

# 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

AUTOMATIC DISTINCTION OF SCUM IN URBAN RIVER  
BY THE NEURAL NETWORK USING FIXED POINT CAMERA IMAGE

水田周作<sup>1</sup>・高崎忠勝<sup>2</sup>・河村明<sup>3</sup>・天口英雄<sup>4</sup>・石原成幸<sup>5</sup>

Syuusaku MIZUTA, Tadakatsu TAKASAKI, Akira KAWAMURA,  
Hideo AMAGUCHI and Shigeyuki ISHIHARA

<sup>1</sup> 学生会員 首都大学東京大学院 都市環境科学研究科 (〒192-0397 東京都八王子市南大沢 1-1)

<sup>2</sup> 正会員 博(工) 東京都建設局 河川部 (〒163-8001 東京都新宿区西新宿 2-8-1)

<sup>3</sup> 正会員 工博 首都大学東京大学院 都市環境科学研究科 (〒192-0397 東京都八王子市南大沢 1-1)

<sup>4</sup> 正会員 博(工) 首都大学東京大学院 都市環境科学研究科 (〒192-0397 東京都八王子市南大沢 1-1)

<sup>5</sup> 正会員 修(学) 東京都土木技術支援・人材育成センター (〒136-0075 東京都江東区新砂 1-9-15)

For appropriate river management, continuous monitoring scum causing bad smell and aggravation of the scene and cleaning the water surface if appeared are necessary. In this study, the method of monitoring scum at tidal area of urban river was proposed. With pictures of the fixed point camera for monitoring water level by Ryukei Bridge over Kanda River, scum were automatically distinguished from the surface of the water. For distinction of scum, pictures were split into lattice-like and each lattice having scum or not were distinguished by pattern analysis of color using artificial neural network. The results showed that the number of lattices having scum which the neural network detect follow volume of scum with visual observation. For monitoring scum, fixed point camera is useful.

**Key Words** :scum, tidal area, monitoring, fixed point camera, picture analysis, artificial neural network

## 1. はじめに

多くの都市で水辺を重視したまちづくりが進められている<sup>1)</sup>。例えば、東京都では景観づくりを総合的かつ計画的に進めるため、東京都景観条例に基づく河川の景観基本軸が制定されている<sup>2)</sup>。また、隅田川や神田川などの都市河川では川に沿う遊歩道や船着場の整備が進められており、さらに隅田川やその支川を対象に舟運を活用した新たな河川整備の提案が行われている<sup>3)</sup>。

東京の河川の水質は下水道の普及に伴い大幅に改善されたものの、合流式下水道が接続されている東京区部の感潮河川では夏季を中心にスカムがしばしば見られる。山崎ら<sup>4)</sup>によって都内河川のスカム発生のメカニズムが示されており、また、スカム発生に影響する強降雨時の水質変動は林ら<sup>5)</sup>によって報告されているが、スカムの

解消には合流式下水道の改善を要するため短期間での対応は極めて困難である。このため、河川水面を常時監視しスカムが多い時に水面の清掃を行うなど適切な河川管理を行うことが望まれる。

河川水面の浮遊物監視については尾ノ井ら<sup>6)</sup>によって江戸川におけるビデオ映像を用いた漂流ゴミのモニタリングが提案され、映像分析の有効性が示されている。近年、自治体が中小河川の監視を目的とした定点カメラを設置しており、その映像は Web 上で閲覧可能なものもある。これらの定点カメラは、中小河川の増水の把握を目的としているため映像の更新間隔が短く、河川水面の実態把握にも利用できるものと考えられる。すでに数多くの定点カメラが設置されており、新たな機器を設置することなくスカム監視ができる利点がある一方で、河川に隣接する構造物等が複雑に河川水面に映り込んでおり、適切にスカムを判別させるには高度な画像分析が必要だと考

えられる。画像分析においては、小杉<sup>7)</sup>による顔画像認識や、沖井ら<sup>8)</sup>による医療用画像の解析などにおいて、人工知能の一種であるニューラルネットワークを用いることで良好な結果を得られたことが報告されている。

このため本研究では、自治体が設置した定点カメラ映像を用い、ニューラルネットワークを活用したスカムの自動判別手法を示す。具体的には、定点カメラ映像からスカムの特徴を抽出し、スカム判定用のニューラルネットワークを構築する。構築したニューラルネットワークを用いて定点カメラ映像のスカム判定を行うことにより、本手法の有用性を示す。

## 2. 対象地点および使用データ

本研究で対象とした神田川の隆慶橋地点を図-1に示す。神田川は、東京都三鷹市にある井の頭池に源を発し、東京都の中心部を流れ、日本橋川を分派し隅田川に合流する河川延長 24.6km の一級河川である。対象地点は JR 飯田橋駅から約 300m の距離にあり、河川は首都高速道路の高架下を流れる。当地点の約 300m 上流に位置する白鳥橋の上流側ではスカムが多く発生する<sup>4)</sup>ことが報告されている。

隆慶橋地点には文京区によって定点カメラが設置されており、その映像は Web 上で閲覧できる<sup>9)</sup>。本研究に用いた映像データは 10 分間隔で更新される Web 上のライブ映像をプログラムによって自動的に取得した。2012 年 1 年間の全データを目視により異常データの確認を行い、計 50808 枚の映像データを有効とした。また、有効としたデータに対してスカムの有無を目視で判定し、3 月 1 日から 11 月 6 日までスカムが見られることをすでに確認している<sup>10)</sup>。

## 3. 定点カメラ映像の分析

図-2 に定点カメラ映像の例を示す。図の左は 6 月 3 日 9 時 40 分、右は 6 月 5 日 17 時 00 分の映像である。映像データは上下端にある撮影時刻表示部分を除くと横 704 ピクセル、縦 464 ピクセルの計 326656 ピクセルで構成され、各ピクセルは赤・緑・青成分それぞれ 256 段階の色情報を有している。

映像について水面部分（図-2 赤枠部）に着目すると、左の図にのみスカムが見られる。2 つの映像に共通して暗部と明部があり、暗部は隆慶橋、神田川の護岸、河川上部に位置する首都高速道路の陰になる部分であり、明部には神田川の転落防止柵や隆慶橋の側面、河川周辺の建物等が映り込んでいる。

こうした水面に映り込む場所は太陽の位置によって変化し、また、図-1 に示した新宿区が管理する白鳥橋観測

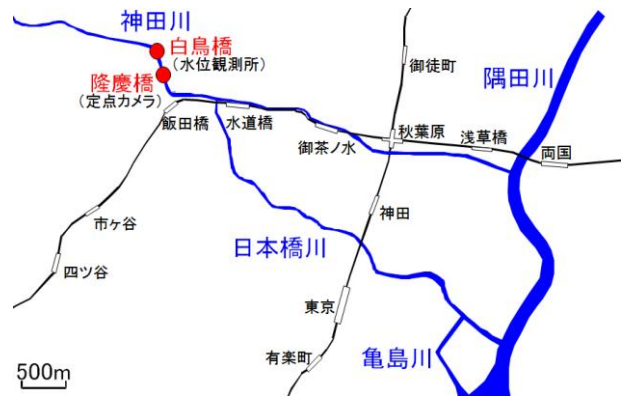


図-1 対象地点

6 月 3 日 9 時 40 分      6 月 5 日 17 時 00 分



図-2 定点カメラ映像例




図-3 水面部分のピクセルの色情報

所<sup>11)</sup>の水位をみると潮汐によって約 2m 変化していることから、水面の映り込みは水位変化の影響も受ける。

図-2 に示した映像例について水面部分のピクセルの色情報を図-3 に示す。色情報を示したピクセル数は 6 月 3 日 9 時 40 分が 180115 ピクセル、6 月 5 日 17 時 00 分が 212204 ピクセルであり、映像全体の占める割合はそれぞれ 55%、65% になる。図横軸の赤・緑・青成分の値はそれぞれ 0~255 の範囲の値を有しており、図縦軸はその値を持つピクセルの数を表している。

2 つの映像共に赤・緑・青成分の値は 50~150 付近と 250 付近に多く分布している。50~150 付近の分布が暗部、250 付近の分布が明部を形成している。スカムのある 6 月 3 日 9 時 40 分の映像よりスカムのない 6 月 5 日 17 時 00 分の方が赤・緑・青成分の分布が複雑な形状をしており、水面全体の色はスカムの有無より、水面への映り込みによって大きく変化することが分かる。

目視によるスカムの判断は、スカム自体の色だけではなく、その周辺との色の違いも参考にしていることから、一定範囲のピクセルの情報を用いてスカムの判定を行う。




図-4 格子の設定

スカムとその周辺の水面を含むことができるよう、 $20 \times 20$  ピクセルの矩形範囲を1格子と設定し、格子単位でスカムの有無を判定することとした。

図-4に6月3日9時40分の映像に格子を重ねたものを示す。格子数は805である。図中に示した(a)~(d)の格子は、(a)が全体が明部でスカムなし、(b)が隆慶橋の側面が映り込んでいてスカムなし、(c)が全体が暗部でスカムなし、(d)が全体が暗部でスカムありである。

(a)~(d)の格子について赤・緑・青成分の値を図-5に示す。図横軸のピクセル番号は、各ピクセルの赤・緑・青成分の値の合計を小さい順に並べて番号を付したものであり、同じピクセル番号の赤・緑・青成分は、同一ピクセルのものである。

4つの図を比較すると、(a)と(c)は赤・緑・青成分の値がほぼ一定もしくは狭い範囲に分布している。一方で、(b)と(d)は広範囲の様々な値を有しており、また図の全体的な特徴が似ていることが分かる。よって、ピクセル全てが明部や暗部となっている格子は、赤・緑・青成分の分布がスカムの有無によって大きく異なるため判定は容易であるが、手すり等が映り込んでいる格子はスカムがある場合と分布が似ているため、この情報のみからスカムを適切に判定することは難しい。この対応として、映り込みに関する情報を事前に取得し、これと組み合わせて判定を行う方法が考えられる。

格子毎の水面の映り込みの特性の違いを把握するために、複数のスカムのない映像を用いて各格子についてピクセル番号に対する赤・緑・青成分の最大値と最小値を求めた。なお、ピクセル番号は図-5と同様のものである。使用した映像データは目視でスカムがないことを確認済みの映像48枚であり、各月4枚ずつ夜間以外の朝、昼、夕方と様々な時間帯から幅広く選択した。

図-6に(a)~(d)の格子についてスカムがない状況での赤・緑・青成分の最大、最小値を示す。

ピクセル番号に対する最大値の分布について見ると全てのピクセル番号が255付近になっているのは(a)だけであることから、4格子の中で全てのピクセルが明部になるのは格子(a)だけである。(a)の最小値の分布につい

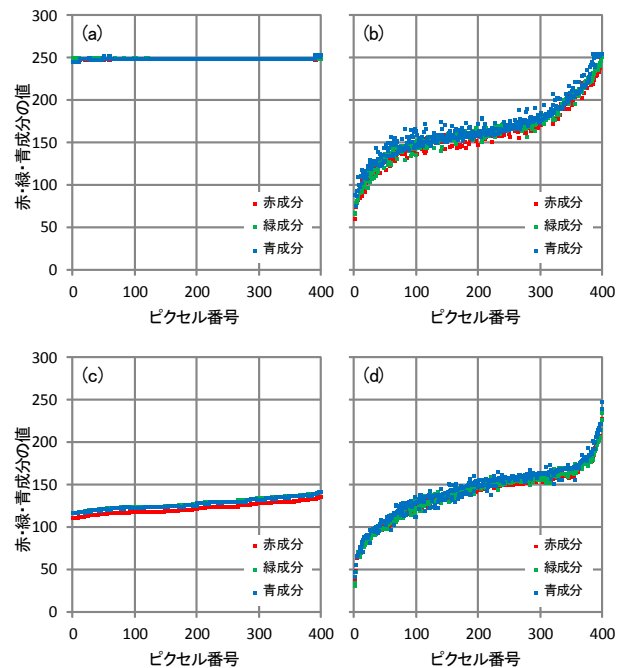


図-5 格子の赤・緑・青成分

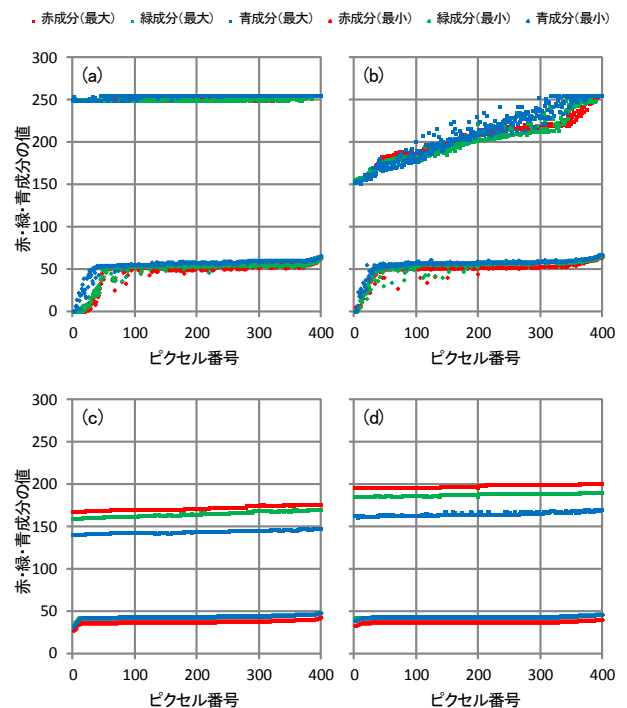


図-6 格子の映り込み特性

て見るとピクセル全てが暗部であった図-5(c)と比べて値が小さいことから、時間によっては暗部となるピクセルがある。また、最小値の分布は(b)の同分布に似ており、格子(a)は時間によっては橋梁や手すり等の映り込みがあるものと推察される。

一方、格子(b)は最大値、最小値の分布ともに赤・緑・青成分でばらついており、(b)では多くの時間において橋梁や手すり等の映り込みがあるものと考えられる。

格子(c)と(d)は、図-5ではスカムの有無によって赤・

緑・青成分の分布が異なりましたが、図-6では似た分布となっており、同じような映り込みの特徴を有している。また、図-5では同様の分布をしていた格子(b)と(d)については、図-6では全く異なった分布となっている。よって、図-5で(b)や(d)のような分布でかつ図-6で(c)や(d)のような分布の場合にスカムがあると判定できる。

#### 4. スカムの自動判定

##### (1) スカム判定用ニューラルネットワーク

ニューラルネットワークは実績データの学習結果をもとに予測計算を行う手法であり、非線形の連続関数を近似できる点が強みである。

スカムの自動判定に際し、ニューラルネットワークへの適用方法を検討する。本研究で用いるのは、入力層、中間層、出力層の3層からなる階層型ニューラルネットワークであり、そのモデル図を図-7に示す。各ユニットに対して(1)式、(2)式による計算を行う。

$$T_j = \sum_{i=1}^n X_i W_i \quad (1)$$

$$Y_j = \frac{1}{1 + \exp(-T_j)} \quad (2)$$

ここに、 $T_j$ : ユニット  $j$  への入力値の総和、 $X_i$ : 入力値、 $W_i$ : 連結荷重、 $Y_j$ : 出力値

1 格子の情報を入力し、その格子のスカムの有無が出力となる。入力に用いる 1 格子の情報は図-5に示した判定映像データおよび図-6に示した水面への映り込みの最大値と最小値（以下映り込み特性と記す）の3種類である。それぞれピクセル番号に対応する赤・緑・青の3成分について最小値、25パーセント、中央値、75パーセント、最大値付近の10ピクセルの平均値を使用することとし、計45項目を入力値とする。出力値は0から1までの実数であり、出力値が0.5未満をスカムなし、0.5以上をスカムありとしている。

##### (2) スカム判定用ニューラルネットワークの学習

学習、検証に用いた映像データについて表-1に示す。2012年1年間を目視で確認し、スカムが多い日として選んだ9日間の映像に対し、目視にて格子毎にスカムの有無を判別した。スカムがある場合は1、ない場合は0とし、教師データとした。これらの教師データを3日ずつ3グループに分け、それぞれA、B、Cグループとした。括弧内の数値は各グループの全データに対するスカムの有無の割合を示しており、各グループともにスカムなし格子の割合が高くなっている。

表-2に示す条件でニューラルネットワークの学習を行った。映り込み特性の入力の有無、中間層のユニット

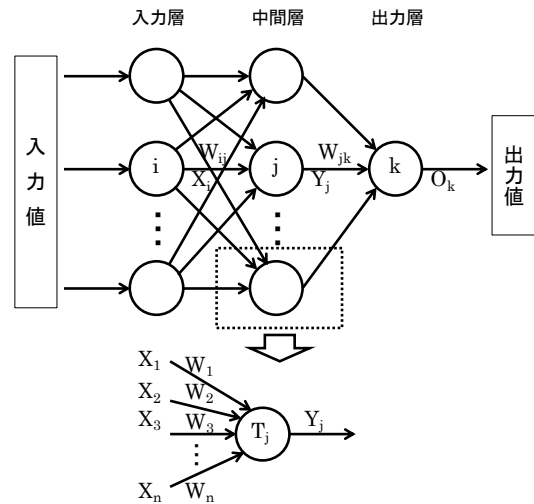


図-7 ニューラルネットワークモデル図

表-1 教師データ一覧

	教師データ数			月日
	全体	スカムあり	スカムなし	
グループA	7,166	3,168 (44%)	3,998 (56%)	5月31日
				7月9日
				9月20日
グループB	5,811	1,730 (30%)	4,081 (70%)	6月3日
				7月10日
				9月22日
グループC	6,566	1,235 (19%)	5,331 (81%)	6月5日
				7月22日
				9月24日

表-2 学習計算条件

	中間層 ユニット数	映り込み 特性入力	学習データ	比較データ	検証データ
ケース1	25	あり	グループA	グループB	グループC
ケース2	50				
ケース3	100				
ケース4	25	なし	グループB	グループC	グループA
ケース5	50				
ケース6	100				
ケース7	25	あり	グループC	グループA	グループB
ケース8	50				
ケース9	100				
ケース10	25	なし	グループA	グループB	グループC
ケース11	50				
ケース12	100				
ケース13	25	あり	グループB	グループA	グループC
ケース14	50				
ケース15	100				
ケース16	25	なし	グループA	グループB	グループC
ケース17	50				
ケース18	100				

数が25、50、100の3種類についてA、B、Cの3グループを学習、比較、検証にそれぞれ一度ずつ用い、計18ケースについて行った。

ニューラルネットワークの学習は表-2の学習データのグループからランダムに格子データを1つ選択し、バ



ックプロパゲーション<sup>12)</sup>により連結荷重の値を更新する。この作業を教師データ数と同じ回数繰り返した時点で学習回数1回とし、学習回数3000回まで行った。

過学習を防止するため、学習回数10回終了度にその時点の連結荷重を比較データの全データに適用し、式(3)のエラー値を算出し、エラー値が最小であった学習回数時を最終的な連結荷重とした。また、同様の学習を再度行い、比較データのエラー値が小さい方を採用した。

$$E = \frac{1}{2} \sum_{i=1}^n (t_i - O_i)^2 \quad (3)$$

ここに、 $E$ :エラー値、 $t_i$ :教師信号(0または1)、 $O_i$ :出力値、 $i$ :データ番号、 $n$ :グループのデータ数とし、 $E$ はグループ全データに対するものであり、格子毎のエラーの総和を表す。

図-8にケース1における学習回数とエラー値の関係を示す。図においては検証データに対する計算も学習回数10回毎に行っている。学習データのエラー値について見ると、学習終了時点まで学習回数の増加に伴うエラー値の減少傾向が見られるが、比較データについて見ると学習回数450でエラー値が最小となっており、以降は学習回数の増加に伴いエラー値が大きくなる傾向が見られる。検証データについても比較データと同様の傾向が見られることから、学習の進捗状況を比較データのエラー値を参照することで過学習となっていないことを確認した。

学習および検証計算の結果を表-3に示す。比較データのエラー値が最小となる学習回数は1ケースを除いて1000回以下であり、概ね1000回までの学習回数で最終的な連結荷重の値を得られる。正答率は、格子内のスカムの有無について目視とニューラルネットワークの判断が一致した割合を示しており、例えば「スカムあり」は目視にてスカムありと判断した格子の内、ニューラルネットワークによってスカムありと判定した格子の割合を表す。

正答率を見ると全体のデータに占める割合の高いスカムなしの方がスカムありより高くなっている。ケース1とケース4のように映り込み特性の有無以外の条件が同じケースについて全体の正答率を比較すると、映り込み特性を入力した全てのケースで正答率が高くなっている。映り込み特性の入力によりスカムありのデータについては約10%精度が向上しており、全体で見ると約4%の向上になっている。

映り込み特性を入力したケースについて中間層のユニット数による全体の正答率の違いをみると、ユニット数を25に設定したものの正答率が最も高かったことから中間層のユニット数を25に設定し、ケース1, 7, 13で学習した連結荷重の値を用いてスカム判定を行う。

### (3) カメラ映像に対するスカム判定

学習済みのニューラルネットワークをスカムの量が異なる映像に適用する。スカムが比較的多く見られた9月3




図-8 学習回数によるエラー値の変化

表-3 学習および検証結果

	学習回数	エラー値			正答率		
		学習	比較	検証	全体	スカムあり	スカムなし
ケース1	450	214.7	233.7	367.9	86%	58%	92%
ケース2	670	189.4	238.9	393.6	85%	53%	93%
ケース3	820	190.9	242.8	376.6	85%	63%	91%
ケース4	990	271.7	302.5	397.5	83%	47%	91%
ケース5	650	275.0	317.6	439.5	82%	48%	89%
ケース6	640	279.0	310.2	434.7	82%	50%	89%
ケース7	330	115.0	241.3	351.6	88%	88%	88%
ケース8	180	136.4	239.0	369.9	87%	85%	88%
ケース9	120	148.0	234.8	367.6	86%	87%	86%
ケース10	820	204.5	230.4	456.8	83%	74%	90%
ケース11	260	228.1	227.1	447.5	83%	77%	88%
ケース12	180	226.9	238.8	424.5	84%	81%	87%
ケース13	740	132.8	385.8	232.8	90%	81%	93%
ケース14	760	128.1	392.7	228.9	89%	81%	93%
ケース15	390	169.6	409.0	256.8	88%	84%	89%
ケース16	280	204.0	568.3	319.7	85%	69%	92%
ケース17	2020	169.2	587.9	343.6	84%	74%	85%
ケース18	250	214.1	589.6	319.2	86%	71%	92%

日の映像から目視で判断して、図-9に示すようにスカムが見られる程度に応じた映像を選んだ。

各映像において水面のみが映っている格子を対象に、ケース1, 7, 13で学習済みの連結荷重を用いてニューラルネットワークによるスカムの判定を行った。3種類の連結荷重を用いて算出した3通りの出力値を平均したものをその格子における出力値とし、出力値が0.5未満をスカムなし、0.5以上をスカムありとしている。

ニューラルネットワークがスカムありと判定した格子数を図中において各映像の右上に示した。スカムが多いとした映像は、目視でスカムが少しあるとした映像より概ね100以上判定格子数が多く、スカムが多い映像の抽出が可能である。また、目視でスカムが少しあるとした映像はスカムがないとしたものより20程度格子を多く判定しており、判定格子数110~120が水面全体に対するスカム有無のしきい値と推測する。

図-10に示したニューラルネットワークおよび目視にてスカムありと判定した格子数の関係において相関が極めて高いことから撮影地点に浮遊しているスカムの定量的な把握も可能だと考えられる。なお、ニューラルネットワークによるスカム判定計算は瞬時に終了するため、

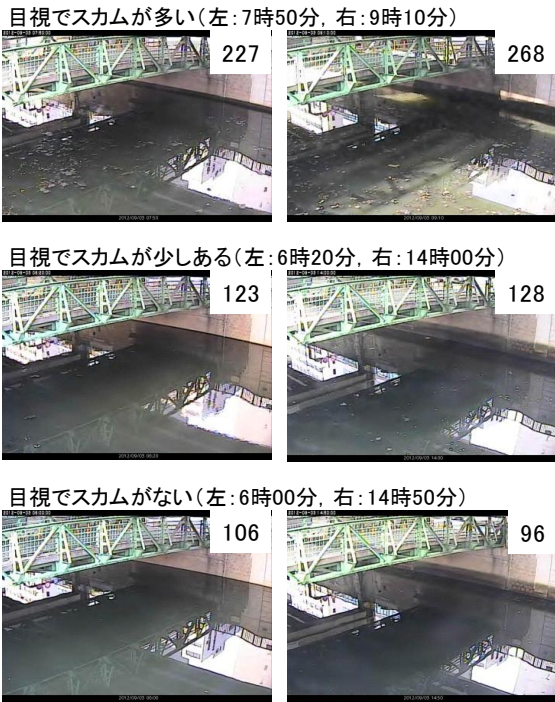


図-9 スカム判定映像




図-10 スカム格子数の比較




図-11 スカム格子数と水位の比較(9月3日)

実時間のスカム監視にも適用できる。

図-11では、9月3日の時系列でのニューラルネットワークによるスカム格子数と水位の関係を示した。特に満潮もしくは干潮付近の水の流れが少ない時間帯にスカムが多く確認された。

## 5. むすび

本研究は、神田川等の都市河川感潮域で発生するスカムを監視する手法を提案したものである。神田川隆慶橋

付近に設置されている既存の水位監視用の定点カメラの映像を用い、ニューラルネットワークによってスカムの自動判別を行った。

スカムの判別は、映像を  $20 \times 20$  ピクセルの格子で分割し格子単位で行い、ニューラルネットワークの入力には格子の各ピクセルの赤・緑・青成分について合計値を小さい順に並び替えた情報を用いる。また、河川に隣接する構造物等が河川水面に映り込み、時間とともに状況が変化するため、この対応としてスカムのない映像から格子毎の映り込みの特徴を抽出し、ニューラルネットワークの入力に追加する。この映り込み特性の追加によりスカムがある場合の正答率が約 10% 向上し、格子単位のスカムの正答率が 85%~90% になった。

学習後のニューラルネットワークをスカム浮遊量が異なる複数の映像に適用した結果、目視による判定と同様の傾向が得られたことから、ある程度の定量的な判定も可能であると考えられる。

## 参考文献

- 1) 高橋達也, 吉川勝秀, 山本有二: 水辺からの都市再生に関する研究報告, リバーフロント研究所報告, 第 16 号, pp.198-205, 2005.
- 2) 東京都都市整備局: 東京都景観計画, pp.52-69, 2011
- 3) 東京都建設局: 隅田川等における新たな水辺空間のあり方, 2014.
- 4) 山崎正夫, 津久井公昭: 河川におけるスカム発生に関する研究(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, pp.174-179, 1991.
- 5) 林秀彦, 高坂信章, 石塚与志雄, 守田優: 都市中小感潮河川における強降雨時の水質変動と汚濁負荷, 土木学会論文集 B1(水工学) Vol.69, No.4, I\_1723-I\_1728, 2013.
- 6) 尾ノ井龍仁, 二瓶泰雄, 片岡智哉, 日向博文: 河川漂流ゴミ輸送量に関する自動モニタリング技術の検討, 土木学会論文集 B1(水工学), Vol.69, No.4, pp.I\_769-I\_774, 2013.
- 7) 小杉信: モザイクとニューラルネットを用いた顔画像の認識, 電子情報通信学会論文誌, D-II, 情報・システム, II-情報処理 J76-D-2(6), pp.1132-1139, 1993.
- 8) 沖井広宣, 島田浩次, 原弘, 小野功一: ニューラルネットワークによる病理画像の領域分割, 電子情報通信学会論文誌, D-II, 情報・システム, II-情報処理 J76-D-2(3), pp.815-817, 1993.
- 9) 文京区水防災監視システムホームページ: <http://bousaiweb.city.bunkyo.lg.jp/mizubousai/index2.html>
- 10) 小池英晃, 高崎忠勝, 河村明, 天口英雄, 中川直子: 定点カメラを用いた目視による神田川におけるスカム実態, 第 41 回土木学会関東支部技術研究発表会, 2014.
- 11) 東京都建設局: 東京都水防計画(資料編), pp.資 3-10, 2014.
- 12) 吉富康成: ニューラルネットワーク, 朝倉書店, 2002.

(2014. 9. 30 受付)