

深層学習を用いたフロック形成中画像からの凝集後濁度の予測

A Study on Prediction of Turbidity after Flocculation from Floc Images during Flocculation using Deep Learning

鈴木 昭弘[†]川上 敬[‡]
根本 雄一[§]山村 寛[‡]
大江 亮介[‡]Eryanti Utami Putri[‡]

Akihiro Suzuki

Takashi Kawakami
Yuichi NemotoYamamura Hiroshi
Ryosuke Ooe

Eryanti Utami Putri

1. 緒言

浄水場における浄水プロセスは河川から取水した原水に対し、薬品の注入、混和、凝集、沈澱、ろ過など多くのプロセスを経て浄水処理を行っている。この中でも原水に凝集剤(PAC)を注入し攪拌することで、原水中の懸濁質(そのままでは沈澱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。なぜなら後続プロセスの沈澱、ろ過プロセスにおいて円滑に処理を行うためには良質なフロックの形成が求められるためである。この良質なフロックとは沈降性に優れ沈澱池にて多くのフロックが沈澱し、さらに大きさが適切であり、ろ過池に負荷をかけないフロックのことである。生成されるフロックの良し悪しは凝集に用いられる凝集剤の注入量の多少により決まるため凝集剤の注入量を制御および管理する仕組みが重要である。

現在、凝集剤の注入量の決定は自動化なされておらず、「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実際に凝集処理を行う試験が広く行われている。ジャーテストの様子を fig.1 に示す。ジャーテストでは 150rpm にて 2 分間の急速攪拌、30rpm にて 10 分間の緩速攪拌、回転を停止して 10 分間静置の順で実施する。凝集剤を添加した直後の 0 秒では懸濁質と凝集剤が混濁した様子であり、400 秒では細かなフロックが形成され、その後、800 秒ではフロックが沈降を始め、1200 秒では上

澄み水の透明度が高くなっている様子がわかる。ジャーテストの問題はテストとその濁度の測定に 1 回あたり 1 時間程度が必要となることである。さらに熟練した作業者の経験により行われている事も多く、属人化や熟練作業者の高齢化などの問題が生じている。さらに、浄水場における凝集剤の注入量は注入過多の状態にあると言われており、適正な注入量のコントロールによって浄水コストを下げるとともに、より安全な飲料水の提供が求められている。

自動化なされていないのは凝集の化学反応が、多くの化学的なパラメータが必要となるうえにその予測が難しいことに起因する。これは凝集の化学反応の代表的なパラメータは原水濁度、水温、pH、アルカリ度などが挙げられるが、それぞれが凝集剤の注入量との間に非線形の関係を持つ^[1]ためである。

先行研究として凝集中のフロックから画像処理的に凝集後の濁度を予測する研究もなされている^[2]。しかしこれは特殊な装置が必要であることから浄水場には導入されていない。様々な種類の人工ニューラルネットワークを用いて化学的なパラメータから予測する研究^[3]もなされているが、手法により精度が出やすい濁度区間が異なることが報告されており、統一的な手法で予測することが難しい様子がわかる。一方で、本研究で用いる手法である、フロックの形成中画像から深層学習によって凝集後の濁度を予測する研究は存在しない。

そこで我々は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モデルを作成するための実験を行った。

2. 実験

2.1 実験の目的

凝集後濁度の予測モデルを作成するために以下の観点で実験を実施した。

- (1) DCNN により河川水の凝集後濁度を予測可能であるか
- (2) 予測可能な最も早いタイミングはジャーテスト開始より何秒経過後か
- (3) 外れ値の除外によって精度の向上が可能か

1 つめの観点として、まず DCNN によって凝集後濁度の予測が可能であるのか不明であるためこれを明らかにする。




fig.1 ジャーテストの様子

[†] 北海道科学大学 Hokkaido University of Science[‡] 中央大学 Chuo University[§] 前澤工業 Maezawa Industries

また、2 つめの観点として、本システムの有効性を高めるには、できる限り早い段階で凝集後濁度の予測ができることが好ましいため、これを明らかにする。(1)および(2)を明らかにするために、凝集剤注入後からある一定時間間隔でデータセットを区切り、DCNN が最も早く予測可能となる時間帯を明らかにする実験を実施した。また、3 つめの観点として、観点(1)、(2)で実施した実験からさらに精度を向上させるため、外れ値とするデータの特徴について検討し、これを除外することで精度の向上が可能か実験した。

2.2 データセット

データセットとして河川水のジャーテストの様子を撮影した動画 148 本を用意した。動画の撮影期間は 2018 年 11 月～2019 年 3 月までの冬期間に撮影した。河川水は埼玉県吉見浄水場にて荒川水系の水を取水し利用した。ジャーテストでは凝集剤として広く使われているポリ塩化アルミニウム(PAC)を用い、注入量は 1 つの原水に対しジャーテストの際に用いられる凝集剤の量の 0.5 倍、1.0 倍、2.0 倍、4.0 倍の 4 パターンを注入した。また、ジャーテストは同条件でそれぞれ 2 回ずつ実施した。

各動画を Table1 のように凝集後濁度別に 3 つのカテゴリに分類した。この基準としては、浄水場において凝集沈殿後の濁度を 0.5 度（本研究において NTU と同値）もしくは 1.0 度と定めている事業者が多いことから、本実験では、カテゴリ 1 と 2 間の閾値を 0.5NTU とし、カテゴリ 2 と 3 間の閾値を 1.0NTU とした。

動画は画像として毎秒 5 枚で切り出した。この画像は fig.2 で矩形の枠で示したように、ジャーテスト中の画像か

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. 2 画像の切り出し



Category1 Category2 Category3

fig. 3 各グループのフロックの様子

ら攪拌用のパドルが写らず、かつ写りこみが少ない場所を選び抽出した。この時、画像は 200×200px の正方形に切り出した。切り出した各カテゴリから差異がわかりやすい画像を代表画像として fig.3 に示す。この画像のように各カテゴリによって微妙には異なるがその様子が異なることがわかる。

2.3 DCNN モデル

本研究では DCNN には Alexnet^[4]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。また、今回の実験では 1 枚の画像から凝集後濁度の予測を試みた。これは 1 枚の画像による予測は、例えばある時間範囲の複数画像からの予測やリカレント構造を持つネットワークによる予測よりも難しいと考えられ、もし 1 枚において高い予測精度を得る手法を確立できれば、そこから先述した方法を用いることにより、さらにその精度を向上させることが可能となると想定されるためである。

我々は既にカオリン溶液および標準フミン酸溶液で作成した人工河川水における学習実験^{[5][6]}を実施しており、Alexnet を使用し、教師データで最大 97%程度、テストデータで最大 94%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 を利用し、損失関数には SoftmaxCrossEntropy を使用した。学習はバッチサイズを 500、エポック数 100 として実施した。

3. 凝集後濁度の予測実験

3.1 実験のパラメータ

データセットをカテゴリごとに教師データとテストデータに 3:1 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。実験では、凝集剤を注入した 100 秒後から始め、100 秒区間毎にデータセットを区切り学習を実施した。そのため動画 1 本あたりの画像数は 500 枚である。各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。

3.2 実験結果

実験結果の学習曲線を fig.4 に示す。この図では、横軸がエポック数となっており、縦軸が精度となっている。凡例に「train」と記載しているデータは教師データを表しており、「test」と記載しているデータはテストデータを表している。コロン右側の数値は 100 秒区間の開始秒を表している。

教師データについては破線で囲った範囲の通り、100 秒から 800 秒までの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。200～400 秒、また、800 秒において精度が 1.0 となるエポックがあった。テストデータにおける精度についてはエポックによる精度の上下が大きいものの、赤丸で囲った箇所がテストデータにおける最大値の約 0.76 前後となっている箇所であり、このデータは 400 秒（400 秒から 500 秒までの画像群）である。上記の結果から 400 秒の区間が最も特徴が表れやすいと考えられることが明らかになった。




fig. 4 教師データとテストデータの学習曲線




fig. 5 400-500 秒区間の混同行列

次に、最も精度が良かった 400 秒の区間における混同行列を Fig.5 に示す。カテゴリ 3 については 0.84 と相対的に高い精度で予測できている事がわかる。一方でカテゴリ 2 に関しては 0.65 と精度が低めであることがわかる。これは同一カテゴリにけるフロックの様子にゆらぎがあるためと考えられる。これは各カテゴリのフロック画像を確認したところ、同一カテゴリ内の画像でも基本的にその様子は異なっているが、その中でも明らかにその様子が異なる見えるものが存在していたためである。そのため、カテゴリ 1 のように見えるカテゴリ 2 やその逆の画像が存在している可能性がある。すなわち外れ値が存在することにより学習精度に影響を及ぼしている可能性が考えられた。

この実験から実際の河川水を用いたジャーテスト中のフロックの画像から、精度は十分ではないものの、DCNN を用いることでフロック画像の微妙な画像の違いが学習可能であり、凝集後濁度のカテゴリ予測が可能であるということが明らかになったといえる。さらに、今回のデータでは凝集開始後 400 秒経過後から 100 秒区間のデータが最も早い段階で精度が高まるということが明らかになった。

4. 外れ値画像の検討と除外後精度の実験

4.1 実験の概要

3 章の実験結果から 0.76 という精度で凝集後濁度が予測可能であることがわかった。さらに安定した精度のモデルを得るために、予測精度の低下の原因と考えられる外れ値データについて検討と実験を行った。

4.2 外れ値とすべき画像の検討

外れ値とすべき画像の特徴を明らかにするために分類を誤った動画について検証を行った。まず、3 章の実験と同様にデータセットをカテゴリごとに教師データとテストデータに 3:1 に分け 4 回学習を実施した。このとき、必ず全ての動画が教師データにもテストデータにもなるようにした。このようにして学習したモデルの予測結果のうち、動画内に含まれる画像の 20%以上を誤って判定された動画 41 本の特徴から外れ値について検討した。

我々は実験時には必ず 2 回同じ原水に対して同量の凝集剤を注入してジャーテストを実施しており、その際の凝集後濁度とフロック画像の様子に着目した。凝集によるフロック形成はゆらぎが大きく、2 つに分けた原水に同量の凝集剤を注入したとしても、微細なパラメータの違いによりその様子が異なることがある。これが大きく異なる場合は学習に悪影響を及ぼす可能性があると考えられるため、これを外れ値として除外することとした。そこで以下のような凝集過程と凝集後濁度の結果の組み合わせを想定した。

- (1) 凝集過程がほぼ同一であり、凝集後濁度も近い
- (2) 凝集過程がほぼ同一であり、凝集後濁度が異なる
- (3) 凝集過程が大きく異なり、凝集後濁度は近い
- (4) 凝集過程が大きく異なり、凝集後濁度も異なる

まず、(1)については問題の無いパターンである。(2)は外れ値とした。これは本研究では凝集中の画像から凝集後濁度を予測するため、凝集過程が同一であるならば、凝集後濁度も同一でなくては分類器が正しく学習できないと考えられるためである。(3)についても外れ値とした。これは凝集過程が多少異なる程度であれば問題ないが、異なるカテゴリの画像と酷似するほどであれば分類器のノイズとなってしまう可能性が考えられるためである。(4)については問題無しとした。これはゆらぎとして生じるパターンであり、凝集過程もその結果も異なるのであれば、分類器は正しく学習可能であると考えられるためである。

上記の観点に基づいて分類に失敗した各動画のペアについて、凝集過程がほぼ同一か、それとも大きく異なるのかを目視での確認を実施した。この結果、いくつかの外れ値といえる動画があることがわかった。観点毎の動画の本数を Table2 にまとめる。表の動画 No.のハイフン記号はその 2 つの動画が同一原水に同一量の凝集剤を注入したペアのデータであることを表している。

観点(2)については 7 ペアが該当した。この動画の凝集過程の推移の様子の例を fig.6 に示す。画像左には動画 No.と括弧内に凝集後濁度を記載している。そしてそれぞれの動画の 400 秒、600 秒、800 秒経過後の画像を表した。凝集後濁度は 0.76NTU と 0.44NTU であり、差は 0.32NTU と差異が大きい。S139 はカテゴリ 2、S143 はカテゴリ 1 に分類される動画であり、カテゴリを跨いでしまっている。しかし、凝集過程をみると 400 秒、600 秒、800 秒のいずれにおいても、フロックの量、大きさ、濃さともにほぼ同じよ

Table 2 外れ値とする動画

観点	ペア数	動画 No.
(2)	7	S2-S6, S19-S23, S89-S93, S98-S102, S122-S126, S139-S143, S155-S159
(3)	1	S90-S94




fig. 6 観点(2)の凝集中画像




fig. 7 観点(3)の凝集中画像

うに見て取れる。凝集過程から凝集後濁度を予測するためには、凝集過程がほぼ同一の場合はその結果の予測が不可能であるといえる。ほかの 6 つのペアについても同様な結果であった。

次に観点(3)については 1 ペアが該当した。この動画の凝集過程の推移の様子を fig.7 に示す。凝集後濁度は 0.89NTU と 0.78NTU であり、差は 0.11NTU であることから濁度に大きな差は見えず、両方ともカテゴリ 2 に分類される動画である。凝集経過を見ると S90 は 400 秒時点でうっすらとフロックが生成されており、600 秒にはフロックがやや大きくなり、800 秒ではフロックが濃くなる様子が見て取れる。一方で、S94 をみると 400 秒時点ではほぼフロックは見られない。これは 600 秒においても変わらない。そして 800 秒でやっとフロックが見て取れ、その様子は S90 の 400 秒経過後の画像と酷似する。このように 2 つの動画のペアにおいてその様子が大きく異なる場合は、どちらが正しい凝集過程かわからずノイズになってしまう事が感られることから、このペアを外れ値として除外した。

4.3 外れ値除外後の精度の学習実験

外れ値を除外したデータセットを用い、学習実験を行った。パラメータは 3 章と同様である。ただし、データセットに含まれる画像の枚数は外れ値を除外したことにより合計 74,000 枚から 67,000 枚に減っている。各教師データの画像は 50,250 枚であり、テストデータの画像は 16,750 枚である。教師データとテストデータの組をランダムにし、20 回学習を行った。

その結果、20 回学習したうちの最大の精度は 0.944 であり、最小の場合で 0.772 であった。20 回実施した各学習の最大の精度の平均は 0.839 であった。精度が最も高くなった 0.944 の際の混同行列を fig.8 に示す。3 章の実験では特に精度が低かったカテゴリ 2 の動画について、その精度が 0.92 と大きく精度が向上している様子が見える。

外れ値を除外することで、データの組に依存するものの精度の向上が得られ、最大で 0.944 の精度で凝集後濁度を




fig. 8 外れ値除外後の混同行列

予測可能であることが明らかになった。以上のことから、ジャーテスト時に生成されるフロックの様子はゆらぎが大きいことを再確認するとともに、我々が提案した 2 つの観点による外れ値の除外が有効であることを明らかにしたといえる。一方で、未だに教師データとテストデータの組によって精度が上下する様子が見て取れ、改善が必要であるという知見も明らかになった。

5. 結言

本論文では浄水処理における凝集プロセスの制御を行うシステムを開発するために、凝集中のフロック画像からの DCNN を用いて凝集後濁度の予測を行うモデルの作成を試みた。冬期間の河川水を用いた実験を実施した結果、(1)DCNN を用いることにより河川水の凝集後濁度を予測可能である、(2)ジャーテスト開始後 400~500 秒の区間のデータを用いるのが最も早くかつ予測精度も高まる、(3)外れ値とするべきフロックの特徴を明らかにし、これを除外することで精度が向上することを明らかにした。

今後の展望として、夏期間のデータや異なる水系のデータを集め、様々なデータについて学習実験を行うことにより、より適したモデルの作成を行っていく。

参考文献

- [1] 永田悦史, 三浦良輔, "II. 浄水処理制御技術", 電気学会雑誌, vol.104, No.12, pp.1069-1072, (1984)
- [2] 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)
- [3] 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)
- [4] A. Krizhevsky, I. Sutskever, GE. Hinton, "Imagenet classification with deep convolutional neural networks", Advances in neural information processing systems, Vol.25, No.2 pp.1106-1114, (2012)
- [5] 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)
- [6] Hiroshi Yamamura, Eryanti Utami Putri, Takashi Kawakami, Akihiro Suzuki, Herto Dwi Ariesyady, Takaaki Ishii, "Dosage optimization of polyaluminum chloride by the application of convolutional neural network to the floc images captured in jar tests", Separation and Purification Technology, Vol.237, No.116467, pp.1-6, (2020)