

〈研究発表〉

AIによる下水の流入水質や必要酸素量の予測とブロー運転計画

柏崎 拓成¹⁾, 湛 記先¹⁾

¹⁾ (株)ウォーターエージェンシー 研究開発部

(〒162-0813 新宿区東五軒町3-25 E-mail: wa03-00018@water-agency.com)

概要

下水処理場の運転管理では、エネルギー消費を抑えつつ、良好な処理水質を維持することが求められている。酸素必要量計算に基づいて下水処理を自動制御するOR制御は、エネルギー効率と水質をバランスする、より良い解法の1つである。更なるエネルギー効率の向上には、将来的なOR値や流入水質の変化に基づいて長期のブロー運転計画を反映させていくことが重要である。そこで今回、既にOR制御が導入されているA処理場において、AIを用いて、反応槽のORの変化の予測や流入下水の水質、水量予測を行い、ブローの運転計画への反映に関する可能性を検証した。

キーワード：予測，ディープラーニング，AI

原稿受付 2022.6.30

EICA: 27(2・3) 26-29

1. はじめに

現在、下水道事業においては、エネルギー対策・地球温暖化対策として、より効率的で省エネルギーな処理施設の運転管理が求められている一方で、水質等の要求事項を満たす必要がある。そうした運転管理技術の解法としてOR制御を開発し、実用化を行った¹⁾。今後、更なるエネルギー効率の向上を図るためには、必要な風量を確保しながら、ブロワの運転時間や台数を低減することが重要である。

OR制御は、反応タンクで必要となるBODの酸化に起因したOR、ケルダール窒素の硝化に起因したOR、活性汚泥の内生呼吸に起因したORを求め、この和をとり、散気装置の性能曲線から必要な曝気風量を計算し、ブロワ制御を行う手法である。より長期のORを予測することができれば、将来的な要求風量に基づいた、ブロワの運転計画が事前に立案可能となる(**Fig. 1**)。既に、ブロワの台数制御は実用化していること²⁾、様々な予測にAIを用いて検証して、良好な結果が得られたこと³⁾を踏まえ、AIによるOR予測が可能か、ブロワの運転計画が策定可能か検証を行った。

また、OR制御には、流入水質や水量のセンサー値を用いるが、センサーの故障やメンテナンスにより、値が利用できない状況が発生する。AIによる流入水質、水量の予測が十分な精度であれば、OR予測から自動制御まで継続することができる。そこで、AIを活用した流入に関する水質、水量の予測もあわせて検証を行った。




Fig. 1 Blower operation planning based on predicted air volume

2. 実験概要

本研究は、すでにOR制御が導入されているA処理場で行った。A処理場の概要と研究対象として使用したデータの期間を**Table 1**に示す。

予測に用いたAIは、すべてニューラルネットワーク(以下、NN)を用いて実装を行った。詳細は各項の実験仕様に示す。

Table 1 Outline the Plant A

処理水量	153,934m ³ /日 (令和元年度実績)
水処理方式	標準活性汚泥法
排除方式	分流式
系列/稼働池数	現有5系列 検証対象: 4系(池数2 2020/12/07より池数3)
期間	学習: 2019/1~2020/9 検証: 2020/10~2021/2

3. OR 予測

3.1 実験仕様

学習データは、A 処理場 4 系の 1 分単位のトレンドデータから NN の学習効率を向上するために、データを 5 分間隔で抽出し、間引かれたデータを NN の入力に加える工夫を行い、情報量を落とさず、計算量を 70% 程度削減した。

OR 値は、処理場で送風量制御を行うために実際に使用している計算値を用いた。

NN の説明変数は、OR 計算に必要な最低限のパラメータを選定した。

NN の目的変数は、将来時刻の OR 値とした。出力点数による予測精度の差を検証するため、24 時間で 1 時間おきの予測を行うパターン (OR_{24h}) と 3 時間先まで予測を行うパターン (OR_{3h}) で実施した。

NN モデルは、LSTM (Long short-term memory) および CNN (Convolutional neural network) を採用し、構造探索で良い結果が得られたものを使用した。NN の学習アルゴリズムは Adam, 損失関数は平均二乗誤差 (MSE: Mean Squared Error), 検証におけるモデル評価は、平均絶対パーセント誤差 (MAPE: Mean Absolute Percentage Error) で実施した。

OR 予測に用いたデータの仕様を Table 2 に示す。

Table 2 Data specifications

データ	A 処理場 4 系のトレンドデータ (1 分間隔)
入出力 説明変数	過去の OR 値, 流入水量, 返送流量, 曝気風量, MLSS, DO, NH ₄ -N, NO ₃ -N など -[1440, 1380, 1320, ..., 60, 30, 10, 4, 3, 2, 1](分)
目的変数	将来の OR 値
OR _{24h}	30 分後, 1 時間後以降, 24 時間後まで 1 時間間隔 [30, 60, 120, ..., 1320, 1380, 1440](分)
OR _{3h}	将来の OR 値 30 分後, 1 時間後以降, 3 時間後まで 1 時間間隔 [30, 60, 120, ..., 360](分)

3.2 結果と考察

OR 予測の結果を Table 3 に示す。OR_{24h} の MAPE は全時間帯で 4.8% となり、NN による OR 予測は実用的であることが分かった。

OR_{3h} は、出力点数が少なかったため、OR_{24h} に比べて更に予測精度が向上した。この結果から、長期の予測は OR_{24h} の NN モデルで予測し、短期は OR_{3h} の NN モデルを活用するなど、運転計画に必要な時間や

Table 3 Validation of the NN prediction on OR (MAPE)

出力	NN	30 分後	1 時間後	3 時間後	6 時間後	12 時間後	24 時間後	全時間平均
OR _{24h}	LSTM	2.22%	3.57%	5.05%	4.87%	5.62%	5.58%	5.13%
	CNN	2.41%	3.53%	5.01%	5.27%	5.26%	5.18%	4.82%
OR _{3h}	CNN	1.85%	3.30%	4.53%	-	-	-	3.23%

目的に応じて、より良い OR 予測 AI を切り替える運用も可能であることが示された。

また、Table 3 の OR_{24h}・CNN の結果を得た NN を用いて、12 時間先の予測を行い、実績値と比較をしたところ、OR がピークとなる部分も安定した結果が得られていた。2020/10/25 から 2020/11/11 までの結果を Fig. 2 に示す。




Fig. 2 Comparison of predicted and actual ORs (12 hours ahead)

また、前述の NN を用いて、0 時に 24 時間分、OR 予測を行い、実績と比較を行った (Fig. 3)。

1 日の OR の変化が少ない場合 (2020/10/27), 大きい場合 (2021/2/18) のいずれも、OR の変化に追従した予測ができていたことから、OR の 1 日の変化の大きさに係わらず、予測が可能であることが示された。

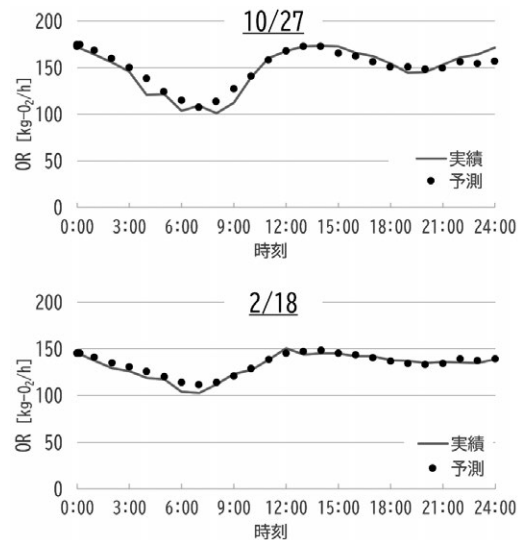


Fig. 3 24-hour time-course OR prediction

3.3 ブロワ運転計画 (台数制御) への適用

A 処理場は、OR 値が概ね 125 を超えると、ブロワ台数が 2 台となる実績がある。この実績に基づき、ブロワ台数が切り替わる OR の閾値を 125 として、2020 年 10 月 3 日 1 時 15 分時点の OR_{24h} の予測結果を元に、ブロワ運転計画の机上シミュレーションを実施した (Fig. 4)。

シミュレーションの結果、2 時間後から 7 時間後の間は、ブロワの 1 台運転が可能であることが分かった。2 台より 1 台運転をしたほうがエネルギー効率は良い




Fig. 4 Plan for number of blowers in operation based on OR projections (10/3 1:15)

ため、省エネ運転となる。ORの実績値とも一致したため、OR予測によるブローの運転計画が可能であることが示された。また、実績値では4～5時間後に一時的にORが上昇するが、OR予測に基づけば、同時時間帯は1台運転が継続可能であると読み取ることができる。

4. 流入水質、水量予測

4.1 実験仕様

予測対象は、4系に流入する水量、 $\text{NH}_4\text{-N}$ 濃度、濁度とした。

学習データは、OR予測と同じ5分間隔データを基本に、間引いたデータを入力に加えたものを使用した。流入水質や水量の測定値については、増減の傾向を正しく把握するため30分の移動平均をデータに加えた。

NNの説明変数は、予測対象が異なっても、相互に関連性の高いパラメータであるため、共通とした。1分間のトレンドデータ、過去30分移動平均データに加えて曜日、時間といった情報を加えた。

NNの目的変数は、予測対象の移動平均を基に、位相補正を行った値を使用した。

NNモデルは、CNN (Convolutional neural network) を基本として、予測対象毎に学習を行い、NNの構造探索で良い結果が得られたものを使用した。NNの学習アルゴリズム、損失関数、モデル評価はOR予測と同様とした。

流入予測に用いたデータの仕様をTable 4に示す。

Table 4 Data specifications

データ	A処理場 4系のトレンドデータ (1分間隔)
説明変数	4系への流入 (水量、 $\text{NH}_4\text{-N}$ 濃度、濁度)のトレンド値および過去移動平均 (30分)、月、時間、曜日 -[1440, 1380, 1320, ..., 60, 30, 10, 4, 3, 2, 1] (分)
目的変数	位相補正後の移動平均
水量	15分後から6時間後まで15分間隔 [30, 60, 120, ..., 360] (分)
$\text{NH}_4\text{-N}$	〃
濁度	〃

4.2 結果と考察

予測対象毎の流入予測の結果について、Table 5に示す。いずれもMAPEが全時間平均で2%前後の結果が得られ、実用的であることが分かった。

Table 5 NN prediction on influent loadings (MAPE)

予測対象	30分後	60分後	120分後	180分後	240分後	300分後	360分後	全時間平均
水量	1.47%	1.53%	1.43%	1.94%	3.15%	3.49%	4.40%	2.47%
$\text{NH}_4\text{-N}$	0.48%	0.49%	0.37%	0.35%	2.02%	2.71%	3.21%	1.35%
濁度	1.53%	1.15%	0.84%	0.90%	3.67%	4.33%	5.03%	2.48%

ただし、水量、 $\text{NH}_4\text{-N}$ 、濁度のいずれも、3時間後までの予測と、4時間後以降の予測精度に開きが見られた。2021/1/4の濁度の3時間先予測と4時間先予測を実績値と比較すると、3時間先の予測は、濁度の上昇が予測できたが、4時間先では出来なかった (Fig. 5)。分析したところ、A処理場では、流入水質や水量の急激な変化は、概ね3時間以内で収束していた。そのため、4時間先の予測の時点では、水質や水量の変化の兆候が現れず、予測に反映ができなかったことが原因と考えられる。




Fig. 5 Prediction accuracy for different durations of abnormal inflow (turbidity)

4.3 系列の池数変化前後の水量予測

流入水量の予測では、NNの学習に用いたデータは、4系の稼働池数が2池のときのデータのみを使用している。検証期間中は、途中で池数が3に増えているが、NNは学習し直さずに、そのまま予測を継続した。

4系の稼働池数の増加に伴い、系列毎の流入水量が変化した。稼働池数の変化前後の4系の流入水量をFig. 6に示す。

池数増加後は、4系への流入水量が平均で24%増加しており、変動幅も大きくなっていることが分かる。




Fig. 6 Box-and-whisker diagram of inflow before and after change in number of reaction tanks

しかしながら、予測誤差 (MAPE) は、池数変化前後で全時間平均 0.6% の増加に留まった (Fig. 7)。




Fig. 7 Comparison of MAPE before and after changing the number of reaction tanks

NN などの AI は、系列の稼働池数の変更があった場合、データを収集し直して再学習することが望ましい。しかしながら、運用の変更直後は、再学習に必要なデータが揃っておらず、変更前に学習した AI で運用せざるを得ない状況が生じる。今回の A 処理場では、稼働池数の変化後も NN の予測誤差が 2.76% と許

容範囲であったため、AI の連続運用が可能であった。下水処理場では、工事や清掃に伴い各系列の稼働池数が変わるため、引き続き、運用面を考慮した説明変数の選択を検討し、AI の可用性の向上を図りたい。

5. ま と め

本検証で、AI による OR 予測が概ね 24 時間先まで可能であること、OR 予測に基づいてプロワの運転計画を立案することが可能であった。また、出力をより短時間にする事で更に精度を向上させることができ、計画に必要な時間の長さや目的に応じて、最適な AI を構築することも可能であった。

また、流入水質や水量の予測についても、良好な結果が得られた。ただし、異常流入の事前予知が可能な時間は、異常流入の継続時間に依存した。予知可能な時間を延ばすためには、施設外の情報を組み合わせることが必要であることが明確となった。

OR 予測や流入水質、水量の予測精度が十分な施設であれば、センサーの故障やメンテナンス時であっても、予測値によりセンサー値を代替する可能性が見えた。予測値を活用することで、プロワの運転計画のみならず、OR 制御をはじめとした各種システムの可用性を高めることが期待できるため、今後も引き続き検証を行いたい。

参 考 文 献

- 1) 湛記先：OR 制御技術の紹介，月間下水道，Vol. 42，No. 7，pp. 65-69 (2019)
- 2) 湛記先，池田洋平：曝気プロワ運転台数の自動制御，第 54 回下水道研究発表会講演集，pp. 1120-1122 (2017)
- 3) 柏崎拓成，湛記先：下水処理場における AI を活用した予測や画像診断について，第 58 回下水道研究発表会講演集，pp. 761-763 (2021)