

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

東京都立大学大学院	都市環境科学研究科	学生会員	○芥田 直輝
東京都建設局	土木技術支援・人材育成センター	正会員	高崎 忠勝
東京都立大学大学院	都市環境科学研究科	正会員	河村 明
東京都立大学大学院	都市環境科学研究科	正会員	天口 英雄
東京都立大学	都市環境学部	学生会員	加藤 奨之

1. はじめに

東京都内を流れる石神井川の王子駅付近では、しばしばスカムやゴミ等の浮遊物の滞留がみられ（写真-1参照）、悪臭や河川景観の悪化が問題となっている¹⁾。著者らは、浮遊物を解消する対策の支援を目的とし、定点カメラ画像から水面浮遊物を定量的に把握するAIモデルを開発している²⁾が、実用化に向けては更なる判定精度の向上が望まれる。判定精度の向上を図る手法の一つとしてアンサンブル学習がある。アンサンブル学習は、独立した複数の識別器の判定結果を用いて判定を行う方法であり、個々の識別器が間違えた判定



写真-1 スカムの発生状況

をしても最終的には正しい判定ができる可能性があり、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³⁾。本研究では、異なる色空間と画像処理を適用したデータセットによって学習させた複数の畳み込みニューラルネットワーク（以下、CNNと記す）を用いてアンサンブル学習の有用性を検証する。

2. 水面浮遊物判定モデル

本検討で用いたCNNは、特に画像認識の分野で優れた性能を発揮しているネットワークである。本モデルは、1280ピクセル×720ピクセルの写真-1のような定点カメラ画像を読み込み、1ピクセルごとに情報を出力するモデルである。入力層では、33ピクセル×33ピクセルの矩形ごとに色情報を3チャンネルで読み込む。そして、矩形の中心1ピクセルの情報を4通りに出力するモデルとなっている。出力される情報は、「護岸などの水面以外の箇所」、「浮遊物がない水面」、「ゴミや落ち葉が浮遊している水面」、「スカムが浮遊している水面」の4通りである。中間層は、畳み込み層、プーリング層、全結合層をそれぞれ2層ずつで構成されている（図-1参照）。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する。各層のユニット数、教師データの諸元、学習用・検証用データの諸元などについては既往モデル²⁾と同様であり、そちらを参照されたい。




図-1 検討モデルの概要

キーワード 畳み込みニューラルネットワーク、アンサンブル学習、石神井川、浮遊物、スカム

連絡先 〒192-0397 東京都八王子市南大沢1-1 東京都立大学 E-mail: akuta-naoki@ed.tmu.ac.jp

3. アンサンブル学習

本検討では、表-1 に示す 6 つのデータセットによって学習させた CNN を用いる。なお、各データセットに示す値は、既往モデル²⁾で最も判定精度が良いと判断した 20epoch 学習時のものである。データセットに用いる色空間は、Red, Green, Blue で構成される RGB と色相 (Hue)、彩度 (Saturation Chroma)、明度 (Value Brightness) で構成される HSV の 2 種類である。適用する画像処理は、ノイズ除去に用いられるバイラテラルフィルタ (Bilateral Filter) と画像のコントラストを上げる目的で使用される適用的ヒストグラム平坦化 (Contrast Limited Adaptive Histogram Equalization : CLAHE) である。

表-1 に示すように 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。正答数が最大となるデータセットは学習データに対しては HSV・CLAHE であるが、検証データに対しては RGB・画像処理なしであり、異なるデータセットとなった。

アンサンブル学習においては 6 つの CNN に対して重み付けを行う。学習データを用いて正答数が最大になるように各 CNN の重みを SCE-UA 法⁴⁾を用いて求める。重みの値は表-1 に示すように最大が RGB・Bilateral Filter の 1.000 であり最小が RGB・CLAHE の 0.375 となった。

表-1 に示した重みによって 6 つの CNN を用いた判定結果を表-1 のアンサンブル欄に示した。アンサンブルの正答率は学習データに対しては 95.6%、検証データに対しては 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を得られた。

4. むすび

色空間と画像処理が異なる 6 つのデータセットによる CNN に重み付けをし、アンサンブル学習を行った。アンサンブル学習を行うことによって学習データだけではなく検証データについても正答率が高くなることを確認した。

表 - 1 アンサンブル学習

データセット		学習データに対する判定		検証データに対する判定		重み
色空間	画像処理	正答数	正答率	正答数	正答率	
RGB	なし	944,553	95.2%	204,609	84.0%	0.694
	Bilateral Filter	943,968	95.1%	203,894	83.7%	1.000
	CLAHE	945,309	95.3%	201,675	82.8%	0.375
HSV	なし	945,178	95.3%	201,548	82.7%	0.768
	Bilateral Filter	944,239	95.2%	199,879	82.0%	0.606
	CLAHE	946,011	95.3%	201,017	82.5%	0.384
アンサンブル		948,688	95.6%	205,168	84.2%	—

参考文献

- 1) 高崎忠勝, 枝澤知樹, 川合将文: 石神井川感潮区間の流れに関する分析, 令和元年. 東京都建設局土木技術支援・人材育成センター年報, pp.74-78, 2019.
- 2) 加藤奨之, 高崎忠勝, 河村明, 天口英雄, 芥田直輝: 石神井川感潮域における水面浮遊物判定モデルの構築, 第 48 回土木学会関東支部技術研究発表会 第 II 部門, 2021.
- 3) 杉原麻美子, Zheng Yuchen, 内田誠一: 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, 2018.
- 4) Duan Q, Sorooshian S, Gupta VK. : Effective and Efficient Global Optimization for Conceptual Rainfall-Runoff Models, Water Resources Research, 28-4: 1015-1031, 1992.