

## 小型凝集プラントから取得したフロック画像からの 季節性を考慮した凝集後濁度予測

### A Study of Prediction of Turbidity after Flocculation Considering Seasonality from Flock Images from a Small Flocculation Plant

鈴木 昭弘<sup>†</sup>  
Akihiro Suzuki

川上 敬<sup>‡</sup>  
Takashi Kawakami

山村 寛<sup>‡</sup>  
Yamamura Hiroshi

根本 雄一<sup>§</sup>  
Yuichi Nemoto

松川 瞬<sup>†</sup>  
Shun Matsukawa

#### 1. 緒言

浄水場における浄水処理において「凝集プロセス」は後続処理に大きな影響を与えるため重要なプロセスである。このプロセスでは原水に凝集剤を注入し攪拌することで、原水中の懸濁質を集塊したフロックと呼ばれる塊を生成する。この凝集剤の注入量の決定について浄水場は問題を抱えている。まず1つ目の問題は過剰注入の問題である。日本の浄水場では処理水の化学的なパラメータを用いた近似式により凝集剤の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状態にあると言われている。

2つ目の問題は台風や嵐などで近似式が使えない際の注入量の決定に時間がかかる問題である。このような場合の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の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、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がある。

機械学習を用いて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、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[1]が提案されているが汎化性能などの問題もあり実用化なされていない。

そこで我々は凝集中の画像に対して深層畳み込みニューラルネットワーク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[2]を行っており、フロックの画像から凝集後の濁度を予測可能であることを示した。

そこで次のステップとして本研究では浄水場での利用を想定し、より実際の環境に近い条件で凝集後濁度の予測を行うために、浄水場の敷地内に小型凝集プラントを設置した。一般的に季節によって河川の水質が異なることが知られていることから、この装置を用いて取得したデータから季節性の有無や、季節性を考慮した有効な凝集後濁度の予測手法について検討を行う。

#### 2. 小型凝集プラント

小型凝集プラントは埼玉県浄水場内に設置した。処理水量は 15m<sup>3</sup>/日であり、急速攪拌槽の混和装置の速度は 200rpm、緩速攪拌層は 30rpm である。水中カメラは緩速攪拌装置の後に設置した。カメラの解像度は 1920×1280px であり 1fps で撮影を行う。装置の概要図を fig.2 示す。センサーは原水濁度計、処理水濁度計、原水温度計、原水 pH 計、カメラ位置 pH 計を設置した。センサー値は 1 分おきに取得した。様々な水質と凝集剤の注入量の組み合わせのデータを得るために、凝集剤の注入量を 12 時間ごとに、10, 20, 40, 60mgPAC/L とランダムに切り替えた。

#### 3. データセットと前処理

小型凝集プラントから取得した 2022 年 1 月から 2022 年 3 月末までのデータ (以降 Q1)、2022 年 4 月から 2022 年 6 月末までのデータ (以降 Q2)、および Q1 と Q2 を含めた全て (以降 ALL) の 3 種類のデータセットを作成した。取得した 1920×1280px の画像データから、画像の中央部を 800×800px にクロップし、224×224px に縮小した。また、凝集剤は毎日 0 時と 12 時に凝集剤の注入量を変更してい




fig.1 ジャーテストの様子

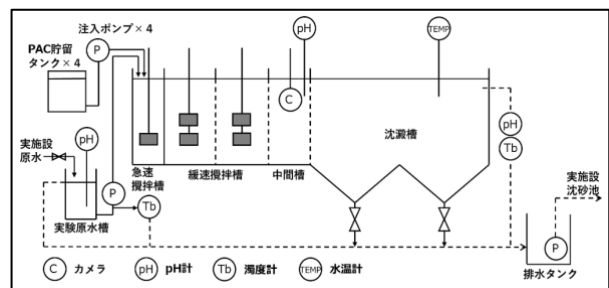


fig.2 小型凝集装置プラントの概要

<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

Table 1 学習データとテストデータの数

クォーター	学習データ	テストデータ
Q1	5,278,462	2,121,281
Q2	5,462,634	2,119,511

るため、凝集が安定するまでの 3 時間のデータを削除した。また、センサーから取得した、原水濁度、水温、カメラ位置 pH のデータを学習データに用いた。

学習データとテストデータは曜日ごとに分割し、学習データは日曜、火曜、水曜、金曜および土曜であり、テストデータは月曜および木曜とした。学習データとテストデータの数を Table 1 に示す。

#### 4. モデル

深層学習モデルとして ResNet50[3]をベースにして、凝集後濁度を出力する回帰モデルを作成した。初期重みには ImageNet で学習済みの重みを用いてファインチューニングを行った。このとき、ResNet50 への入力画像のみとし、ResNet50 の残差ブロックが出力した 2046 ベクトルの結果を 1024 ベクトルに全結合 (2 層) し、最終的に 1 ベクトルの回帰結果を出力するようにしている。

最適化手法には Adam を使用し、損失関数には MSE を使用した。バッチサイズは 100、エポック数は 200 とした。評価関数には MSE および MAE を用いた。

#### 5. 実験結果

ALL, Q1 および Q2, の 3 つのそれぞれのデータセットについて学習を行い、テストデータに対する MAE の精度が最も良かったエポックのモデルを利用し、テストデータの正解の凝集後濁度と予測した凝集後濁度の誤差のヒストグラムを fig. 3 に示す。この結果から、ALL の半年間のデータセットを全て学習したモデルと、Q1 および Q2 の 3 ヶ月毎に区切ったモデルのどちらの方が好ましいのかを検討する。

前提として我々が目標としている濁度誤差は、第一の目標としては 0.5 度以下であり、第二の目標は 0.25 度以下である。これは浄水場では凝集沈殿後の濁度が 1.0 度以下であることが求められるためである。つまり 0.5 度以下の誤差で濁度予測が可能となれば、例えば 0.5 度になるように凝集剤を注入するようにコントロールすることにより、予測誤差があっても 1.0 度以下に収めるように自律制御を行うことが可能となる。そして 0.25 度の誤差で予測可能

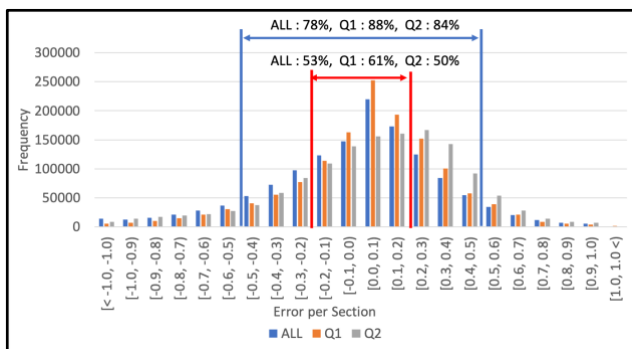


fig. 3 濁度区間ごとの誤差の頻度

になれば、例えば 0.75 度になるように凝集剤を注入すれば、濁度が高すぎず低すぎずという状態を作れるため、凝集剤の最適化が可能である。よって 0.5 度および 0.25 度を目標としている。

±0.5 度以下の濁度誤差では ALL が 78%, Q1 が 88%, Q2 が 84%のデータについてこの濁度誤差以下で予測できた。ALL の頻度が Q1 および Q2 の頻度よりも低いのは、半年間の幅広い水質の状態を学習し予測する必要があることから精度が下がったものと考えられる。一般的に河川水は季節によって水温や濁度だけではなく、水中の微生物なども異なり、それに適した浄水制御が必要になることが知られている。また、凝集剤の反応速度は水温によって異なる事も知られている。つまり、この実験の結果から、Q1 と Q2 では季節によってその水質が異なり、それがフロックの形状に影響を及ぼしていることが示唆されたといえる。一方で Q1 と Q2 については 3 ヶ月間のまだ近い状態の原水を対象としたため、ALL よりも良好な結果を得られたと考えられる。

±0.25 度以下の濁度誤差では ALL が 53%, Q1 が 61%, Q2 が 50%のデータについてこの濁度誤差以下で予測できていたことがわかる。Q2 について ALL の方が高い精度で予測可能であった点について考察する。Q1 の頻度が 61%と高いことから、ALL についても Q1 のデータについては高い精度で予測が可能であると考えられる。一方で Q2 の精度が低いことから、平均して Q2 以上かつ Q1 未満の 53%という精度になったと考えられる。

以上のことから、小型凝集装置で取得したフロックの画像と凝集後濁度には季節性があり、今回の実験から 3 ヶ月区間で区切るなどの手法は有効であることが明らかになった。今回は 3 ヶ月ごとに区切ったが、例えば季節と水温で区切る手法など複数の区切り方でモデルを分け、それらのモデルでアンサンブル学習を行うなどの手法によってより高い精度のモデルを作成できる可能性があると考えられる。

#### 6. 結言

小型凝集プラントと深層学習を用いて凝集後濁度を予測するモデルについて実験を行った。今回の実験から取得した凝集後濁度とフロック画像は季節性があり、例えば 3 ヶ月ごとに区切るなど、季節に応じたモデルとして学習することで良好な結果を得ることができるという知見を得た。

今後はより精度を高め、特に 0.25 度以下で学習が行えるように、複数のモデルによるアンサンブル学習を行うなど精度向上のためのアプローチを行っていく。

#### 謝辞

本研究は JSPS 科研費 JP22K04382 の助成を受け実施した。

#### 参考文献

- [1] Chan Moon Kim, Manukid Parnichkunm, "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)
- [2] 鈴木 昭弘, 川上 敬, 山村, 寛, Eryanti Utami Putri, 根本 雄一, 大江 亮介, "浄水プロセス制御を目的とした深層学習によるフロック画像からの凝集後濁度予測に関する研究", 計測自動制御学会論文集, Vol.58, No.5, pp.271-281, (2022)
- [3] Karen Simonyan, Andrew Zisserman, "Deep Residual Learning for Image Recognition", arXiv, Vol. 1512, No. 03385, pp.1-12, (2015)