

4. 中小河川感潮域の水面浮遊物判定CNNの構築

Automatic Distinction of Floating River Litter in Tidal Area using Convolutional Neural Network

技術支援課 ○高崎 忠勝、枝澤 知樹

1. はじめに

石神井川等の感潮域では、しばしばスカムやゴミ等の浮遊物による河川景観の悪化や悪臭の発生が問題となっている。スカムとは河床に堆積した有機性の懸濁物質が水面に浮上したものであり、感潮域に位置する多くの中小河川で確認されている^{1~3)}。

スカムが問題となっている河川では、さまざまなスカム対策の取り組みが行われており⁴⁾、こうした取り組みの効果を沿川住民に示す方法として定量的なスカム浮遊量を用いた説明が考えられる。例えば、呑川では将来的な水質改善の目標値として、水面のスカムが占める面積割合1%以下することが示されている⁵⁾。実際の河川水面の状況をモニタリングし、水面のスカムが占める面積割合を継続して示すことで、経年的なスカム浮遊量の変化を把握することができる。

これまでに、AIの一種である多層パーセプトロン (Multilayer perceptron : MLP) を用いることにより、定点カメラ画像から河川水面上に浮遊しているスカムの程度を判定することが可能となっている^{6,7)}。しかし、このMLPモデルでは20×20ピクセルの矩形範囲毎にスカムの多少を判定しており、呑川の将来的な水質改善の目標値で記されているような面積割合1%といった詳細な判定には使用できない。

近年、AIを用いた画像認識においては畳み込みニューラルネットワーク (Convolutional neural network : CNN) が多く用いられており、画像認識のテストに利用できるオープンデータセットも公開

されている。また、AIモデルのプログラム作成においては、TensorFlowやPyTorch等の機械学習ライブラリが利用できるようになっている。

こうした背景のもと、東京都立大学との共同研究によりCNNを用いた高解像度の水面浮遊物の判定に取り組み、1ピクセル毎の判定を行うCNNモデルを構築した^{8,9)}。

2. 水面浮遊物判定CNNモデル

スカムやゴミ等の浮遊物は時間経過によって移動するため、浮遊物の実態を把握するにはビデオ映像や一定時間間隔で撮影したカメラ画像を分析する必要がある。本検討では石神井川感潮域において2016年に定点撮影したカメラ画像を用いて検討を行った。

図-1に示すように王子駅付近の石神井川右岸にインターバルカメラを設置した。



図-1 カメラ設置地点

図-2にインターバルカメラによって取得した画像の例を示す。画像はサイズが1280×720ピクセルのカラーのデータとなっている。10分間隔で撮影を行っている。本検討では目視で多くの浮遊物を確認した9月8日、9月9日、9月16日、9月17日の4日間の画像を用いた。

図-2をみると水面に空や電線、周囲の建物が映っていることが分かる。水面への映り込みは気象の状況によって異なる。このため、1ピクセルのみの色情報では浮遊物を適切に判定することができず、周囲のピクセルの色情報も含めて判定する必要がある。そこで、図-3のように矩形範囲の色情報を用いて、中心部分のピクセルに映っているものを判定することとした。

また、画像には水面以外の部分が多く含まれていることが分かる。感潮域では潮汐によって水位が時々刻々と変化し、画像毎に水面の範囲が異なるため、水面と水面以外を判定する必要もある。

浮遊物にはスカムの他に落葉や枝、発泡スチロール等、様々なものがあるが、本検討では、スカム以外の浮遊物は全てゴミとして取り扱うこととした。

水面浮遊物を判定するCNNモデルは、矩形範囲の中心部分が、「水面以外」「浮遊物なし」「ゴミ」「スカム」の4種類のいずれの状態であるかを判定するものである。画像から抜き出す矩形範囲を移動させながら判定を行うことで、画像における水面に占めるスカムやゴミが占める割合を求めることができる。

図-4に構築したCNNモデルの構成を示す。入力層、畳み込み層・プーリング層が2層、全結合層が2層、出力層となっている。

入力層には読み込んだ画像から抜き出した33×33ピクセルの色情報を入力する。色情報はRGBあるいはHSVの3チャンネルの情報である。

出力層のユニット数は4であり、各ユニットがそれぞれ「水面以外」「浮遊物なし」「ゴミ」「スカム」の状態に対応し、最も値が大きいユニットが受け持つ状態が判定結果となる。

CNNのプログラム作成には、プログラミング言語Pythonおよび機械学習ライブラリPyTorchを用いた。



図-2 カメラ画像の例




図-3 入力情報と判定対象




図-4 水面浮遊物判定CNNの構成

3. 教師データの作成

CNNモデルが適切な判定をできるようにするには、模範解答を付したデータを用いて学習を行う必要がある。また、CNNモデルの判定の妥当性を検証する際にも模範解答が必要となる。この学習や検証に用いる模範解答を付したデータを教師データという。

学習に用いるデータ（以下、学習データ）には、9月8日、9月9日、9月16日の3日間の画像を用い、検証に用いるデータ（以下、検証データ）には、9月17日の画像を用いた。画像の各ピクセルが「水面以外」「浮遊物なし」「ゴミ」「スカム」のいずれの状態に該当するかを目視で判定した。暗部等で判別できないものは「不明」とした。

目視で画像の全ピクセルを判定すると膨大な手間を要するので、10×10ピクセルに対して1ピクセルを判定対象とした。また、判定作業を容易にすることを目的として図-5のように判定結果の入力を支援するプログラムを作成した。このプログラムでは目視による判定を容易にするため、通常の画像と色反転させたネガポジ画像の両方を見ながら作業を行うことができる。

学習データと検証データに用いた全ての画像において「水面以外」と判定した部分と「不明」が多い部分は、CNNモデルによる判定の対象外とした。検討に用いた学習データと検証データの数を表-1に示す。学習データに占める各状態の割合は、「水面以外」13%、「浮遊物なし」69%、「ゴミ」6%、「スカム」12%であり、「浮遊物なし」の割合が大きくなっている。また、検証データについては、「水面以外」7%、「浮遊物なし」70%、「ゴミ」10%、「スカム」13%であり、学習データの割合と大きくは変わらない。

4. RGBデータによるCNNモデル

図-4に示したCNNモデルについて表-1の学習データを用いて学習を行った。CNNモデルに入力する際の色情報は、Red、Green、Blueで構成されるRGBを用いた。学習においてはドロップアウトとバッチノーマライゼーションを適用した。

学習の進捗による判定能力の変化を把握するために、学習回数を1、10、20、30、40、50epochとした




図-5 教師データ作成支援プログラム

表-1 教師データ数

	学習データ	検証データ	計
水面以外	125,629	16,815	142,444
浮遊物なし	687,450	171,260	858,710
ゴミ	55,638	24,486	80,124
スカム	123,429	31,131	154,560
計	992,146	243,692	1,235,838




図-6 学習回数と正答率

ときのCNNモデルを用いて学習データおよび検証データに対して判定を行った。CNNモデルの出力と教師データが一致している割合を正答率とし、正答率と学習回数との関係を図-6に示す。

学習データに対する判定は、20epoch以上の学習で95%以上の正答率となった。また、実際の判定能力に大きく関係する検証データに対する判定は、20epoch学習時に84.0%の正答率となった。

20epoch学習時のCNNモデルを用いて画像を判定させた例を図-7に示す。出力結果において「水面以外」は無着色、「浮遊物なし」は水色で着色、「ゴミ」は黄色で着色、「スカム」は赤色で着色している。判定結果のピクセル数をみると「水面以外」が55200ピクセル、「浮遊物なし」が265250ピクセル、




図-7 入力画像と出力結果

表-2 学習データに対する判定

色空間	画像処理	正答数	正答率
RGB	なし	944,553	95.2%
	Bilateral Filter	943,968	95.1%
	CLAHE	945,309	95.3%
HSV	なし	945,178	95.3%
	Bilateral Filter	944,239	95.2%
	CLAHE	946,011	95.3%

表-3 検証データに対する判定

色空間	画像処理	正答数	正答率
RGB	なし	204,609	84.0%
	Bilateral Filter	203,894	83.7%
	CLAHE	201,675	82.8%
HSV	なし	201,548	82.7%
	Bilateral Filter	199,879	82.0%
	CLAHE	201,017	82.5%

表-4 アンサンブルの重み

色空間	画像処理	重み
RGB	なし	0.694
	Bilateral Filter	1.000
	CLAHE	0.375
HSV	なし	0.768
	Bilateral Filter	0.606
	CLAHE	0.384

「ゴミ」が26663ピクセル、「スカム」が81642ピクセルである。水面部分は「浮遊物なし」と「ゴミ」と「スカム」を合わせた373555ピクセルとなる。以上からゴミが水面に占める割合は7%、スカムが水面に占める割合は22%になる。

5. アンサンブル学習

RGBデータを用いたCNNモデルにより水面浮遊物を判定できるようになったが、判定精度の一層の向上を図るためにアンサンブル学習の適用について検討する。

アンサンブル学習は、独立した複数の判定結果を用いて最終的な判定を行う方法であり、画像の判定にアンサンブル学習を適用することで性能が向上した事例も報告されている¹⁰⁾。

表-2に示す6種類の色空間・画像処理を適用したデータセットによって学習させたCNNモデルを用いてアンサンブル学習の有用性を確認する。適用する色空間はRGBとHSVの2種類、画像処理についてはバイラテラルフィルタ (Bilateral Filter) と適用的ヒストグラム平坦化 (Contrast Limited Adaptive Histogram Equalization: CLAHE) および処理なしの3種類である。なお、HSVは色相 (Hue)、彩度 (Saturation Chrome)、明度 (Value Brightness) で構成される色空間である。また、Bilateral Filterはノイズ除去に用いられ、CLAHEは画像のコントラストを上げる目的で使用される。

色空間・画像処理の適用は、カメラ画像から抜き出した33×33ピクセルのカラーデータに対して画像処理および色空間の変換処理を行った後に、CNNモデルに入力することで行う。

各CNNモデルについて20epochの学習を行い、判定を行った。学習データに対する判定結果を表-2に、検証データに対する判定結果を表-3に示す。1つのデータセットを用いた場合の正答率は、学習データに対しては95.1~95.3%となり、検証データに対しては82.0~84.0%となった。正答率が最高となるデータセットは、学習データに対しては色空間HSV・画像処理CLAHEの組合せであるが、検証データに対しては色空間RGB・画像処理なしの組合せとなり、学習と検

証で異なる。

アンサンブルでは各CNNモデルに重みを付け、全CNNモデルの出力とモデルの重みから最終的な判定結果を決定する。学習データに対する正答数が最大になるように設定した重みを表-4に示す。この重みを用いた判定の正答率は学習データに対して95.6%、検証データに対して84.2%となり、1つのデータセットを用いた場合より高い正答率が得られた。

6. 実運用に際して

実際にスカムのモニタリングを行う場合、さまざまな気象条件においても水面の状態が分かる画像を取得できるようにする必要がある。河川に浮遊しているスクムは時間と共に位置が変わるため、短い時間間隔での画像取得が望ましい。

次に、CNNモデルの学習データを作成するための画像を取得する必要がある。取得する画像には、ゴミやスクム等、今後の判定時に画像に映ることが考えられるものが含まれるようにする。

取得した画像からピクセルに映っているものを目視で判定して学習データを作成する。本検討では、「水面以外」「浮遊物なし」「ゴミ」「スクム」の

4種類の判定としている。CNNに適切な判定を行わせるには多くの学習データが必要であるが、学習データの作成には多くの労力を要する。このため学習データ作成労力の軽減化を図ることが望まれる。

7. まとめ

スクム浮遊量の把握に向けて、東京都立大学との共同研究でカメラ画像から水面浮遊物を判定するCNNモデルを構築した。

構築したモデルは定点カメラ画像をもとに、潮汐によって変化する水面の範囲や水面に浮遊しているゴミ・スクムを判定できることを確認した。

スクム浮遊量を継続的にモニタリングすることによって、スクム対策の取り組みの効果を分かりやすく示すことができると思われる。

CNNモデルを用いることでスカムの継続的なモニタリングを比較的容易に行うことが可能であるが、現状ではCNNモデルの学習に用いるデータ作成に多くの労力を要するため、この作業の軽減化に向けた技術開発が望まれる。本技術がスクム対策の推進につながることを期待する。

参 考 文 献

- 1) 山崎正夫、津久井公昭 (1991) : 河川におけるスカムの発生に関する研究 (その1) スカムの起源に関する研究、東京都環境科学研究所年報、1991
- 2) 山崎正夫、津久井公昭 (1991) : 河川におけるスカムの発生に関する研究 (その2) 一神田川白鳥橋～飯田橋間の堆積状況調査結果一、東京都環境科学研究所年報、1991-2
- 3) 山崎正夫、津久井公昭 (1992) : 河川におけるスカムの発生に関する研究 (その3) 一降雨後のたい積状況変化について一、東京都環境科学研究所年報、1992
- 4) 北区土木部道路公園課公園河川係：石神井川の臭気対策・環境改善に取り組んでいます、<https://www.city.kita.tokyo.jp/d-douro/jutaku/kankyo/bika/documents/syukitaisaku.pdf>
- 5) 呑川水質浄化対策研究会(2020)：令和元年度呑川水質浄化対策研究会報告書、http://www.city.ota.tokyo.jp/gikai/honkaigi_iinkai/iinkai/iinkaishiryo/r_2/machidukuri/020305.files/04-1_machi_2.3.5.pdf
- 6) 水田周作、高崎忠勝、河村明、天口英雄、石原成幸(2015)：定点カメラ画像を用いたニューラルネットワークによる都市河川のスクム自動判別、土木学会論文集B1(水工学)、Vol. 71, No. 4, I_1231-I_1236
- 7) 大澤健二、石原成幸、高崎忠勝(2015)：定点カメラを用いた都市河川のスクム自動判別、平27.都土木技術支援・人材育成センター年報、pp. 201-204

- 8) 加藤奨之、高崎忠勝、河村明、天口英雄、芥田直輝 (2021) : 定点カメラ画像を用いた石神井川感潮域の水面浮遊物判定モデルの構築、第48回土木学会関東支部研究発表会講演集、II-58
- 9) 芥田直輝、高崎忠勝、河村明、天口英雄、加藤奨之 (2021) : アンサンブル学習を用いた石神井川感潮区間の水面浮遊物判定、第48回土木学会関東支部研究発表会講演集、II-68
- 10) 杉原麻美子、Zheng YuchenZheng、内田誠一 (2018) : CNNを用いたアンサンブル学習による画像分類、電気関係学会九州支部連合大会講演論文集、平成30年度電気・情報関係学会九州支部連合大会 (第71回連合大会) 講演論文集、セッションID 01-2P-03、p. 416