

# 畳み込みニューラルネットワークを用いた 模擬掃流砂判別への試み

TRIAL STUDY ON DETECTION OF DUMMY BED LOAD USING  
CONBOLUTIONAL NEWRAL NETWORK

鍋島 康之<sup>1</sup>・竹ノ内 史弥<sup>2</sup>

Yasuyuki NABESHIMA and Fumiya TAKENOUCI

<sup>1</sup>明石工業高等専門学校 (〒674-8501 明石市魚住町西岡 679-3)

E-mail: nabesima@akashi.ac.jp

<sup>2</sup>明石工業高等専門学校 専攻科 (〒674-8501 明石市魚住町西岡 679-3)

E-mail: ac2206@s.akashi.ac.jp

**Key Words:** artificial intelligence, neural network, image analysis, dummy bed load

## 1. はじめに

近年の日本の気象災害<sup>1)</sup>は、局地的に時間雨量 50mm を超える継続的な激しい雨により、土砂災害を誘発する現象が顕著にみられる。平成 30 年 7 月豪雨では、広島県と愛媛県で土石流により人的被害が発生した。この内、死者が発生した溪流の約 7 割は流域面積が 0.05km<sup>2</sup> (5ha) 以下であった。国の土石流危険溪流のうち 5ha 以下の溪流は全体の 35%<sup>2)</sup> を占めており、こうした小規模な溪流は、溪流出口まで宅地開発が進展している場合が多く、人的被害が発生しやすい要因となっており、早急な防災・減災対策が必要になっている。全国の溪流には CCTV カメラが整備されているが、目視での利用のみに留まっており、これらの画像を有効利用した早期避難誘導の仕組みが必要である。

本研究では、既存の低解像度の CCTV や CCD カメラ画像データをリソースとして、土石流の初期段階を検知できるか検討する目的で室内実験の模擬掃流砂の発生を判別できるか検討した。低解像度の画像でも、機械学習<sup>3)</sup>の中でも画像内の特徴から判別を行うことができる畳み込みニューラルネットワーク (以下, CNN) を用いて掃流砂を判別できるか検証を行う。まず、小規模溪流に見立てた模型水路で

発生させた模擬掃流砂を CNN により、判別できるか検証した。次に、実際の溪流で撮影された低画質画像を用いて CNN で出水の判別を行い、既存カメラの画像を用いた簡易な避難システム開発への可能性について検討した。

## 2. CNN による模擬掃流砂の判別

### (1) CNN とは

畳み込みニューラルネットワーク<sup>4), 5)</sup> (CNN) は機械学習の一種であり、特に画像や動画認識に広く使われている。CCD カメラ画像を用いた土石流検知手法は五十嵐ら<sup>6)</sup>により詳しくまとめられており、PIV 法を用いた手法、画像鮮明化処理や輝度差分映像を用いた手法などがある。本研究では特殊な処理を行わずに低解像度のカメラ画像による判別が可能か検討するため、Sony が提供する Neural Network Console<sup>4)</sup> (以下, NNC) というソフトを用いた。NNC では、既存のユニットを連結させるだけでプログラミングをする必要がなく、クラウド上で計算処理が行われるため、コンピューターの性能によらず大量の画像が処理できるのが特徴である。ここでは、図-1 に示す CNN を用いて、「水のみ」または模擬掃流砂に見立てた「砂を含んだ水」の判別を試みている。

I	Input Dataset: X	入力層
C	Convolution KernelShape: 9,16	畳み込み層
R	ReLU	ReLU関数
M	MaxPooling Shape: 2,2	プーリング層
C	Convolution_2 KernelShape: 3,4	畳み込み層
R	ReLU_2	ReLU関数
M	MaxPooling_2 Shape: 3,2	プーリング層
A	Affine	全結合層
S	Softmax	活性化関数
S	SoftmaxCrossEntropy T.Dataset: y	出力層

図-1 畳み込みニューラルネットワークの構成

図中の I はデータ画像入力を意味し、C は畳み込み演算層、R は ReLU 関数による中間層としての活性化関数、M は重要な特徴を残しデータを圧縮するプーリング層、A は全結合層、S (Softmax) は結果を 0.0~1.0 で出力させる活性化関数、S (Softmax cross Entropy) は出力層を示している。

畳み込み層において画像はフィルタと呼ばれる重み信号を用いた畳み込み演算を行い、特徴マップを作成する。プーリング層では、畳み込み層から受け取った特徴マップに対して最大値や平均値を取る作業を繰り返し行うことで、重要な特徴を残してデータを圧縮するため、画像の特徴量から結果を出力することができる<sup>7)</sup>。この結果、従来のニューラルネットワークよりも精度の高い画像の判別が行えるため、画像や動画認識などに広く使われている。

## (2) 模型水路を用いた模擬掃流砂画像の撮影

本研究では実際に発生した掃流砂の動画から画像を取得することを検討したが、機械学習に必要な十分な画像を入手できなかったため、模型水路を用いて模擬的な掃流砂を発生させて判別することにした。

図-2 に示すような小規模な溪流に見立てた樹脂製 U 字溝 (幅 150 mm, 高さ 150 mm, 長さ 1000 mm, 勾配 1/10) を用いて左右および正面にタイムラプスカメラを設置し、3 方向から画像を収集することにした。図-3 は水を流していない U 字溝を下流側から見て左側、右側、正面から撮影した写真である。水を毎分 6 リットル流し、その様子をカメラで撮影を行い、「水のみ」の画像を取得した。次に、乾燥質量 300 g または 600 g の 7 号珪砂 (平均粒径 0.30 mm) を毎分 6 リットルの流水に投入し、模擬掃流砂である「砂を含んだ水」の画像を取得した。毎分 6 リットルの流量は乾燥した 7 号珪砂 600 g を流すのに必要な流量であり、砂量の違いを判別するため、半分の 300 g についても検討した。



図-2 樹脂製 U 字溝を用いた水路 (下流正面から)



図-3 下流側の 3 方向から U 字溝を撮影した写真



図-4 模擬水路を用いた水および掃流砂の画像例

## (3) 判別条件

本研究では図-2, 3 に示した模型水路を用いて「水のみ」の画像および 7 号珪砂と水を流した「砂を含んだ水」の画像を合計 489 枚撮影した。図-4 はそれぞれ水路正面から撮影した「水のみ」の画像および「砂を含んだ水」の画像の例である。各画像には教師付きデータとして、「水のみ」が映っている場合を 1、「砂を含んだ水」が映っている場合を 0 とし、学習用データと評価用データを 8 対 2 の割合で分割したデータセットを作成した。また、画像解像度を幅 360×高さ 640, エポック数は 100 にした。このデータセットを使い、畳み込みニューラルネットワークに学習させた後、評価用データを用いて判別を行った。

## (4) 判別結果

表-1~3 は下流から見て正面、左側、右側から撮影した画像を基に「水のみ」と「砂を含んだ水」の判別を行った結果である。実際と予測結果が一致している場合 (表内の網掛部) が正しく判別をしている事例数である。また、再現率は実際の事例を正判別している予測結果の割合を示し、全体の精度は正判別している予測結果の合計を全事例数で除した割合を示している。つまり、全体の精度の値が 1.00 に近づくほど正しく判別できていることを示す。この

表-1 模型水路画像判別結果（正面）

実際\予測	水・珪砂	水	再現率
水・珪砂	0	14	0.00
水	0	14	1.00
全体の精度	0.50		

表-2 模型水路画像判別結果（左側）

実際\予測	水・珪砂	水	再現率
水・珪砂	18	1	0.95
水	0	22	1.00
全体の精度	0.98		

表-3 模型水路画像判別結果（右側）

実際\予測	水・珪砂	水	再現率
水・珪砂	19	0	1.00
水	0	17	1.00
全体の精度	1.00		



(a) 広範囲を撮影した画像 (b) 範囲を限定した画像

図-5 模型水路正面の画像撮影方法について



(a) 300g (b) 600g

図-6 U字溝に流す土砂量が異なる画像

表-4 模型水路画像判別結果（正面）

実際\予測	300g	600g	再現率
300g	7	0	1.00
600g	0	4	1.00
全体の精度	1.00		

結果、下流から見て左側および右側から撮影した画像では高い精度で判別が行えているが、正面から撮影した画像では精度良く判別できていない。この理由として、図-5(a)に示すようにU字溝を広範囲で撮影した画像を用いたために、模擬掃流砂の判別とは関係のない部分が画像内に映っているためだと考えた。そこで、図-5(b)のように角度を変えて正面から撮り直したところ判別精度の改善が見られた。このことから、適切な角度や方向から撮影した画像を用いる必要があることがわかった。

次に、水の流量毎分6リットルは変えずに、図-6に示すようにU字溝に流す7号珪砂の量（300g、

600g）を変えた場合の正面（角度調整後）から撮影した画像を用いて判別を行った。判別結果を表-4に示す。表-4より、珪砂の量に関する判別について、高い精度で判別でき、左、右側から撮影した画像についても判別できることを確認した。以上のことから、撮影範囲を適切に限定した画像を用いることによって、模擬掃流砂の砂量の変化を画像から判別できることが示された。過去の検討結果<sup>8)</sup>ではカラー画像とモノクロ画像を用いて比較したが、大きな差はみられなかった。

### 3. CNNによる溪流の出水判別

#### (1) 使用したCNN

模型水路を用いた判別において良好な結果が得られたため、次に実際の溪流を撮影した画像から出水を判別できるか検討を行った。使用したCNNは図-1と同じ構成のCNNを用いて判別を行った。

#### (2) 使用した溪流の画像

今回の判別に用いた画像は兵庫県神戸市北区の溪流において撮影された図-7に示すような画像を用いた。2021年から2022年の撮影期間内に土石流の発生が記録されなかったため、土石流の前段階として出水現象が起こると考え、出水時と平常時の画像について判別を行うことにした。

#### (3) 判別条件

平常時の画像は、2021年7月4日～5日に撮影された458枚、出水時の画像は7月7日～9日に撮影された452枚、計910枚の画像を用いた。教師付きデータとして、出水時の画像を0、平常時の画像を1とし、学習用データと評価用データを8対2の割合で分割したデータセット（782枚/182枚）を作成した。また、使用したカメラ画像は低画質であったた



(a) 出水時 (b) 平常時  
図-7 実際の溪流で撮影された画像

表-5 出水時判別結果（解像度180×320）

実際\予測	出水時	平常時	再現率
出水時	0	88	0.00
平常時	0	94	1.00
全体の精度	0.52		

I	Input Dataset: X	I	Input Dataset: X
C	Convolution KernelShape: 36,64	C	Convolution KernelShape: 18,32
R	ReLU	R	ReLU
M	MaxPooling Shape: 3,3	M	MaxPooling Shape: 5,5
C	Convolution_2 KernelShape: 18,32	C	Convolution_2 KernelShape: 5,5
R	ReLU_2	R	ReLU_2
M	MaxPooling_2 Shape: 3,2	M	MaxPooling_2 Shape: 3,3
A	Affine	A	Affine
S	Softmax	S	Softmax
S	SoftmaxCrossEntropy T.Dataset: y	S	SoftmaxCrossEntropy T.Dataset: y

(a) 改良前 (b) 改良後

図-8 カーネルサイズの変更 (図中の数字参照)

表-6 出水時判別結果 (改良後)

実際\予測	出水時	平常時	再現率
出水時	101	0	1.00
平常時	0	81	1.00
全体の精度	1.00		

め、解像度の違いによる判別精度を比較するため、撮影した画像データの解像度を高さ 360×幅 640、高さ 180×幅 320 の 2 種類のデータセットを作成したが、解像度による差がみられなかったため、より低画像の 180×320 の画像を用いた結果を示す。

#### (4) 判別結果および考察

表-5 に図-1 と同じ CNN を用いた判別結果を示す。表-5 から明らかなように画像すべてを「平常時」の画像と判別しており、正しく判別できなかった。このため、図-8 に示すようにプーリング層ならびに畳み込み層のカーネルサイズを変更して再判別を行った。その結果が表-6 であり、正しく判別できることが確認された。今回の判別では、畳み込み層のカーネルサイズを小さくし、プーリング層のカーネルサイズを大きくしたことで、正しく判別を行えるようになった。この要因として特徴マップを作成する際、カーネルサイズが過大であったことで、特徴マップが適切に作られていなかったことが考えられる。一方、プーリング層については、カーネルサイズを大きくすると詳細な特徴が失われる恐れがあるが、微小な修正だけで詳細な特徴が失われずに判別精度を向上することができた。

また、神戸市北区の別の溪流で撮影された画像について、同じ変更を行った CNN を用いて出水時の判別の検証した結果、正しい判別が行えることが確認できたため、CNN を用いて出水判別が行えることがわかった。

今回の検証結果は限定的であり、実用的なレベルに達するには解決すべき課題が多いが、観測には適

していない低画質の既存のカメラ画像でも CNN を用いて簡易な避難システムの開発を行える可能性が示された。

## 4. まとめ

### (1) 模擬掃流砂の判別

室内模型実験において、撮影角度や方向を工夫することによって CNN による模擬掃流砂の判別ができた。また、土砂量の異なる掃流砂を判別できた。

### (2) 溪流の出水判別

CNN のカーネルサイズを変更することによって、実際の溪流を撮影した低画質画像から、CNN を用いて出水時・平常時の判別をすることができた。

本研究の結果は限定的な内容であり、CNN を用いた判別手法を実用的なレベルにするため、今後も改良を重ねていく必要がある。

謝辞：本研究の溪流の出水検証に用いた溪流のモニタリング画像は、神戸の減災研究会(鳥居宣之 会長)WG2 から提供されたものである。ここに記して謝意を表します。

### 参考文献

- 1) 気象庁：特集激甚化する豪雨災害から命と暮らしを守るために、<https://www.jma.go.jp/jma/kishou/books/hakusho/2020/index1.html> (2024/1/18 取得)
- 2) 国土交通省：平成 30 年 7 月豪雨における土砂災害の被害実態 p.22, [https://www.mlit.go.jp/river/sabo/committee\\_jikkousei/181031/02shiryu2.pdf](https://www.mlit.go.jp/river/sabo/committee_jikkousei/181031/02shiryu2.pdf) (2024/1/18 取得)
- 3) 小高知宏：はじめての機械学習, p.14, オーム社, 2011.
- 4) 足立悠：ソニー開発の Neural Network Console 入門—数式なしコーディングなしのディープラーニング, リックテレコム, p.61, 2018.
- 5) 全邦釘：ディープラーニングの活用による点検・調査業務省力化, 地質と調査, 第 1 号, p.9, 2020.
- 6) 五十嵐和秀, 松岡暁, 木下篤彦, 山田孝：渓流水面画像の RGB 値の単位ベクトルを用いた濁度評価と土石流検知手法, 砂防学会誌, 76 巻, 1 号, pp.22-33, 2023.
- 7) 平野徹, 安武健司, 片山達也, 岡田浩：AI と CAE を用いた実用化設計, 日刊工業新聞社, pp.20-21, 2021.
- 8) 鍋島康之, 石松一仁, 竹ノ内史弥, 下田清太郎：畳み込みニューラルネットワークを用いた画像解析による土石流検知, Kansai Geo-Symposium 2023 論文集, pp.51-54, 2023.

(2024. 5. 31 受付)