処理研究室：B-DASH プロジェクト —— 下水処理研究室/国総研, 2024/05/20, <https://www.nilim.go.jp/lab/ecg/bdash/bdash.htm>（参照 2024/6/21）
- 2) Breiman, L.: Random forests, *Machine Learning*, Vol. 45, pp. 5-32 (2001)
- 3) 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)
- 4) 藤原翔, 平林和也, 山本明広, 糸川浩紀: 下水処理場におけるAI予測モデルの自動制御への適用, *環境システム計測制御学会誌*, Vol. 27, No. 2・3, pp. 19-22 (2022)