

機械学習による浄水プロセスにおける凝集後濁度予測手法

鈴木 昭弘[†] 川上 敬[†] 山村 寛[‡] Eryanti Utami Putri[‡] 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

浄水場における浄水プロセスは原水に対し、薬品の注入、混和、凝集、沈殿、濾過など多くのプロセスを経て浄水処理を行っている。これらの中でも凝集プロセスは凝集剤を注入し原水中の懸濁質を集塊させ、フロックと呼ばれる塊を形成させるプロセスである。凝集による濾過しやすい良質（沈降性が良く大きさが適切である）なフロックの形成は非常に重要である。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。

凝集剤の注入量の決定は、ジャーテストと呼ばれる、原水に対して複数パターンの量の凝集剤を注入しフロックを形成させ、過不足の無い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、ジャーテストは所要時間が長く、さらに熟練技術者の不足の問題もある。凝集中の水からその結果の予測や注入量を制御する研究もなされている¹⁾が、現在の手法を置き換えるには至っていない。また、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。

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。最終的にはこのモデルを利用することで凝集剤の注入量を過不足なく決定し、凝集剤の注入を制御するシステムの開発を目標としている。

2 河川水によるモデルの作成

2.1 DCNN モデル

本研究では DCNN には Alexnet²⁾ と呼ばれる全 11 層からなるモデルを使用した。このモデルは層の数が少なく、シンプルなモデルとなっている。複雑な特徴を捉えるには適さないが、学習の所要時間が短く済むメリットがある。実施済みの人工河川水を用いた予備実験³⁾において、教師データで最大 97% 程度、テストデータで最大 94% の程度の精度で凝集後濁度が判定できることが判明しているためこのモデルを利用した。

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 100 にて実施した。

2.2 データセット

2018 年 11 月～2019 年 3 月に河川から取水し、その水に対し 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 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。




fig. 1 ジャーテストの様子

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

3 実験

3.1 実験の概要

実験はまず、(1)凝集後濁度の予測に適した時間帯はジャーテストより何秒経過後であるのかを把握する実験を行った。これは、ジャーテスト開始から100秒経過後から、動画を100秒区間で区切りDCNNへのデータセットとすることで、DCNNにて予測可能な最も早いタイミングを調査するものである。その後、(2)凝集後濁度の予測モデルの学習実験を実施した。(1)の実験結果から調査を行い、明らかにした観点を基に外れ値となるデータを削除したのちに学習を実施した。

3.2 (1) 予測に適した時間帯の把握

ジャーテスト開始後100秒から800秒までのデータにおいて、100秒区間で区切りそれぞれ学習した結果をfig.2に示す。教師データについては破線で囲った範囲の通り、いずれの区間においても精度はおよそ1.0に達する結果となった。テストデータにおける精度は赤丸で囲った箇所が最大値である約0.76前後となった箇所である。これは400秒から500秒までの画像群であった。500秒以降でも0.76前後に達することも確認できたが、最も早い400秒の区間を予測に用いるのが適していることが明らかになった。

3.3 (2) 凝集後濁度の予測モデルの学習実験

3.2節の結果0.76の精度で予測可能であることが明らかになったが、精度は高いとは言えない。そこで上記実験にて分類に失敗した動画データの特徴について調査し、以下の知見を得た。

① 同一の原水に対し同量の凝集剤を注入した結果、凝集後濁度は同程度であるが、その凝集過程の様子が大きく異なる場合がある (fig.3 原水A) : 原水A-1では400秒からブロックが表れるが、A-2では400秒、600秒ともにブロックが現れていない。このような動画が1ペア存在した。

② 同一の原水に対し同量の凝集剤を注入した結果、途中経過は同一だが凝集後濁度が異なる場合がある (fig.3 原水B) : 原水B-1の凝集後濁度は0.76NTU、B-2は0.44NTUとなっており、カテゴリを跨ぐほど濁度が異なっている。このような動画が6ペア存在した。




fig.2 時間帯による実験結果




fig.3 同一原水、同一凝集剤での凝集の様子




fig.4 除外後:20回試行

上記の①および②に該当する動画は学習時のノイズとなってしまうことが想定されるため外れデータとしてデータセットから取り除いた。このデータセットを用いて、3.2節と同条件で教師データとテストデータの組みを毎回ランダムにして20回学習の試行を行った。その結果をfig.4に示す。破線で囲ったデータがテストデータで最も予測精度が良かったものを表しており、最大0.94の精度で予測可能となった。また、20回学習した最大の精度の平均値は0.84であった。

以上のことから凝集結果の予測においては、①および②の観点で外れ値を除外しデータを整理することが有効であることが明らかになった。

4 結言

本論文では、浄水処理における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の予測を行うモデルの作成を試みた。実験の結果、凝集剤の注入開始後400秒~500秒の画像群をデータセットとして用いるのが適していることを明らかにした。また、凝集中の画像の特性から除外すべき特徴を持つデータを明らかにし、その結果、最大で予測精度が0.94のモデルが作成可能であることを明らかにした。今後は冬期間以外の河川水や異なる水系における実験を進めていく。

参考文献

- 1) 有村良一, 黒川太, 毛受卓, 横山雄: 画像処理型凝集センサによる水質制御システム, 第52回日本水環境学会年会講演集, p.28, 2018
- 2) 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, pp.15-18, 2019
- 3) A. Krizhevsky, I. Sutskever, GE. Hinton: Imagenet classification with deep convolutional neural networks, Adv. Neur. In., vol.25, pp.1106-1114, 2012