

〈研究発表〉

畳み込みオートエンコーダを用いた下水処理施設の異常検知

高瀬 信 彰¹⁾, 木村 雄 喜¹⁾, 高倉 正 佳¹⁾, 鮫島 正 一¹⁾
庭川 誠¹⁾, 倉本 喜 文²⁾, 南浦 詳 仁³⁾, 上原 洋 平³⁾
増屋 征 訓⁴⁾, 竹田 功⁴⁾, 川崎 達⁴⁾
中橋 達也⁴⁾, 松橋 学⁵⁾

¹⁾ 株式会社明電舎

(〒410-8588 静岡県沼津市東間門字上中溝515 E-mail: takase-n@mb.meidensha.co.jp)

²⁾ 広島市下水道局 (現 日本下水道事業団)

³⁾ 広島市下水道局

⁴⁾ 株式会社NJS

⁵⁾ 国土交通省 国土技術政策総合研究所

概要

下水処理施設の運転・保全の効率化を目的として、下水処理施設の沈殿池にカメラを設置し、畳み込みオートエンコーダを用いた異常検知技術によって水質異常を検知する手法を提案する。過酷な撮影環境である沈殿池において、水質変化の位置、個数、面積を定量的に評価可能であることを示した。

キーワード：異常検知, 畳み込みオートエンコーダ, 下水処理施設
原稿受付 2021.6.23

EICA: 26(2・3) 31-34

1. はじめに

我が国の下水道処理人口普及率は1997年の56%から2018年の79%まで年々増加しており¹⁾、下水処理システムは私たちの生活を維持し、健全な都市の水循環サイクルを実現するために必要不可欠なシステムである。一方で、我が国の人口減少問題は、全国の下水道部署の職員の減少や下水道使用料収入減少により、下水道システムを支えている下水道事業継続の大きな問題になっている。これらの下水道事業が抱える課題の解決策として国土交通省では、平成25年度より下水道におけるICTの活用に関する検討会の設置や、ICTの活用による下水道事業の質・効率性の向上や情報の見える化を行うこと目的とした*i-Gesuido*施策の実施など、ICTを活用した効率的な下水道の事業実施を推進している。また、下水道に限らず、世界的にあらゆる産業において、新たなデジタル技術を利用したこれまでにないビジネスモデルが展開されており、各企業は競争力維持・強化のために、デジタルトランスフォーメーション(DX: Digital Transformation)をスピーディーに進めていくことが求められている²⁾。

これらのことから、本研究はデジタル情報の活用し

た水処理場の運転管理の自動化・省力化を目的として、特に沈殿池における巡視作業の省力化に着目し、沈殿池の画像から処理状況を自動で判断する「画像処理AI」を開発し実処理場での適応可能性について検証した。

2. 下水処理場における画像処理AIの検証範囲

下水処理場では、熟練技術者が運転操作の変更を判断する際に、①データから異常を感知 ②現場の状況を目視で把握 ③経験による原因特定・判断という3つの行動が行われている。筆者らが対象とした下水処理場の熟練技術者へのヒアリングより、過去の操作履歴や水質分析結果、監視装置の観測値(DO, MLSSなどの水質)、異常発泡等の各種処理槽の目視が確認項目として挙げられた。このうち②の現場状況を目視で把握する必要がある異常発泡等の目視確認の情報について注目し、本検証を実施した。具体的には、下水処理施設の最終沈殿池を対象とし、最終沈殿池における異常現象として水質の悪化の原因となる浮遊物の発生や発泡などの目視により確認可能な水面の状況変化について、画像処理による検出の可能性を検証した。

また、検証の現場条件については、覆蓋のある屋内施設のため、降雨等による影響が少ない条件下で有効性を検証している。なお、通常の維持管理の最終沈殿池の目視確認は定期的に行われているが、作業員が各池まで移動して目視点検を実施していることから長時間の連続観察は困難であり、スカムに代表される水質異常の見逃しも懸念されるため、本検証では24時間の連続監視が可能なシステムとした。

3. 画像処理 AI の概要

本検証のために開発した画像処理 AI は、最終沈殿池にネットワークカメラを設置し、カメラ画像または動画 (Fig. 1) を取得、監視制御室に集約、画像解析を用いて異常を判断し、異常と判定した場合、異常があることを運転員に通報するシステムである (Fig. 2)。本システムの画像解析は、最終沈殿池画像の浮遊物を検知するため、背景モデリングによる背景推定を行う畳み込みオートエンコーダ (Convolutional Auto-Encoder: CAE) を活用した画像処理手法を採用した。具体的には、背景とは正常な水面領域を指し、前景とは検知したい浮遊物の領域を指し、過去の背景画像から適切に背景推定を行い、前景である浮遊物を検知する手法である。CAE は優れた特徴量抽出手法であり、その出力である復元画像を用いた高精度な異常領域検出が可能である³⁻⁵⁾。本研究は、このような CAE の優



Fig. 1 Image taken of the final sedimentation tank

れた特性に着目し、過去の大量の正常な沈殿池画像から背景モデリングを行う手法を提案する⁶⁾。正常な画像で学習された CAE を用いて背景モデリングを行うことで、異常な画像が入力された場合にその異常部分を取り除いた復元画像を生成され、背景推定を行うことが可能となる。沈殿池画像は様々な外的要因で均一な正常画像を取得することが難しいが、CAE による背景モデリング手法はこうした背景の変化も適切にモデリングすることが可能である。背景モデリングの方法として中央値法と呼ばれる手法が提案されている⁷⁾。中央値法とは、背景を推定したい画像の前後 N フレーム (N は任意の自然数) の画像から、各画素値の中央値を背景推定画像の画素値として出力する手法である。本研究では、前後 N フレームの画像と、N 個の CAE によって生成された復元画像 N 枚を合わせた 2N 枚の画像の各画素値の中央値を取ることで推定背景画像を生成する中央値法を採用した。なお最終沈殿池では、水質の状態や外光の影響によって水面上の透明度、色が変化して背景が変化する場合があることから、CAE 単体での背景モデリングではこれらの水面上の変化が学習時に存在しなかった場合に正しく異常検知を行うことができない。そのため中央値法はこうした背景変化が生じた場合でも自動的に背景推定画像が修正されるという点で優れていることから、より頑健性の高い背景モデリングが可能な手法を採用した。

4. 実験と評価

4.1 実験方法

実験は広島市下水道局西部水資源再生センター内の覆蓋化された最終沈殿池にネットワークカメラと LED 照明を設置した。返流水処理のための循環式硝化脱窒法による処理が行われる 1 系最終沈殿池と、標準活性汚泥法による処理が行われる 3 系最終沈殿池を

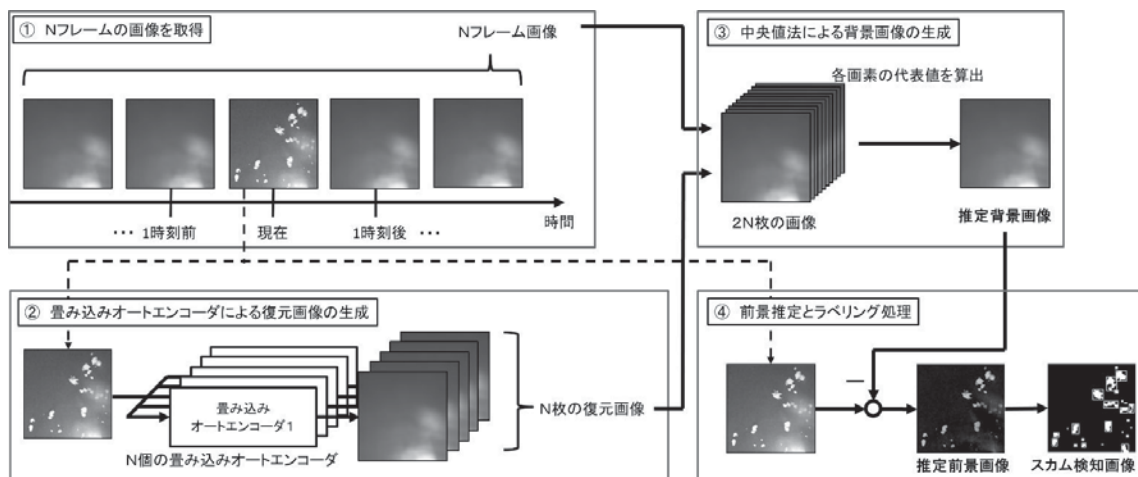


Fig. 2 Outline diagram of anomaly detection system by cooperation of CAE and median method

対象とした。30分間隔で照明を点灯させ、1回の照明点灯の間に10秒間隔の画像を10枚撮影した。2018年11月20日から2018年12月31日をCAEの学習期間、2019年1月1日から2019年2月28日を検証期間として実験を行った。本手法は教師なし学習の一形態であるため各画像データに正常・異常のラベルを必要としないが、モデル性能評価のためには正解ラベルが必要となる。検証期間に得られる大量の画像データにラベリングを行うことは困難であるため、検証期間のうち異常データを含む1,000データをランダムサンプリングしてラベルを付与したデータを検証用データとした。本実験に使用した計算機スペック表をTable 1に示す。

CAEは18層で構成される対称なネットワークを用い、中間層で画像を100次元まで圧縮した。CAEの

Table 1 Machine specifications

プロセッサ	Intel® Core™ i7-7700K 4.2 GHz
メモリ	64.0 GB
GPU	NVIDIA® GeForce® GTX 1080 Ti

エンコーダ部は9層の畳み込み層から構成され、デコーダ部は9層の逆畳み込み層から構成される。エンコーダ部、デコーダ部ともに、出力層以外は畳み込み処理の後にBatch Normalizationおよび活性化関数であるReLU関数を適用する。エンコーダ部の出力層は活性化関数に恒等関数を使用し、デコーダ部の出力層は、画素値の最小値0最大値1の画像とするため、活性化関数として最大値を1としたClipped ReLU関数を使用した。沈殿池画像は池の中心領域をトリミングし、リサイズおよびグレースケール化を行い、画像サイズを128×128としてCAEに入力する。CAEの学習におけるバッチサイズは32、学習エポックは30

とした。復元画像と入力画像の差分画像に対して二値化処理、クロージング処理、ラベリング処理を行う。二値化処理のしきい値は学習期間で得られた画素値の分布より50と設定した。クロージング処理のカーネルサイズは3×3とした。ラベリング処理で得られる浮遊物の個数と総面積を異常検知の指標として用いる。個数、総面積の各々にしきい値を設定し、しきい値を超えたら異常と判定する。実験は複数の沈殿池で実施したが、CAEは各沈殿池で別々に学習を行った。中央値法に用いるフレーム数は11フレームとした。10秒間隔画像であるので、110秒の画像によって背景を推定する。

4.2 実験結果および考察

Fig. 3, 4に、3系最終沈殿池における浮遊物判定結果を例示する。各図の(a)は元画像である入力画像を、(b)は提案手法による推定背景画像を、(c)は入力画像と推定背景画像との各画素値の差分を取った推定前景画像を、(d)は推定前景画像に対して画像処理を行ってラベリング処理を行ったスクラム検知画像を示している。Fig. 3は照明が水面に反射して写り込んでいるため、入力画像に濃淡が生じていることが確認できる。提案手法による推定背景画像はこの濃淡を高精度で再現していることが確認できる。これより、入力画像と推定背景画像の差分である(c)推定前景画像は各画素が0に近い値となり、異常検知画像では何も検出されず正常と判定されたことが確認できる。Fig. 4は浮遊物が入力画像に表出している例である。浮遊物がある場合、推定背景画像は浮遊物の無い背景画像となり、推定前景画像によって浮遊物の画素が抽出される。異常検知画像では異常箇所が正しくラベリングされていることが確認できる。




Fig. 3 Anomaly detection flow of the No. 3 final sedimentation tank at 2019/1/1 00:23:58




Fig. 4 Anomaly detection flow of the No. 3 final sedimentation tank at 2019/1/17 01:58:08

Table 2 Accuracy, recall, precision and f-measure of anomaly detection system

実験条件	再現率	適合率	f 値
(1)	0.92	0.92	0.92
(2)	0.90	0.90	0.90
(1) and (2)	0.82	0.98	0.89
(1) or (2)	1.00	0.86	0.92

次に検証期間全体での精度評価を示す。本節では、正常／異常の判断指標を浮遊物の個数とした場合を実験条件(1)、正常／異常の判断指標を浮遊物の面積とした場合を実験条件(2)と表記する。浮遊物の個数のしきい値を10個、浮遊物の面積のしきい値を $128 \times 128 \div 16,000$ pixelの1%に相当する160 pixelとした場合の再現率、適合率、f値を**Table 2**に示す。実験条件は(1)、(2)に加えて、そのどちらかが異常と判定した場合に運転員に通報する「(1) or (2)」と、その両方が異常と判定した場合に運転員に通報する「(1) and (2)」を示す。実験条件(1)、実験条件(2)ともに高い再現率であることが確認できる。「(1) and (2)」では、二つの判断指標が異常となった場合に異常と判断するため、適合率を0.98と高くすることが可能となる。「(1) or (2)」では二つの判断指標のうち一方が異常となった場合に異常と判断するため、再現率は1.0となる。異常を100%検知するのか、正常の誤検知を小さくしたいのかという現場の状況に合わせて、しきい値や異常判断の指標を適切に決定することが可能である。

CAEの学習時間は、1系最終沈殿池が5,907秒、3系最終沈殿池が4,222秒であった。CAEによる背景推定は、より直近の正常画像によって行われることが望ましい。各週や各月に再学習可能な計算時間であることが示された。

5. おわりに

水処理施設の運転・保全の効率化を目的として、CAEを用いた異常検知技術によって、下水処理施設の沈殿池に生じる水質異常を検知する手法を提案した。数値実験において、CAEが水面画像を適切にモデリング可能であり、再現率90%で異常検知が可能であることを示し、提案手法の有効性を確認した。今後の課題として異常判断のしきい値の自動決定方法の考案が挙げられる。

謝辞

本研究の実施にあたりデータ提供を頂いた広島市下水道局西部水資源再生センターの関係者および本研究の関係者各位に謝辞を表す。

参考文献

- 1) 国土交通省：下水道事業の現状と課題，下水道事業における広域化・官民連携・革新的技術（B-DASH）に関する説明会（2019）
- 2) 経済産業省：デジタルトランスフォーメーションを推進するためのガイドライン（DX推進ガイドライン）Ver.1.0（2018）
- 3) J. Masci, U. Meier, D. Cireşan, and J. Schmidhuber, "Stacked Convolutional Auto-Encoders for Hierarchical Feature Extraction", ICANN, pp. 52-59. Springer (2011).
- 4) C. Baur, B. Wiestler, S. Albarqouni, and N. Navab, "Deep Auto-encoding Models for Unsupervised Anomaly Segmentation in Brain MR Images", arXiv: 1804.04488 (2018).
- 5) P. Bergmann, S. Löwe, M. Fauser, D. Sattlegger, C. Steger, "Improving Unsupervised Defect Segmentation by Applying Structural Similarity to Autoencoders", arXiv: 1807.02011 (2018).
- 6) 高瀬信彰, 木村雄喜, 鮫島正一, 高倉正佳, 倉本喜文, 上原洋平, 南浦詳仁, 増屋征訓, 川崎達, 中橋達也, 松橋学: 畳み込みオートエンコーダを用いた下水処理施設の異常検知, 動的画像処理実利用化ワークショップ, pp. 276-282 (2020)
- 7) R. Cucchiara, G. Constantino, M. Piccardi, and A. Prati, "Detecting Moving Objects, Ghosts, and Shadows in Video Streams", Pattern Analysis and Machine Intelligence, pp. 1337-1342 (2003).