

# 都市河川スカム発生問題に対する AI を使った取り組み

エンジニアリング本部 防災・環境解析部 水圏解析グループ

宮野 実佳

## 1. はじめに

都市河川の水質は下水道の普及に伴い大幅に改善されてきたものの、合流式下水道が接続されている河川では、洪水時に汚水を含む雨水が流入し、水質への影響が懸念されている。水質悪化が進むと、春季から夏季にかけてスカムの発生がみられる。スカムとは、川底に堆積した汚濁物質が有機物の分解とともに発生したメタン等のガス泡の浮力によって水面へ浮上したものである。図 1 にスカム発生状況を示す。このように水面一帯にスカムが発生し、悪臭や景観の悪化がもたらされるため、早急な解消対策が必要とされている。



図 1 スカム発生状況

スカム発生のメカニズムは、様々な要因が複合的に絡み合っている。例として、河川水中での酸素消費による貧酸素化や、河口からの貧酸素水塊の遡上、さらに潮の満ち引きの影響を受ける感潮河川では、潮汐現象による水位低下による水圧の減少などが挙げられる。スカムの抑制対策として最も有効なのは、川底への堆積物を減少させることが期待できる分流通式下水道への改善であるが、短期間で実現すること

は難しい。現在可能な対策としては、河川水面を常時監視し、スカムが多量に発生している際にスカムの回収や散水による沈降作業を行う等である。

ここで、スカム発生状況を把握する手段として現地に設置した定点カメラ画像から発生の有無とその程度を判別する手法がある。しかし、人が目視により発生状況を確認するため、大量に取得された画像の判別に膨大な時間を必要とし、その精度は担当者の感覚に大きく左右される。スカムの有無判別を目視によらず自動で行う手法については水田ら<sup>1)</sup>によって提案されており、人工知能(以下「AI」とする)の一種であるニューラルネットワーク(以下「NN」とする)を用いた画像判別の有効性が示されている。

本稿では、NN の中でも画像認識の分野で実績のある、畳み込みニューラルネットワーク(以下「CNN」とする)によるスカム有無の判定およびスカム発生量の定量評価を行った。具体的には、河川に設置された定点カメラ画像をスカムの規模によって分類し、分類した画像を教師データとして学習を行う。学習済みの CNN を用いてスカムの有無判別および定量評価を行い、その精度を評価することによって本手法の有効性を示す。

## 2. 解析手法

### 2.1 畳み込みニューラルネットワーク(CNN)

これまで、画像認識の手法は NN など数多く検討されてきたが、現在最も顕著な成功を収めているのは CNN である。CNN は脳の視覚野の構造における

知見を基に構築された機械学習手法の一種であり、顔認識システムによる入退室管理や製造ラインでの異物混入検査等、幅広い分野で適用されている。従来の手法である NN では、入力画像にアルゴリズムを適用する前に特徴抽出と呼ばれる操作を要する。特徴抽出とは、学習の際に有効だと思われる特徴を入力画像から取り出す作業である。この特徴抽出方法を人間が選択するのが常識であった。対して CNN では、特徴抽出がアルゴリズムに組み込まれており、抽出すべき特徴の選択自体も機械が学習によって判断する。これにより、人手が必要とされていた特徴抽出が自動化され、判別精度の向上へとつながった。

CNN はその構造も NN と比較して特徴的といえる。NN と CNN の内部処理の模式図を図 2 に示す。NN は入力層、中間層、出力層の 3 層から成り、全層のニューロン同士が結合している全結合層のみで構成されている。これに対して、CNN は中間層を多層に展開し、中間層ではニューロン間の結合を局所に限定している。中間層を多層にすることで特徴量の汎用性・予測精度が向上し、ニューロン間の結合を一部に限定することで NN と比較して学習速度の向上が可能となった。さらに CNN は中間層において、画像の局所的な特徴抽出を行う畳み込み層と、局所ごとに特徴をまとめあげるプーリング層を繰り返した構造となっている。全ての層が全結合している NN に比べパラメータ数が大きく減少し、より効率的に学習を行うことが可能である。また、プーリング層を交えることによって、パラメータ数を削減すると同時に、一般物体認識において必要不可欠である物体の移動不変性を加えることができる。これによって、特徴が入力画像の如何なる場所に存在していても検知することが可能となった。

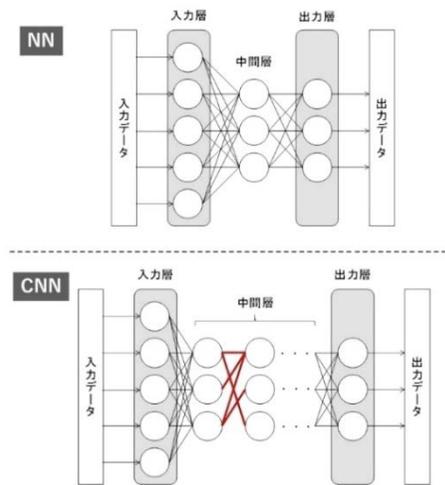


図 2 内部処理の模式図

## 2.2 CNN の構造

次に、スカムの自動判別へ利用する CNN の構築を行った。本稿で用いた CNN の構造を図 3、表 1 に示す。入力画像の特徴を維持しながら画像の持つ情報量を圧縮して画像を抽象化するために、畳み込み層とプーリング層の層数・フィルタサイズを調整し、入出力層を含む 9 層構造とした。

まず入力画像として、本稿では計算速度を優先しカラー画像を 1 チャンネルの白黒画像へ、画像サイズについては元の画像をおよそ 1/2 サイズの 320 × 320 ピクセルへ縮小したものを与える。入力画像中で 5 × 5 のフィルタと一致する特徴を抽出する畳み込み層の処理を行い、32 枚の特徴マップを得る。次に、畳み込み層①での出力を次の入力としてプーリング層②に与え、5 × 5 の領域内における最大値を選択するマックスプーリングにより特徴を抽出し、画像サイズを小さくする。さらにこの作業を 2 回繰り返すことでプーリング層⑥において出力される画像のサイズは 4 × 4 のサイズまで縮小され、これを全結合層へ入力することで画像の判別を行う。

表 1 CNN の構造

特徴量マップ	縦×横×枚数	フィルタサイズ
入力層	320×320×1	-
①畳み込み層	318×318×32	5×5
②プーリング層	64×64×32	5×5
③畳み込み層	62×62×64	5×5
④プーリング層	16×16×64	4×4
⑤畳み込み層	14×14×64	5×5
⑥プーリング層	4×4×64	4×4

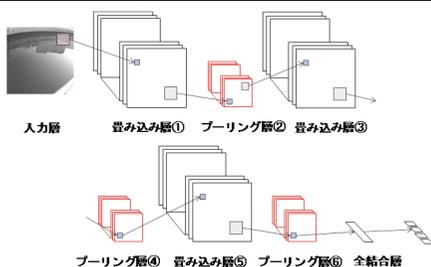


図 3 CNN の構造

### 2. 3 データセット

次に、CNN へ学習させる画像データの分類を行う。本稿では東京都北区に位置する石神井川の鍮溝橋を対象とした。対象地点を図 4 に示す。石神井川は合流式下水道に接続しており、鍮溝橋を含む下流部は感潮河川となっているため、経年的にスカムや悪臭の発生が確認されており、これまでも水流発生装置によるスカム集積防止や放水作業によるスカム沈下対策等が実施されてきた。



図 4 対象地点

鍮溝橋に定点カメラを設置し、平成 30 年 4 月 17 日～平成 30 年 8 月 20 日の間に 10 分間隔で撮影した画像を入力データとして用いた。使用カメラを図 5 に、カメラ設置状況を図 6 に示す。



図 5 使用カメラ

Time Lapse Camera BCC100 (brinno 社製)



図 6 カメラ設置状況

学習の教師データセットとして、撮影された全ての定点カメラ画像の中からスカムが発生しているものを対象に、その規模が類似するものとして、「スカムあり(小規模)」と「スカムあり(中規模)」と「スカムあり(大規模)」の 3 種に分類した。スカムが発生していない状態についても、誤って「スカムあり」と判断しやすい「護岸の影が映り込む状態」と「水面が波立っている状態」のデータセットを作成し、併せて 6 種への判別を試みた。各データセットの例を図 7 に示す。

教師データセットは訓練データ、検証データに分割した。訓練データにより学習を行い、検証データでモデルの精度を確認する。最後に、学習が完了した時点で学習に使用していないテストデータによってモデルの最終的な評価を行う。訓練データと検証データへの分類について、カメラ画像は全て時系列順に整理しているため、全体で 1,211 枚のデータセットをシャッフルしたのち 8:2 の割合で分割した。データセットの詳細を表 2 に示す。

表 2 訓練データ、検証データの詳細(枚)

分類名	訓練データ	検証データ
スカムなし	125	35
スカムなし(護岸の影)	142	48
スカムなし(水面の波立ち)	138	35
スカムあり(小規模)	158	36
スカムあり(中規模)	155	28
スカムあり(大規模)	251	60
合計	969	242

テスト用のデータセットは、スカムが多量に確認できる日を撮影期間中からランダムに 5 日間選び、各日のスカム判別精度を検証した。テスト用データセットの詳細については表 3に示す。

表 3 テストデータの詳細(枚)

4月26日	5月1日	6月24日	7月28日	8月20日	合計
168	171	182	172	165	858

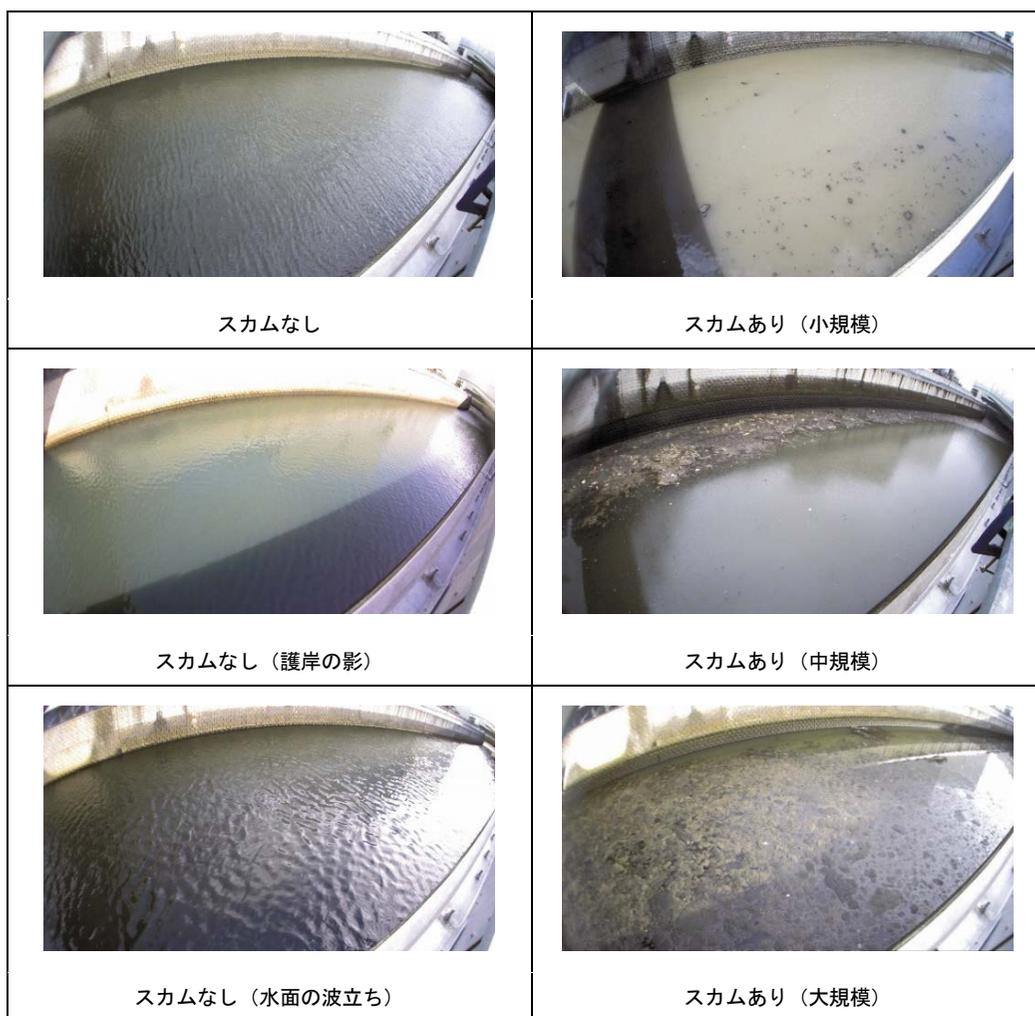


図 7 各データセット例

### 3. 検証結果

学習後のモデルにテストデータを判別させ、最終的な精度評価を行った。判別された画像の内、目視での判断と一致した割合を判別精度として算出した。なお、「スカムなし」の3分類については「スカムあり」と誤認しないために「スカムなし」と「スカムなし(護岸の影)」と「スカムなし(水面の波立ち)」の3通りに分類させたが、本稿ではスカムの定量評価を目的としているため、「スカムなし」の状態を区別する必要がない。よって、精度の算出には全て「スカムなし」の1分類へ統合後、「スカムあり」の3分類と併せて全体で4分類とした。

テストデータにおける判別精度を表4に示す。「スカムなし」の方が「スカムあり」の3分類よりも精度が高くなっている。「スカムなし」については、いずれの判定日においても80%以上の結果が得られた。「スカムあり」については、判定日・スカムの規模によって精度にばらつきがあるものの、65～91%となった。それぞれの正解例を図8-1～図8-3に示す。

表4 テストデータにおける判別精度

分類	4月26日	5月1日	6月24日	7月28日	8月20日	平均
スカムなし	96%	97%	84%	97%	86%	92%
スカムあり(小規模)	55%	-	51%	80%	76%	65%
スカムあり(中規模)	100%	100%	57%	-	69%	82%
スカムあり(大規模)	100%	73%	94%	100%	86%	91%

※「-」は該当なし



図8-1 正解例(スカムあり(小規模))



図8-2 正解例(スカムあり(中規模))



図8-3 正解例(スカムあり(大規模))

### 4. 考察

「スカムあり」の3分類については精度にばらつきがあったが、これには二つの要因が考えられる。一つ目に「スカムあり」の画像を判別する際に規模の判断を誤ってしまったケース、二つ目に「スカムなし」の画像を判別する際に「スカムあり」のいずれかの規模に判別してしまったケースである。前者については、例として「スカムあり(小規模)」と「スカムあり(中規模)」の中間程度の大きさのスカムがあった際に、人による判断と乖離する場合がある。これは、スカムの規模を判断する際にCNNでは判断基準を明確な面積の数値で定めていないこと、さらに正解データを作成する人の感覚によっても、その精度は左右される。後者については、河川の水面は太陽の位置によって河川構造物(橋梁・護岸)の影や、反射による周辺の建物・護岸の映り込み、スカム以外のごみや生物などの浮遊物等、さまざまな物体等が画面内に映りこむ。したがって、これらをスカムと誤って判断してしまっている可能性が考えられる。ごみ(葉)が「スカムあり(大規模)」と判断された画像例を図9に示す。



図 9 スカムあり(大規模)と判断された画像例

このようなスカムの誤認の対策として、スカムから発生する臭気を用いて精度を向上させる方法が挙げられる。スカムとは「1.はじめに」で述べたように、大量発生した際に悪臭の原因となっており、スカムの量と臭気強度には相関関係があると考えられる。そこで、定点カメラによる連続撮影に加えて臭気の観測を行うことができれば、スカムをよりよく判別できると推測される。臭気の測定には図 10 に示す臭気センサーを用いる。一例として、都市河川を対象として実施した臭気強度連続測定結果を図 11 に示す。スカムから悪臭が発生し、周辺の臭気強度が上昇するとセンサー値が上昇する仕組みになっている。これによって、画像認識においてスカム以外の物体を誤ってスカムと判別してしまった場合に、臭気センサーに相応の反応がみられなければその画像を除外することができる。



図 10 臭気センサー

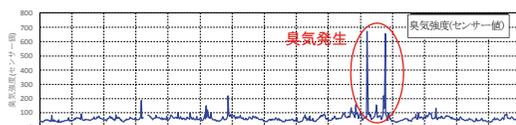


図 11 臭気連続測定結果(センサー値)

## 5. おわりに

本稿は、都市河川において臭気や景観悪化の原因となっているスカムに対して、効率的な回収・沈降作業を行うために、CNN によるスカムの自動判別及び定量評価を試みた。学習、精度検証には石神井川に設置した定点カメラ画像を利用した。

スカムの有無に加えて定量評価を行うために、スカムありの状態についてスカムの規模別に 3 種に分類した。検証の結果、スカムが発生した際には 65～91%の精度が得られ、スカムの規模によって画像を判別することができた。

スカムが発生した際には、判別日やスカムの規模によって判別精度にばらつきがでた。スカムが発生していない場合であっても、周辺の建物・橋梁・護岸等の影や映りこみ、ごみや生物などの浮遊物等、様々な物体が水面へ映りこむ。CNN ではこれらの物体をスカムと誤って判断してしまう現象が度々発生し、結果として画像認識精度の低下を招いている。これらの認識精度低下への対策として、スカムより発生する臭気の測定結果を用いる手法が挙げられる。画像認識後の判別結果へ臭気強度連続測定結果を結合することによって、周辺施設の影や映り込み、浮遊物等を誤ってスカムと判別した画像を取り除くことが可能である。これにより、スカムの自動判別精度が向上し、効果的なスカムの回収・沈降作業が可能になると考えられる。

## <参考文献>

- 1) 水田 周作(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カム自動判別」、『土木学会論文集』71(4), p.1231-1235, 土木学会