

浄水処理における深層学習を用いた 凝集後濁度予測の精度向上手法の検討

鈴木 昭弘[†] 川上 敬[†] 山村 寛[‡] 根本 雄一[§] 大江 亮介[†]
 北海道科学大学[†] 中央大学[‡] 前澤工業[§]

1 緒言

浄水場における原水に凝集剤(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」は重要なプロセスである。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ため、適切な注入量の決定が必要である。だが凝集剤の注入量の決定は人手で行っており自動化なされていない。

そこで、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 (fig.1)。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。

そこで本研究では機械学習の一つであり深層畳み込みニューラルネットワーク(DCNN)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段階での凝集中の画像から最終的な凝集後濁度を予測するモデルの作成を試みている。VGG-16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¹⁾。そこで本論ではより良い精度を得るためにデータ水増しとフィルタによる前処理を試みたため、この結果を報告する。

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。

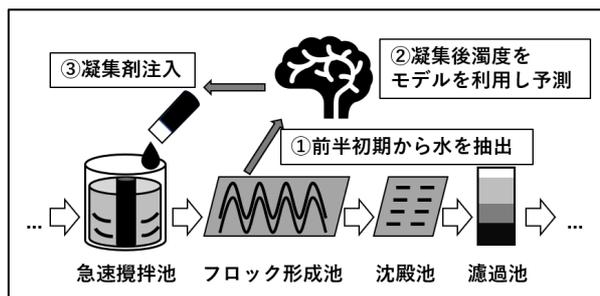


fig.2 システム概要

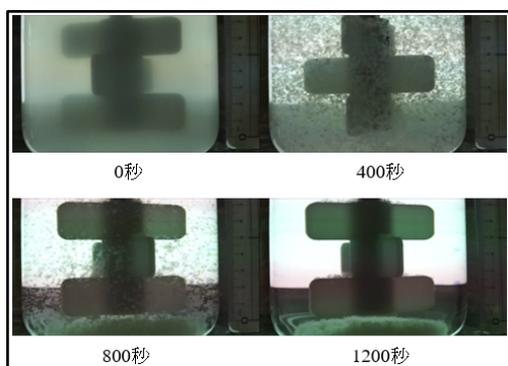


fig.1 ジャーテストの様子

3 実験

3.1 DCNN モデル

本研究ではDCNNにはVGG-16²⁾を利用した。このモデルを利用し、これまでの実験では0.86~0.89程度の結果を得ている。

最適化手法にはAdamを使用し、損失関数にはSoftmax Cross Entropyを使用した。学習はバッチサイズを500、エポック数を200にて実施した。

3.2 データセット

2018年11月~2019年3月の冬季に河川から取水し、これに対し4パターンの凝集剤を注入しそれぞれジャーテストを行った様子を撮影した動画148本を用意した。1つの原水に対して必ず同条件で2回のジャーテストを実施している。動画の長さは約23分程度である。各動画をTable 1のように凝集後濁度別に3つのカテゴリに分類した。カテゴリごとに教師データとテストデータは

A Study of Turbidity Prediction Method after Flocculation in Water Purification Process by Machine Learning
[†]Hokkaido University of Science
[‡]Chuo University
[§]Maezawa Industries

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

7.5:2.5 に分けた。教師データは合計 112 本，テストデータは合計 36 本である。

動画は 5fps で画像化し，さらにビーカーの上下中央付近かつ，パドルが写らない範囲を 200×200px の画像に切り出して使用した。教師データの画像は 56,000 枚であり，テストデータの画像は 18,000 枚である。

3.3 データの水増しと前処理手法

データの水増し手法として，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±40px，回転は±90 度の範囲でランダムに行うようにした。次に前処理としてガウシアンフィルタによる手法を実験した。これはカーネルサイズを 5, 11, 21, 31 の 4 種類について実験を行った。

3.4 実験結果：データ水増し

反転/平行移動/回転によるデータ水増しの実験結果を fig. 3 に示す。グラフは精度を表しており，特に水増しをしていない場合の精度にはラベルに “default” を付けている。また，水増しによる学習はデータセットをシャッフルし 2 回実施しており，それぞれ数字を付けて表している。

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，非水増しのデータは精度が 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。

これはブ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。

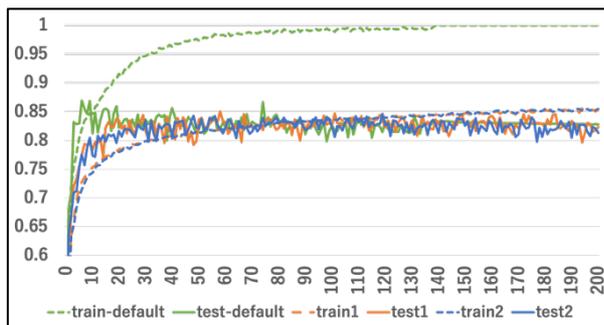


fig. 3 水増し後（反転/平行移動/回転）の精度

3.5 実験結果：前処理

ガウシアンフィルタによる実験結果を fig. 4 に示す。グラフは 3.4 節と同様に精度を表している。ラベルの末尾の数字はガウシアンフィルタのカーネル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極端に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。

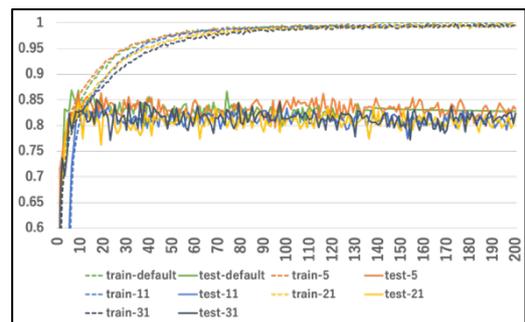


fig. 4 前処理後（ガウシアンフィルタ）の精度

4 結言

本論文では，浄水処理における凝集処理中の画像から凝集後濁度の予測を行うモデルの精度を向上させるために，データ水増しとガウシアンフィルタによる前処理の実験を行った。

実験の結果，これら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。今後は異なるデータ水増しや前処理について調査するとともに，データセットについても異なる季節や水系などのデータの拡充を行い，実験を行っていく。

参考文献

- 1) 鈴木昭弘, 川上敬, 山村寛, 根本雄一, 大江亮介: 浄水プロセス制御のための深層学習による凝集濁度予測, 第 21 回計測自動制御学会システムインテグレーション部門講演会, 2G2-02, 2020
- 2) Karen Simonyan, Andrew Zisserman: Very Deep Convolutional Networks for Large-Scale Image Recognition, arXiv, vol. 1409.1556, pp.1-14, 2015