

深層学習による浄化槽から取得可能なデータを用いた BOD 予測技術の開発

長岡工業高等専門学校 環境都市工学科 非会員 ○ 久住葉瑠
長岡工業高等専門学校 環境都市工学科 正会員 川上周司
長岡工業高等専門学校 環境都市工学科 非会員 土田勝範
北陸先端科学技術大学院大学 先端科学技術科 先端科学技術専攻 非会員 藤田祐樹

1. 背景と目的

合併処理浄化槽（以下、浄化槽）の維持管理や法定検査は、保守点検業者や清掃業者の現場技術者や指定検査機関の検査員が直接、浄化槽現場に出向いて行っている。しかし、各家庭に点在する膨大な浄化槽を全て回って確認する労力等は多大なものであり、現場における作業時間や労力のみだけでなく、移動に伴う排気ガスによる環境負荷や燃料費など相応の必要経費を要する。また、有機物汚濁を把握する上で重要な水質項目となる BOD 値は、測定期間に 5 日間を要するため、処理状況が思わしくない場合においては、採水時段階で初期対応を行うことは難しい。こうした中でも現場技術者や検査員は、処理水の透視度、曝気槽の DO、スカムの生成状況などから浄化槽の状況を経験的かつ総合的に判断し、対応しているのが現状である。

本研究では、短時間で BOD 値を測定する技術の開発を目的として、深層学習を用いて浄化槽の BOD 値を予測する技術の開発を行った。まず、対象とする浄化槽の上部から撮った写真と、BOD 値を関連付けて学習させるデータセットの作成を行い、深層学習を用いて BOD 値を予測した。そして、DO などの現地で取得できる水質情報も関連付けた BOD 予測技術の確立を目指した。

2. 研究手法

2.1 データセットの作成

画像と BOD 値を関連付けて BOD 値を予測する技術の開発には、まず初めに深層学習モデルに学習させるデータセットの作成を行う必要がある。浄化槽の好気槽の上部写真を説明変数とし、BOD 値を目的変数とした。そのデータセットの BOD 数値を分類分析に用いるため、BOD 値が 10 mg/L よりも大きいデータを 1 とし、BOD 値が 10 mg/L 以下のデータを 0 と変換し、二値分類のデータセットを作成した。使用する画像は、224×224 pixel の大きさにリサイズした。その画像に垂直反転、水平反転を施し、データ拡張を行った。データセットは、訓練データ、検証データ、テストデータに分け、その数はそれぞれ 2220, 268, 210 とした。また、訓練データと検証データ、テストデータの各々に同一日の拡張後のデータが入ることを避けた。

2.2 深層学習モデルについて

本研究では、畳み込みニューラルネットワーク (Convolutional Neural Network) 構造を用いてモデルを構築した。転移学習モデルを使用した解析には 5 層の畳み込み層と 3 つの全結合層からなる AlexNet²⁾を採用し、ファインチューニングを行いその予測精度を検証した。ファインチューニングは、ImageNet³⁾と呼ばれる 1,400 万枚以上の画像の教師ラベル付き画像データベースを用いて事前学習した AlexNet に収集した浄化槽の画像を用いて再学習させた。AI モデルの学習、推定にはホールドアウト法を用いた。本研究では、Python を基に構築されているニューラルネットワークライブラリの PyTorch を用いてニューラルネットワークの構築、学習及び評価を行った。損失関数には、交差エントロピーを用い、最適化アルゴリズムには、momentumSGD を用いた。momentumSGD のパラメータである momentum は 0.9 とし、weight decay は 1.0×10^{-3} 、初期学習率は 1.0×10^{-3} とした。

2.3 使用した画像について

本研究では、浄化槽の解析を2回行った。まず1回目の解析では、浄化槽の面積がなるべく残るようにトリミングをした。2回目の解析では、1回目の結果から浄化槽部分のみを抽出することを目的にして、トリミング範囲を縮小した。1回目、2回目それぞれの画像を図1、図2に示す。



図1 解析1回目の浄化槽写真

2.4 モデルの性能評価

予測した結果を評価するために、正解率 (Accuracy) と再現率 (Recall) を採用した。正解率は、予測した BOD 値が正解の BOD 値とどの程度一致しているかで示した。本研究で用いるデータセットは、BOD 値が低いデータが多く存在し、データに偏りが生じていた。このことから、正解率のみの評価では、BOD 値が大きいデータの予測が外れていたとしても、BOD 値が小さいデータの予測が正解することで正解率は上昇する。この問題を解決するために、正解率以外に BOD 値が大きいデータの予測のみに焦点を当てた再現率を用いて評価した。本研究の目的は、浄化槽の水面の状態に基づく BOD 値を予測するモデルの開発であるため、AI モデルが浄化槽の水面を評価している必要がある。AI モデルに入力した画像に対し、画像のどの部分を評価しているかを把握するために、Gradient weighted Class Activation Mapping (Grad-CAM)⁴⁾を用いた。Grad-CAM により、畳み込みニューラルネットワークの特定の出力に対する最終畳み込み層の特徴マップの重要性を評価し、ヒートマップにより評価している箇所を示した。



図2 解析2回目の浄化槽写真

3. 研究結果

3.1 深層学習による分類分析結果

BOD 値を 1 mg/L ごとに細かく分け、分類のカテゴリーを増やしていくとデータ数の不足が生じると予想された。二分類する際に、どちらかに偏りがでないよう BOD 値で 10 mg/L を上回るか下回るかというモデルを構築することとした。

1回目の解析で得られた学習曲線を図3に示す。結果、検証データに対する正解率は、94.6%を示した。図3から訓練と検証の loss 値が減少していていることから学習不足がないと判断し、テストデータを用いて未知のデータに対する予測精度を検証した。その結果、正解率は 26.1%、再現率は 36.2%であった。訓練、検証の正解率が高いことに比べ、テストデータの予測が低いことから、過学習を起こしていると考える。Grad-CAM を使用し、深層学習モデルが画像のどこを評価してテストデータの予測を行ったかを可視化した。結果を図4に示す。図4から、学習モデルは浄化槽ではなく背景のコンクリートを評価し予測してしまっていることが分かった。

1回目の解析では、背景を見てしまっていることが原因だったため、トリミングの範囲をさらに縮小させ、背景が映らないようにした。の際の学習曲線を図5に示す。結果、検証データに対する正解率は 93.4%であった。こちらも1回目と同じように loss 値は減少したことから学習不足がないと判断し、次にテストデータを用いて未知のデータ予測精度を検証した。その結果、正解率は 27.1%、再現率は 37.5%を示した。訓練、

検証の正解率が高いことに比べ、テストデータの予測が低いことから、このモデルも過学習を起こしていると考えられる。2回目の解析の Grad-CAM を図 6 に示す。図 6 から背景を消したらパイプを見ていることが分かった。2回の解析から水面以外の情報を用いて評価し予測していると思われ、さらなる検討の必要性が示された。

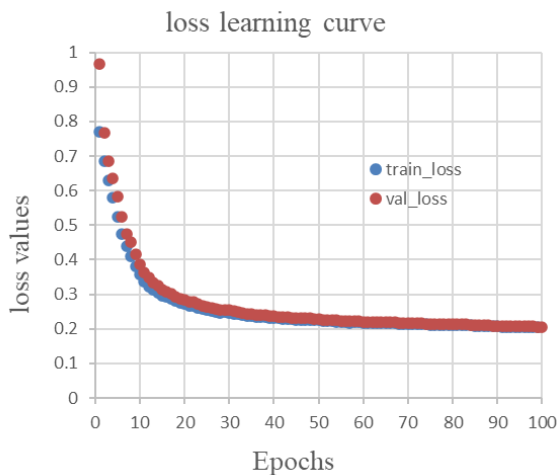


図 3 1 回目の学習曲線




図 4 1 回目の画像の Grad-CAM 使用写真

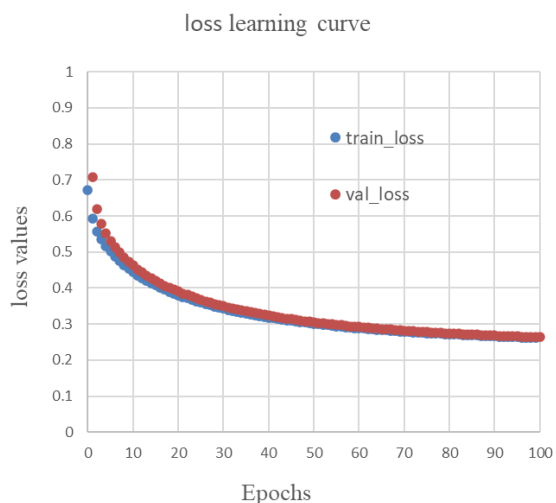


図 5 2 回目の学習曲線




図 6 2 回目の画像の Grad-CAM 使用写真

3.2 ハイパーパラメータについて

深層学習モデルの学習実行前にハイパーパラメータを調整することで、深層学習モデルの予測精度の向上、過学習の抑制が期待できるため、調整を行った。1回目と2回目のハイパーパラメータの設定値を表 1 に示す。

表 1 解析 1 回目のハイパーパラメータ

| learning_rate | batch_size | epochs | momentum | weight_decay | earlystopping | output_channel |
|----------------------|------------|--------|----------|----------------------|---------------|----------------|
| 1.0×10^{-6} | 16 | 100 | 0.9 | 5.0×10^{-5} | TRUE | 2 |

表 2 解析 2 回目のハイパーパラメータ

| learning_rate | batch_size | epochs | momentum | weight_decay | earlystopping_is | output_channel |
|----------------------|------------|--------|----------|----------------------|------------------|----------------|
| 1.0×10^{-3} | 64 | 100 | 0.9 | 5.0×10^{-5} | TRUE | 2 |

4. 考察

本研究では画像データからと BOD 値から BOD を予測する技術を分類分析で開発した。BOD 値は最終的には排水基準を満たすか否かを判断する上で重要な指標である。その上で重要になるのが排水基準となる 20 mg/L⁵⁾という値である。本研究では集積したデータを見ると、BOD が 20 mg/L 以下という良好な処理水が得られた際のデータ数が多く、偏っていることがわかる。一般的に浄化槽は安定的な処理能力を発揮することから、そもそも処理水の悪化したデータ数が少ないという問題がある。このような偏ったデータでモデルを構築すると、十分な予測精度が出ないという報告もある。したがって、BOD 値が均等かつ十分なデータが準備しづらい現状においては、10 mg/L などの 20 mg/L 以下の値を境界値にすることでデータの偏りが減り、高い精度が出せると考えた。

解析 1 回目、2 回目どちらも過学習を起こしていた。今回画像データは 1 日に 20 枚程度撮影したものを使用した。同日に取った画像は浄化槽の映り方がほぼ同じだったことや訓練データを作成する際に似た画像を拡張し使用したことなどによって過学習が起きたのではないかと考える。

5. まとめと今後の展望

本研究では、好気槽の写真から、BOD を予測するモデルの作成を試みた。しかし、深層学習モデルは背景の情報に重みを置いたり、過学習を起こしてしまったりと十分な学習モデルを構築できていない。過学習への対策として、画像データの種類を増やすことや、1 日で 1 枚の画像のみを使うことなどの検討を行っていく。さらに、最適なハイパーパラメータが見つからなかったことから、グリッドサーチやベイズ最適化などの調整法を試していく。さらに、パイプを黒く塗りつぶすことで水面を注視させることや、今の画像では水面が暗く見えづらいため、明度や輝度を調整することで水面が見やすくさせるといった手法を検討し、水面を評価した AI モデルの作成を目指す予定である。これら課題の解決により、予測精度の高い学習モデルを作成することで、5 日間必要とされている BOD の測定を、今よりも迅速に推測できる技術の構築を目指す。

6. 参考文献

- 1) 中島進, 大町盛一郎, 処理水の性状に着目した水質悪化施設の原因究明フローの構築と早期改善への取り組みについて, *全国浄化槽技術研究集会資料*, 2018.
- 2) Krizhevsky, A., Sutskever, I. *et al.* "ImageNet Classification with Deep Convolutional Neural Networks". *Advances in Neural Information Processing Systems* 25, NIPS 2012.
- 3) Deng, J., Dong, W. *et al.* "ImageNet: A Large-Scale Hierarchical Image Database", in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, CVPR 2009.
- 4) Selvaraju, R.R., Cogswell, M. *et al.* "Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization", arXiv, revised 3 Dec 2019.
- 5) よりよい水環境のための浄化槽自己管理マニュアル - 環境省, 2009