

第II部門

定点カメラ画像を用いた深層学習による河川スカムの定量的解析

大阪大学工学部 学生会員 ○奥村素生
大阪大学大学院工学研究科 正会員 西田修三

大阪大学大学院工学研究科 正会員 中谷祐介

1. はじめに

大阪の都市河川において、スカムの発生が問題となっている。スクムは河床に堆積した底泥のうち、有機物の多い表層が嫌気ガスを発生することによって浮上し、悪臭を放ちながら河川を浮遊するものである。従って、水辺の整備が進められている近年においては、この発生を防止することや早期回収を行うことは重要な課題となる。しかしながら、スカムの挙動は明らかにされておらず、発生防止や回収をするための有効な対策はまだ提案されていない。

本研究で対象とするのは図-1に示すような感潮河川の平野川であり、その中流部に架かる剣橋である。また、剣橋には大阪府により河川カメラが設置されており、1分毎に川面を撮影している。この条件から、画像解析によってスカムの有無やその量を推定し、スカムの挙動を解析した。



図-1 対象流域

2. 解析手法

定点カメラにより撮影された画像の解析を行った。近年、人工知能の発達により、車の自動運転など画像を認識する技術が発展している。その中でも、本研究においては物体の色や形状を学習し、認識することのできる畳み込みニューラルネットワーク(Convolutional Neural Network 以下 CNN)の手法を用いた。また、CNN ネットワークには VGG16¹⁾と呼ばれるモデルが存在しており、これも最適なスクム判別モデルを決定するためのモデルとして用いた。VGG16 は様々な画

像を学習して基本的な物体の形や色などのパラメータを保存している。このネットワークの出力層のみを自身のデータを用いて学習することで、保存されたパラメータを転用することができる。

本研究においては画像を大量に扱ったので、プログラミングのライブラリに Keras を導入し、GPU を用いて計算を行った。

3. 使用データ・評価方法

用いたデータは、大阪府河川カメラにより撮影された2017年12月29日7:00から17:00の1分毎の画像データである。このデータには橋や車などが写っているため、図-2のように黒く塗りつぶした。

画像判別においては、スクムが水面を占める量を基に分類を行い、解析を行った。スカムの量は、画像内のスカムの部分に色を塗り、その色が水面の何パーセントを占めるかという川面の被覆率として算出した。

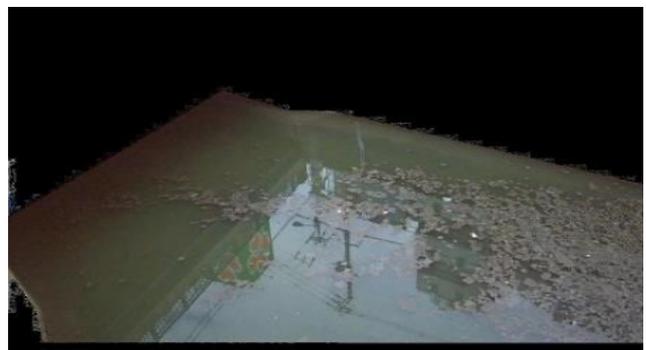


図-2 使用データ(大阪府河川カメラ)

分類はスクム量に応じたクラスに分け、本研究では「2クラス(0%、~100%)」、「3クラス(0%、0~80%、80~100%)」、「5クラス(0%、0~30%、30~60%、60~90%、90~100%)」の3種類に分類した。分類を行った理由としては「スカムの有無」「スカムの有無と、多量発生」「スクム量の大別」を行うためである。分類として見やすく、また、元データでどの分類クラスにも学習に十分なデータ数があるように分けた。

評価は、分類したクラスごとに学習データと検証データに分け、100回学習した。そして、各学習を終え

るたびにクラスを分類できた正答率(%)と損失値 RMSE を式(1)のように算出し、これを評価の対象とした。つまり判別に適したモデルとは、100回の学習が終わった時点で正答率が高く、尚且つ RMSE も小さいモデルということになる。

また、用いた CNN のネットワークは、畳み込みと最大値プーリングを各 4 回行うものとし、VGG16 は出力層のみ解析用に変更した。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{n=1}^N (Y_{\text{actual}} - Y_{\text{predict}})^2} \quad \dots \quad (1)$$

4. 結果

CNN での検証では、どの分類においても学習回数を増すごとに精度が上昇し、RMSE は下降していた。最終的には、2クラス、3クラス、5クラス、どの分類においても正答率が 90%を上回り、RMSE も 0.4 を下回った。一方 VGG16 の検証では、3クラスの分類のみ高精度となったが、全体として良好な結果は得られなかった。従って、スカムの判別においては CNN の 5クラス分類を行ったものを採用した。

更に、スカムの被覆率を CNN がどのように判定したかを出し、観測値と比較した。これを図-4 に示す。この図において、横軸は時間で、縦軸は判別された推定値である。ただし、この図においてはクラスの中央値を%で表示している(0%,15%,45%,75%,95%)。赤い点はモデルが判別したクラスで、黒い実線は実際に観測したスカム量である。スカムのピーク時は上手く検出できているが、スカムが少ない時は量を過大評価してしまっていることがわかる。

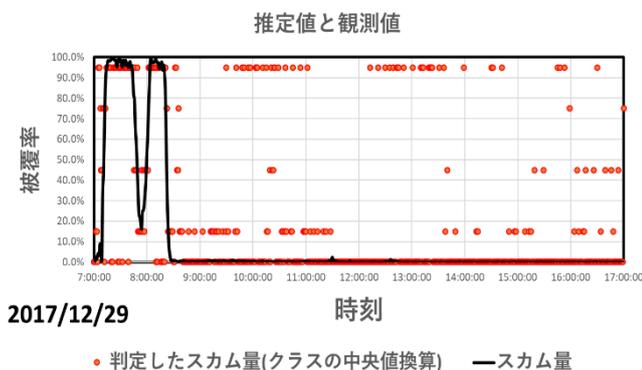


図-4 判定したスカム量の時間推移

5. 考察

スカムの被覆率を推定する際、値が小さい時や、0である時に過大に評価してしまっていることが課題となる。何故、過大に評価をするのかを確認するために、実際にどのような学習が行われているのか、どのようなパラメータになっているのかを見直す必要がある。

また、今回はデータ数が少なかったために、各クラスのスカム量を上手く特徴として抽出できなかった可能性がある。この問題を解決するには、まずはデータ数を増やすこと、また、画像を回転や反転をさせて水増しを行うなどの操作を行うことが望ましい。

6. 結論・展望

本研究で得られた知見として、CNN のネットワークでは、スカムの多い状態の挙動を追うことはできるが、微量時は判定を誤ることが多いということが挙げられる。データ数が少ないという課題が残ったが、実際に増えたとしても、確実な結果になるとは限らない。そのためにも、学習過程の明確化と修正が必要になる。

また、このようにスカムの量を判別できるようになり、複数個所で観測を行うことでスカムの発生や移動経路などの挙動解析が可能となる。その際に、潮汐や気象現象などとの関連性も見出すことで、より具体的なスカムの挙動解析が可能となり、発生防止や早期回収の対策を提案できるようになると考える。

謝辞: 本研究室を進めるにあたり、大阪府河川室により設置された河川カメラの画像を利用するとともに、本研究の一部は JSPS 科研費(18K13838)および(公財)前田記念工学振興財団より助成を受けて行いました。ここに記して謝意を表します。

参考文献:

1) Karen Simonyan, Andrew Zisserman : Very Deep Convolutional Networks for Large-Scale Image Recognition ,2015.

水田ら: 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カム自動判別, 土木学会論文集 B1(水工学) Vol.71, 2015.