

凝集フロック画像のAI判定による凝集条件最適化に向けた フロック画像前処理技術の開発

Image preprocessing of coagulated flocs aiming at development of AI judge of optimal coagulation condition using floc images

都市人間環境学専攻・凌海

Civil, Human and Environmental Engineering・LING Hai

1. はじめに

浄水処理において、急速ろ過法は比較的濁度の高い河川水に適しているため、最も広く用いられている処理プロセスである。凝集沈殿は急速ろ過の前の重要なプロセスであり、凝集剤を添加することにより、水中の濁質を凝集させ、大きなフロックとして沈澱し除去する。凝集沈殿において、原水の状態に応じた適切な量の凝集剤を注入することは非常に重要である。

しかし、地球温暖化に伴う異常気象により、河川原水の水質が大きく変動している。原水水質の急激な変化に対応するため、高度な技術を持った技術員が必要となる。一方で、全国の水道事業者は少子高齢化による人員不足や技術継承不足が深刻な課題となりつつあり、水質異常時の対応も困難となっている。以上より、凝集運転を管理する技術員の支援を目的とした自律制御システムの開発を目指している。

近年、人工知能(artificial intelligence: AI)技術を導入する企業が増加しており、さまざまな装置の自動制御が可能となっている。近年、AI手法の1つとして、画像や音声など複雑なデータから情報を解析できる畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)¹⁾が注目されている。

CNNは画像から人の手を介さずに特徴量を抽出し、高精度に分類可能なモデルである。画像の局所的な特徴を抽出する畳み込み層と、局所的な特徴をまとめるプーリング層を繰り返す構造となっている。画像認識分野においてCNNの様々なアーキテクチャが検討されており、トップクラスの画像分類精度を有するアーキテクチャとして、ResNet-50²⁾アーキテクチャが知られている。

我々の研究グループは、半年間の利根川と荒川の合流水を用いて、ジャーテスト中のフロックをビデオカメラで撮影した。入力を得られたフロック画像、出力を処理水濁度により0.5 NTU未満、0.5から1.0 NTU、1.0 NTU以上の3つのカテゴリ、アーキテクチャをResNet-50としたCNNモデルを構築した。画像処理としてGaussian Blurを利用し、画像中のノイズを平滑化することで、処理水濁度の予測精度を76%から84%と向上させることに成功した。

その後、浄水場の実施設に処理水濁度を予測するモデルを導入することを最終目標として、埼玉県吉見浄水場内に凝集-沈殿装置を設置し、1年間の連続凝集処理を実施した。水中カメラで形成したフロックを撮影し、1 fpsの画像データに変換後、200×200 pixelにトリミングし、CNNモデルの入力データとした。先行研究と同様の前処理と、前処理なしの画像を使用し、CNNモデルを構築したところ、精度はそれぞれ69.18%、69.86%となった。

連続凝集処理において、先行研究の画像前処理により、CNNモデルの予測精度の向上が失敗した。ジャーテスト中のフロックを対象としたCNNモデルと比較して精度が低下した要因として、以下の3点が考えられる。1) 連続凝集処理と水中カメラの使用によりカメラのレンズが汚れる。2) 200×200 pixelのトリミングサイズによりフロックが写っていない画像が存在する。これら2点は入力画像の課題であり適切な前処理により改善可能であると考えた。以上より本研究の目的は、凝集フロック画像のAI判定に適した画像前処理技術を提案する。

2. 実験方法

(1) データの収集

利根川と荒川の合流を水源とする埼玉県吉見浄水場の原水を用いて、図-1に示す凝集-沈澱装置で凝集実験を実施した。処理水量は10.4 L/minとした。2021年10月5日から2022年10月4日まで、週2回データ収集と装置のメンテナンス作業をした。




図-1 装置のイメージ図

凝集-沈澱装置は①200 rpm 急速攪拌槽、②30 rpm と 20 rpm の 2 段の緩速攪拌槽、③水中カメラを設置した中間槽、④沈殿槽となっている。

凝集剤にはポリ塩化アルミニウム(PAC)を急速攪拌槽に添加した。幅広い処理水濁度と多様なフロックを得るため凝集剤注入率を 0.5、1.0、2.0、3.0 mg-Al/L の 4 つの条件に設定し、12 時間毎に自動的に切り替えた。急速攪拌と緩速攪拌で形成したフロックは水中カメラ(UC-IP50、株式会社ミカミ)で 1 fps、1920×1080 pixel の大きさに撮影した。撮影した画像を画像データに変換後、画像の中央 200×200 pixel にトリミングした画像を CNN の入力データとした。

原水濁度計(TUF-7M、東亜ディーケーケー株式会社)で原水濁度、処理水濁度計(HU-200TB-W、株式会社堀場アドバンステクノ)で処理水濁度をそれぞれ 1 分毎に測定した。

(2) モデルの構築

学習データを 2021 年 10 月 5 日から 2022 年 8 月 6 日の合計 861,648 枚の画像、テストデータを 2022 年 8 月 6 日から 2022 年 10 月 4 日の合計 109,524 枚の画像とした。CNN モデルの出力は先行研究と同様に、処理水濁度が 0.5 度未満、0.5 度以上 1 度未満、1 度以上をそれぞれ Class1、Class2、Class3 とした。

CNN のアーキテクチャとして ResNet-50、学習回数を 20 エポックとしてモデルを学習させた。CNN モデルの予測精度はテスト精度で評価した。

(3) 画像の前処理

1) 汚れの除去

カメラレンズに付着したフロックを確認すると、画像の同じ位置に数十分間フロックが留まっていることがわかった。ノイズを平滑化する Gaussian Blur の前処理は付着したフロックの除去が失敗したため、付着したフロックの除去ができる OTSU-差分と暗合成-差分二つの画像処理法を検討した。

OTSU-差分法は、OTSU³⁾アルゴリズムで画像中のフロックの画素値と背景の画素値の間の閾値を算出し、画素値が閾値以上の部分はフロックとなり、画素値が閾値以下の部分は背景とする。背景部分の画素値を 0 にすることで、背景を除去した。付着したフロックは時系列の前後で画像の同じ位置に留まるため、前後画像の一致したフロックを除去した。OTSU アルゴリズムは背景を除去する時、フロックの輪郭の情報を削除する可能性がある。

暗合成-差分法は、フロックの画素値は背景より高く、付着したフロック以外のフロックは常に動いているという特徴から、時系列の前後で画像を比較し、同じ位置の低い画素値を残すことで合成画像を作成した。合成画像には、前後画像で共通する背景と付着したフロックのみが存在する。元画像から合成画像の差分を取り、付着したフロックと背景を除去した。本手法は、画像全体から背景の画素値を削除したため、フロックの色全体的に薄くなった。

画像処理毎の予測を比較するため、Grad-Cam により、処理された画像の CNN モデル判定結果を可視化し、処理効果を検証した。

2) フロックが写っていない画像

入力データの画像サイズである 200×200 pixel トリミングにより、フロックが写っていないトリミング画像が存在しており、フロックを学習することができず、CNN モデルの精度が低下すると考えた。トリミング画像にフロックが写らない条件を抑制するため、1920×1080 pixel の画像の中央から 500×500 pixel と 800×800 pixel にトリミングし、200×200 pixel にリサイズした。各サイズでトリミングしたフロック画像を用いて構築した CNN モデルの精度を比較した。

3. 実験結果及び考察

(1) 汚れの除去

OTSU-差分法と暗合成-差分法によって処理された画像と処理前の画像を図-2 の上に示す。処理前の画像と比較して、左上に付着したフロックが除去されたことがわかる。OTSU-差分法では、フロックの輪郭が除去され、暗合成-差分法では、フロックの色が薄くなった。

それぞれの画像を用いて構築した CNN モデルの精度を図-3 に示す。OTSU-差分法で処理された画像で学習することでモデルの精度が低下した。暗合成-差分法で処理された画像で学習することで CNN モデルの精度が 72.72%と向上した。Grad-Cam で、CNN モデルが特徴とした位置を可視化した結果を図-2 の下に示す。OTSU-差分法では一部のフロックのみ特徴としていることから、CNN モデルが特徴抽出を失敗したことで、予測精度が低下したと考えられる。暗合成-差分法では、前処理なしの画像と比較して、付着したフロック箇所を特徴としていないことで、予測精度が向上したと考えられる。よって、CNN モデルはフロックの輪郭(形)を認識可能であり、暗合成-差分法により、画像からフロックの特徴を正確に抽出することに成功した。




図-2 元画像、OTSU-差分、暗合成-差分
とそれぞれのヒートマップ図

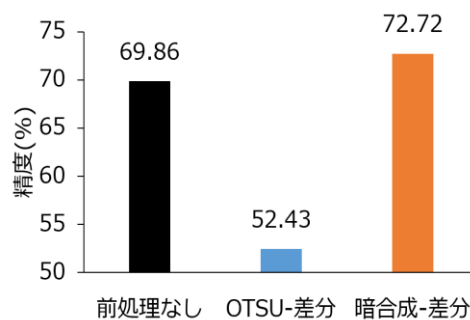


図-3 各前処理の CNN モデル精度

(2) フロックが写っていない画像

200×200 pixel、500×500 pixel、800×800 pixel でトリミングした画像を図-4 に示す。トリミングサイズが大きいほど、画面に写ったフロックの数が多いことがわかる。

それぞれのトリミング画像で構築した CNN モデルを用いてテストした結果(図-5)、トリミングサイズを 500×500 pixel にすることで、フロックが写らない問題を解決し、CNN モデルの精度が 7% 向上した。トリミングサイズを 800×800 pixel にすることで、精度が 81.51% とさらに向上した。CNN モデルは、画像から自動的に情報が抽出できるため、多数のフロックから特徴を抽出しやすいフロックを自動で認識することで、精度が向上したと考える。本研究では、特徴を抽出しやすいフロックを「有効フロック」と定義した。トリミングサイズを 500×500 pixel から 800×800 pixel にすることで、有効フロックが存在する確率が高くなり、CNN モデルは正確にフロックを認識でき、精度がさらに向上したと考えられる。



図-4 異なるサイズでトリミングした画像




図-5 各トリミングサイズの
CNN モデル精度

(3) 考察

暗合成-差分法と 800×800 pixel でトリミングの条件で処理された画像を用いて構築したモデルの精度が 81.51% となった一方で、18.49% のデータが誤答になった原因について検討した。

誤答原因にはデータ由来の誤答とモデル由来の誤答 2 つから考えられる。モデル由来の誤答は過学習などの正しくない学習プロセスに起因する。データ由来の誤答は分類境界付近の画像が分類しにくいことと学習データの不足に起因する。

過学習とは、CNN モデルは学習データに適合しすぎて、未知のテストデータに対して推定する能力が低下することを指す。過学習の有無は、CNN モデルの学習曲線から確認できる。学習曲線とは学習プロセスの中に訓練データと検証データの関係を示したグラフである(図-6)。横軸は CNN モデルの学習回数、縦軸は予測値と正解データの誤差を表す。CNN モデルの学習が進んでも、検証データと訓練データの誤差は離れていないため、過学習が発生していないことを確認した。

18.49% の誤答データの原因は分類境界付近の画像と学習データの不足 2 つがあったと考えた。分類境界付近のデータの問題は深層学習が特有な課題であり、学習データを増やしても、分類境界による精度低下の問題が解決できない⁴⁾。81.51% の予測結果を図-7 のように示す。各 Class の間に分類境界が存在する。ここで、0.5 度と 1.0 度の処理水濁度は境界濁度となり、各処理水濁度における予測精度から、分類境界に近いほど、予測精度が低下し、分類境界での予測精度が一番低かったことがわかる。これは、分類境界付近の画像が類

似していたためと考えた。分類境界による誤答の原因が存在することを確認した。解決策は、分類しにくいデータを検出し、どのくらい間違えるかを定量化することになる。しかし、分類しにくいデータはある範囲のものなので、ここで、仮に分類境界を±0.1度、つまり0.4度から0.6度と0.9度から1.1度を境界濁度と定義すると、境界濁度による誤答データは9.00%があった。残りの9.49%の誤答データは学習データの不足が原因であることが考えた。よって、学習データを増加させると、精度91%のモデルが構築できると推定した。しかし、現時点では、1年間以上のデータはないため、91%精度のモデルを構築するには必要なデータ数を、データ数と予測精度の関係から確認した。

データ数と予測精度の関係を確認するために、1年間データを減らして、2021年10月5日から2021年12月31日の3ヶ月の計267,651枚の画像データで3ヶ月モデルを構築し、2021年10月5日から2022年3月31日の6ヶ月の計509,700枚の画像データで6ヶ月モデルを構築し、2021年10月5日から2022年6月31日の9ヶ月の計783,372枚の画像データで9ヶ月モデルを構築し、同じテストデータに対して予測した結果を図-8に示す。学習データ数を増やすほど、CNNモデルの予測精度が向上しつつあることがわかる。各データ期間の予測精度は対数近似としての決定係数 R^2 は一番高く、0.98であり、91%の予測精度を達成するには、目安として、16ヶ月のデータの学習が必要と考える。




図-6 CNNモデルの学習曲線




図-7 処理水濁度における予測精度




図-8 各データ期間で構築したモデル精度

4. 結論

本研究では、連続凝集装置において、水中カメラで撮影したフロック画像を用いて CNN モデルを構築した。既往研究の前処理法によって CNN モデルの予測精度の向上が失敗した。これは撮影条件の変化による影響だと考える。そこで、凝集フロック画像の AI 判定に適した画像前処理アルゴリズムを提案した。

カメラレンズの汚れを暗合成-差分法で除去することで、CNN モデルは正確にフロックの特徴を捉えることができた。トリミングサイズを適切に増加させることで、有効フロックを正しく認識する確率が高くなる。本研究では暗合成-差分法と 800×800 pixel のトリミングの条件で、CNN モデルの予測精度が 86.9%と向上した。

18.49%の誤答原因について検討した結果、学習データの不足と境界濁度の分類困難 2 つあったと考えた。実際の境界濁度を解明するには、仮に分類境界±0.1度の境界濁度を定義し、誤答データは9.00%になった。残り9.49%の誤答データは学習データ不足が原因であると考えた。学習データ数と精度の関係から、約16ヶ月のデータを学習させることで、91%精度のモデルが構築できることが示唆された。

今後は、16ヶ月のデータを学習したモデルの精度を確認し、データ数を増やしても精度が向上しない時の境界濁度を解明する。誤答データがどれくらい間違えるかを定量化する手法を検討し、実施に導入することが可能な自律制御システムを開発する。

参考文献

- 1) LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- 2) He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- 3) Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66.
- 4) Gal, Y., & Ghahramani, Z. (2016, June). Dropout as a bayesian approximation: Representing model uncertainty in deep learning. In *international conference on machine learning* (pp. 1050-1059). PMLR.