

## 深層学習による浄水処理時のフロック画像からの 凝集後濁度予測精度の向上手法の考察

### A Study on a Method for Improving the Prediction Accuracy of Turbidity after Flocculation using Deep Learning from Floc Images in Water Treatment Process

鈴木 昭弘<sup>†</sup>      川上 敬<sup>‡</sup>      山村 寛<sup>‡</sup>      根本 雄一<sup>§</sup>      大江 亮介<sup>†</sup>  
Akihiro Suzuki    Takashi Kawakami    Yamamura Hiroshi    Yuichi Nemoto    Ryosuke Ooe

#### 1. 緒言

浄水場における浄水処理において、原水に凝集剤(PAC)を注入し攪拌することで、原水中の懸濁質(そのままでは沈殿しないコロイド粒子)を集塊したフロックと呼ばれる塊を生成する「凝集プロセス」がある。このプロセスにおいて適切な量の凝集剤を注入することは非常に重要である。なぜならフロック形成は凝集剤の多少により良し悪しが決定するからである。一方で日本の浄水場においては近似式を用いて注入量を決定しているが、安全性のために必要量以上に注入している注入過多の状態にあると言われている。確実な凝集剤の注入量の決定にはジャーテストと呼ばれる、原水に対して複数パターン量の凝集剤を注入しフロックを形成させ、良好な結果が得られるまで繰り返し注入量を追い込む試験が行われる。ジャーテストの様子を fig.1 に示す。これは凝集剤を注入した直後からの時間の経過とフロックの様子を表している。しかし、これは所要時間が長く、さらに熟練技術者の不足の問題がある。そして凝集剤の注入量と形成されるフロックの関係は複雑であり、pH、温度、アルカリ度など様々な要素で変動するため予測が困難であると言われている。

凝集剤の注入量から凝集後の上澄水濁度を予測する先行研究として、特殊なセンサーを用いて予測する方法[1]や、機械学習を用いて pH やアルカリ度といった化学的なパラメータから予測する手法[2]が提案されているが、いずれも実用化されていない。

そこで我々は先行研究のいずれとも異なる手法として、




fig.1 ジャーテストの様子

<sup>†</sup> 北海道科学大学 Hokkaido University of Science

<sup>‡</sup> 中央大学 Chuo University

<sup>§</sup> 前澤工業 Maezawa Industries

凝集中の画像に対して機械学習の一つである深層畳み込みニューラルネットワーク (DCNN: Deep Convolutional Neural Network) を用いることにより、凝集剤を注入しフロックが形成され始めた初期段階の画像から最終的な凝集後濁度の予測を行う研究を行っている。本研究の最終的な目的はこの予想モデルを利用して凝集剤の注入量が適切になるよう自律的に制御するシステムを開発することである。我々は VGG-16[3]を用いて凝集中の画像から凝集後濁度の予測を行ったところ、凝集開始後 200 秒経過後の画像を用い、0.86~0.89 程度の精度が得られることがわかった[4]。そこで本論ではより良い精度を得るためにフィルタによる前処理とデータ水増しによる手法を試みた。

#### 2. システム概要

凝集プロセス制御システムの概要を fig.2 に示す。フロック形成池にて、①フロックが形成され始める初期の水を抽出し、そのフロックの様子を画像として撮影し、②現在実験および開発中のモデルを利用して凝集後濁度を予測する。そして、予測に基づき③適切な量の凝集剤を注入するよう制御するシステムを目指している。

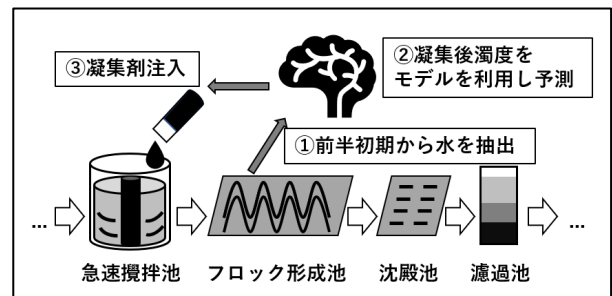


fig.2 システム概要

#### 3. 精度向上のための手法

より高い予測精度を得るための手法を検討する。本研究では凝集中の動画を凝集後濁度区間毎に 3 つのカテゴリに分け、これをデータセットとした。カテゴリ毎の動画数を Table 1 に示す。フロック画像の例を fig. 3 に示す。いずれのカテゴリの画像もぼやけた形のフロックが撮影されていることがわかる。よく確認すると動画を撮影した際に生じるブロックノイズのような細かいノイズがあることがわかった。これを除去もしくは平滑化することによって DCNN モデルが学習しやすい状況を作れる可能性があると考えた。また、凝集中はビーカー内をフロックが移動し、画像内の様々な位置にフロックが存在するため、DCNN にとって学習しにくい命題である可能性があることが考えられる。

Table 1 データセット

名称	凝集後濁度	教師データ数	テストデータ数
カテゴリ 1	0.0-0.5 NTU	35	11
カテゴリ 2	0.5-1.0 NTU	32	10
カテゴリ 3	>1.0 NTU	45	15



fig. 3 各グループのフロックの様子

そこで、(1)ガウシアンフィルタによる平滑化、(2)データ水増し、の2つの手法を用いて精度の向上が可能なのか実験を試みた。学習モデルには VGG-16 を用い、ImageNet の学習済みモデルをファインチューニングして用いた。また、データセットは動画から  $200 \times 200$  の正方形にして切り出してデータセットとした。このとき、凝集開始後 200 秒から 300 秒までの区間について画像として抜き出した。教師データとテストデータは動画ごとに 4:1 で分割した。

### 3.1 ガウシアンフィルタによる前処理

ガウシアンフィルタを用いて平滑化した画像を用いて学習を行う実験を行った。ガウシアンフィルタの適用には OpenCV を用い、カーネルサイズは 5, 11, 21, 31 の 4 種類についてそれぞれ実験を行った。標準偏差はカーネルサイズからの自動計算としている。

実験結果を fig.4 に示す。グラフは精度を表しており、フィルタを適用していない精度のラベルには “default” を付けている。“train” は教師データの精度を表し、“test” はテストデータの精度を表している。ハイフン以降の数字はフィルタサイズを表している。実験の結果、ガウシアンフィルタによる前処理によって前処理なしの場合の精度を超えるような結果は得られなかった。教師データについては 0.99 ~ 1.0 の精度を得ることができており、テストデータについてはいずれも 0.83 ~ 0.86 程度であった。カーネルサイズが 5 の場合が最も精度が良く、最大の精度で 0.86 であった。これは前処理なしの場合での精度と同一であった。また、カーネルサイズによって結果が異なると言えるほどの違いは得られなかった。一方でこの結果はガウシアンフィルタ

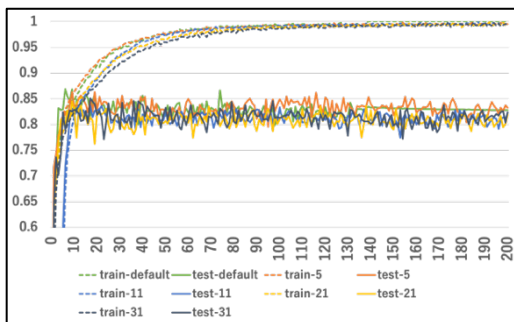


fig. 4 前処理後 (ガウシアンフィルタ) の精度

が精度に大きな影響を与えないことを示しており、今後の浄水場における実験において、画像に多くのノイズが含まれるなどの問題が生じた場合に、ノイズを平滑化するために利用するといった使い方が可能であると考えられる。

### 3.2 データ水増し

反転/平行移動/回転による手法を実験した。この時、反転は 50%、平行移動は  $\pm 40\text{px}$ 、回転は  $\pm 90$  度の範囲でランダムに行うようにした。また、水増しによる学習は 2 回実施した。実験結果を fig.5 に示す。

実験の結果、反転/平行移動/回転によるデータ水増しでは良好な精度を得ることはできなかった。教師データについて、水増し前のデータは精度が 1.0 となったが、水増し後では精度が 0.85 程度であり、200epoch 時点でも約 0.85 程度の精度であった。また、テストデータについても 0.82 ~ 0.84 前後であった。これはフロックが水中を移動していることから、平行移動や回転による水増し手法でも同様に水中を移動するような水増しになるため、大きな結果を得られなかったと考えられる。




fig. 5 水増し後 (反転/平行移動/回転) の精度

## 4. 結言

浄水処理において凝集剤を注入した後の濁度を予測するモデルの予測精度の向上の手法について検討し、ガウシアンフィルタによる前処理とデータ水増しによる精度向上を狙った実験を行った。

今回の実験によって精度の向上を得ることはできなかったが、ガウシアンフィルタについては今後の実験において活用可能であるという知見を得た。今後は異なるフィルタや、化学的パラメータも含めた複合学習による精度向上の実験を行っていく。

### 参考文献

- [1] 海老原聡美, 有村良一, 黒川太, 毛受卓, "顕微鏡電気泳動法を応用した凝集剤注入量の過不足判別手法の開発", 環境システム計測制御学会誌, Vol.19, No.2-3, pp.149-153, (2014)
- [2] Chan Moon Kim, Manukid Parnichkunn, "MLP, ANFIS, and GRNN based real-time coagulant dosage determination and accuracy comparison using full-scale data of a water treatment plant", Journal of Water Supply: Research and Technology-Aqua, Vol.66, No.1, pp.49-61, (2017)
- [3] Karen Simonyan, Andrew Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition", arXiv, Vol. 1409, No. 1556, pp.1-14, (2015)
- [4] 鈴木昭弘, 川上敬, 山村寛, 根本雄一, 大江亮介, "ディープラーニングによる浄水過程における凝集画像判定の検討", 第 18 回複雑系マイクロシンポジウム論文集, Vol.18, pp.15-18, (2019)