

深層学習による水際線の変動と関連のある波浪条件の検討

岐阜工業高等専門学校 学生会員 ○ 宮下 侑莉華 岐阜工業高等専門学校 正会員 菊 雅美
名古屋大学 正会員 中村 友昭 名古屋大学 フェロー 水谷 法美

1. 研究の背景と目的

三重県南部に位置する七里御浜海岸では、高度経済成長期以降、人為的な要因により土砂供給量が減少し、海岸侵食が顕在化している。特に、侵食の激しい井田海岸では、大規模な養浜や人工リーフの増設が実施されているものの、回復には至っていない。そのため、現地海岸の地形変化特性を把握し、有効な侵食対策を講じることが急務である。

著者ら¹⁾は、現地海岸の地形変化特性を把握する手法として深層学習に着目し、井田海岸の護岸背後に設置されているネットワークカメラの画像を用いて、海岸画像と波浪情報の関連性について検討を行った。その結果、波の打上高は海岸画像との関連性が高いことが明らかになっている。しかし、海岸の地形変化と波浪情報の関連性に対する検討には至っていない。本研究では、現地海岸に地形変化をもたらす波浪条件の解明に資することを目的に、現地海岸のネットワークカメラ画像に深層学習を適用し、水際線の変動と関連性の高い波浪条件について検討する。特に、地形変化と関連付けて検討することが有効とされている沖波エネルギーフラックスについて、水際線の変動との関連性を評価する。

2. 検討条件

(1) 画像データ

現地海岸にはネットワークカメラが設置されており、毎日5時台から19時台まで定点観測をしている。図-1に、本研究で用いた画像を例示する。同図(a)に示すように、海岸の南側を捉える画像を1時間毎と1日毎にそれぞれ平均・縮小化し、同図(b)のような水際線を抽出した。そして、同図(c)に示すように、90日後の水際線を重ね合わせることで水際線

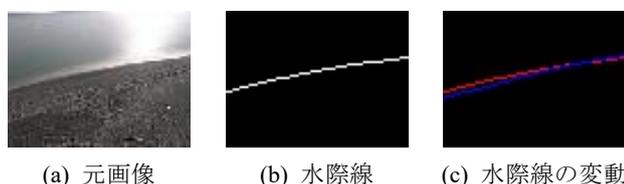


図-1 入力画像

の変動を示す画像を作成した。対象期間は2012年2月から2018年8月までとした。

(2) 波浪データ

井田海岸の波浪特性は、Kim et al.²⁾の波浪推算により、三重県尾鷲沖におけるNOWPHASの観測データと傾向が概ね一致することが確認されている。本研究では、尾鷲沖で観測される波浪データを用いて、沖波エネルギーフラックス E_f と波の打上高 $R_{2\%}$ を算出した。さらに、90日間における水際線の変動と関連付けるため、90日間における E_f の累積値と $R_{2\%}$ の最大値をそれぞれ算出した。

(3) 学習条件

図-2に、本研究で用いた畳み込みニューラルネットワークの構成を示す。すべての検討において、エポックは100、バッチサイズは64とした。

(4) 検討ケース

表-1に、検討ケースを示す。各波浪条件は、画像枚数に基づき、不等間隔で6つのラベルに分類した。Case 1は、90日間の累積沖波エネルギーフラックス ($E_f = 0 \sim 20 \times 10^4$ kN/h)、Case 2は、90日間における最大の波の打上高 ($R_{2\%} = 0 \sim 16$ m) をラベルとし、それぞれ、1日平均の画像と毎時平均の画像について比較した。また、全画像の75%を学習用、25%を評価用のデータセットとし、各ケース3回ずつ学習した。

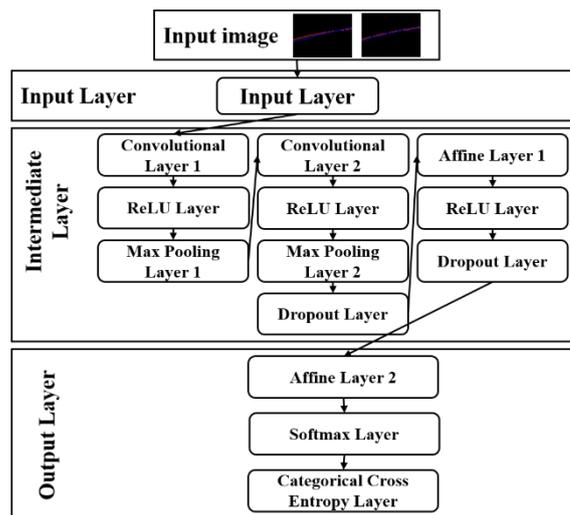


図-2 ネットワークの構成

表-1 検討ケース

ケース	波浪条件	画像	データ数
Case 1-1	E_f	1日平均	2034
Case 1-2	E_f	毎時平均	23897
Case 2-1	$R_{2\%}$	1日平均	2034
Case 2-2	$R_{2\%}$	毎時平均	23897

表-2 評価結果

ケース	Case 1-1	Case 1-2	Case 2-1	Case 2-2
Recall	45.7 %	63.6 %	59.4 %	69.5 %

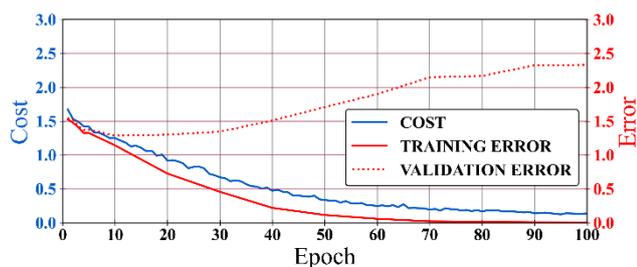


図-3 Case 1-1 の学習曲線

3. 判別結果

評価指標には、式(1)に示す再現率 Recall を用いた。ここで、 TP は正解ラベルと判別結果が一致する回数、 FN は判別結果に対し正解ラベルが異なる回数である。再現率が 100%に近いほど画像の特徴を判別できているといえる。

$$\text{Recall} = \frac{TP}{TP+FN} \quad (1)$$

各ケースの平均 Recall を表-2 に示す。Case 1, Case 2 とともに、1日平均の画像に比べ、毎時平均の画像の方が平均 Recall は高い。図-3 に、Case 1-1 における代表の学習曲線を示す。同図より、1日平均の画像を用いた場合、過学習が発生していることがわかる。これは、画像枚数が少ないことに起因すると考えられ、過学習のため平均 Recall が低いと考えられる。また、Case 1 に比べて、Case 2 の方が平均 Recall は高く、 $R_{2\%}$ をよく判別できている。 E_f は 90 日間の累積値であることから、欠測の影響により平均 Recall が低いと考えられる。そのため、欠測を考慮することで平均 Recall が向上すると考えられる。

図-4 に、Case 1-2 と Case 2-2 における判別結果を示す。同図において、対角線上の数値が 100%に近いほど、正しく判別できているといえる。同図より、

True Label	Num.of images						
	3.5	51.6	16.8	19.0	6.1	4.7	1.8
4.5	18.4	56.1	18.7	5.4	4.5	4.3	1039
5.5	13.1	12.4	66.7	9.9	3.0	2.4	1446
7.0	6.9	7.6	16.4	62.0	5.9	3.7	987
10	6.9	7.5	11.1	7.6	59.5	9.7	931
20	1.3	5.1	3.5	1.9	4.2	84.5	952
	3.5	4.5	5.5	7.0	10	20	

(a) Case 1-2

True Label	Num.of images						
	5.5	64.9	4.0	15.0	5.8	4.5	5.8
6.0	6.6	67.2	13.2	4.3	4.6	1.8	652
6.5	17.6	6.0	68.0	7.3	3.0	2.8	1200
7.0	6.8	2.9	8.5	70.6	6.1	5.4	936
10	7.2	2.6	5.5	7.5	70.8	6.8	950
16	13.2	2.9	5.3	4.2	6.1	72.8	1353
	5.5	6.0	6.5	7.0	10	16	

(b) Case 2-2

図-4 判別結果

両ケースとも対角線上の数値が大きく、機械は概ね正解ラベルを判別できていることがわかる。しかし、Case 2-2 では、対角線上から大きく外れたラベルの判別も多くなっている。Case 2-2 は、90 日間における波の打上高 $R_{2\%}$ の最大値をラベルとしているため、極めて大きな $R_{2\%}$ を観測した場合、長期間にわたり画像のラベルが同一の値となる。そのため、ラベルに大きく偏りがあり、波浪条件との関連性が低い画像も含まれていることが考えられる。

4. おわりに

深層学習を用いて 90 日間の水際線の変動と関連性のある波浪条件について検討を行った。その結果、 E_f 、 $R_{2\%}$ とともに概ね判別可能であり、 E_f は欠測データを考慮することで判別精度向上の可能性が示された。また、毎時平均の画像を用いることで、1日平均の画像を用いた場合に比べ画像枚数が増え、判別精度が向上した。しかし、水際線の変動と波浪情報の関係性は明確にされていない。今後は、欠測データを考慮し、教師データの質を向上させ、機械の判別根拠を明確にすることで地形変化をもたらす波浪条件について考究する。

参考文献: 1) 宮下侑莉華, 菊 雅美, 中村友昭, 水谷法美: ディープラーニングを用いた海岸画像と波浪条件の関連性の検討, 土木学会論文集 B3 (海洋開発), Vol. 75, No. 2, pp. I_677-I_682, 2019. 2) Kim, S., Nakamura, T., Cho, Y., Mizutani N.: Wave hindcast and wave characteristics at Shichiri-Mihama Ida beach, *Journal of Japan Society of Civil Engineers, Ser. B3(Ocean Engineering)*, Vol. 73, No. 2, pp. I_162-I_167, 2017.