

海岸画像を用いた深層学習の判別精度向上に関する一検討

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. はじめに

三重県南部に位置する七里御浜井田海岸では、海岸侵食が顕在化して久しい。これまでに人工リーフの建設や消波ブロックの設置、養浜など様々な海岸保全対策が行われてきたものの、浜の回復には至っていない。井田海岸に有効な海岸保全対策を講じるには、地形変化をもたらす波浪条件を解明する必要がある。渡邉ら¹⁾は、井田海岸に設置されているネットワークカメラの画像に Sobel gradient 法を適用して汀線を抽出し、その変化量と波浪を用いて判別分析を行った。一方、ネットワークカメラで撮影された海岸画像そのものから地形と波浪状況を推定できれば、地形変化をもたらす波浪条件を解明できる可能性がある。そこで、本研究では、ネットワークカメラによって撮影された現地海岸画像から波浪条件を判別するためのディープラーニングのパラメータについて検討することを目的とする。

2. 研究手法

(1) ネットワークカメラによる画像の取得

井田海岸では、護岸背後に設置されたネットワークカメラ(Canon VB-C50 iR)により、毎日6時から18時まで撮影が行われている。カメラは毎時間10分間ずつ撮影方向を変え、1秒間隔で5分間の連続撮影を全5方向に対して行っている。

本研究では、2012年2月から2018年8月に撮影された画像のうち、海岸を正面に捉える毎時21～30分の画像を学習・評価に用いた。毎時間帯に撮影された複数の画像を平均・縮小化し、写真-1に例示するような80×60 pixelの合成画像を1時間に1枚ずつ作成した。

(2) CNNの概要

本研究では、ディープラーニングの中でも画像認識の分野で用いられる畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)を用いた。CNNでは、入力層が学習データとして入力データを受け取り、

中間層を介して出力層で学習の結果を出力している。プラットフォームには、SonyのNeural Network Consoleを使用した。判別処理は、データセットの準備・学習・判別・評価の順に実施した。

(3) データセット

本研究では、画像にラベル付けする波浪条件として玉田ら²⁾が提案している、入射波数の上位2%に対応する超過打上高 $R_{2\%}$ を用いた。 $R_{2\%}$ はNOWPHASにより三重県尾鷲沖で観測されている有義波高 $H_{1/3}$ と有義波周期 $T_{1/3}$ を用いて、式(1)より算出した。

$$R_{2\%} = \left\{ 2.99 - 2.73 \exp(-0.57 \times \tan \beta / \sqrt{H_{1/3}/L}) \right\} \times H_{1/3} \quad (1)$$

ここで、 L は波長である。また、 $\tan \beta$ は海底勾配であり、現地海岸に基づき1/7とした。

本研究では、全画像の75%を学習用、25%を評価用としてデータセットを作成した。

(4) 学習条件

各検討ケースにおけるCNNの構成を図-1に示す。Case 1を初期条件として、学習回数は100回、ミニバッチ学習に使用するデータサイズは64とした。Case 2では、Case 1の構成にDropout層を1層追加し、Case 3では、Case 2における1層目のMax Pooling層をAverage Pooling層に変更した。

(5) 評価指標

本研究では、学習の評価指標として、精度 Precision、検出率 Recall、精度と再現率の調和平均 F-Measures に着目した。各指標の算定式を式(2)～(4)に示す。



写真-1 平均画像の例

キーワード ディープラーニング, CNN, ネットワークカメラ, 海岸画像, 波浪条件

連絡先 〒501-0495 岐阜県本巣市上真桑 2236-2 Tel : 058-320-1324 E-mail : kiku@gifu-nct.ac.jp




図-1 CNN の構成

表-1 学習・判別結果

	Case 1	Case 2	Case 3
Avg. Precision	0.594	0.634	0.616
Avg. Recall	0.518	0.583	0.579
Avg. F-Measures	0.535	0.603	0.594
Time	15:00:11	07:05:19	01:56:36
Best epoch	40	50	100

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$


$$F - \text{Measures} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

ここで、 TP は正解データを正しいと判別した回数、 FP は正解ラベルからみて判別結果と異なる判別をした回数、 FN は判別結果からみて正解ラベルと異なる判別をした回数である。各指標の値が1に近いほど画像の特徴を判別できているといえる。


3. 判別精度が向上する構成

各検討ケースにおける学習・判別結果を表-1に示す。Case 2では、すべての評価指標がほかの検討ケースを上回る結果を得た。しかし、学習時間については、Case 3が最も短く、効率的な学習ができているといえる。


図-2は、各検討ケースにおける学習曲線を示している。同図において、横軸は学習回数、縦軸は計算コストと誤差をそれぞれ表している。誤差には、学習用データに対する誤差を示す訓練誤差と、評価用データに対する誤差を示す汎化誤差がある。汎化誤差、訓練誤差はともに、本来は学習を重ねるにつれて減少していくが、Case 1では、汎化誤差が最適学習回数を境に大幅に増加しており、過学習に陥っていると考えられる。過学習は、



(a) Case 1



(b) Case 2



(c) Case 3

図-2 学習曲線

過大な学習により判断基準が厳しくなることで評価用データに対して正しく判別できない状態であり、未知データへの適用性が低いことである。Dropout層を追加したCase 2とCase 3では、その傾向がみられなくなっていることから、Dropout層を2層設けることで過学習を防ぐことや、判別精度を向上させることがわかる。また、Case 3においては、学習回数100回を超えても汎化誤差が減少傾向にあり、より学習回数を増やすことで判別精度が向上する可能性も考えられる。そのため、短い時間で比較的高い判別精度を得たCase 3のCNNの構成が最もよいといえる。

4. 結論

本研究では、Dropout層を2層設けることで、過学習が抑えられ、判別精度が大きく向上することが明らかとなった。しかし、海岸画像を判別する精度としてはまだ十分とはいえない。本研究で行った検討以外にも設定できるパラメータは多数あり、改善の余地がある。そのため、パラメータの最適設定値や学習率の変化、計算コストを低下させる工夫を行うことでより判別精度を向上させることが今後の課題である。

参考文献：1) 渡邊ら：画像解析を用いた七里御浜井田海岸における海浜地形の変化特性に関する研究，土木学会論文集 B2 (海岸工学)，Vol. 73, No. 2, pp. I 673-I 678, 2017. 2) 玉田ら：複合断面に対する波の不規則性を考慮した打上げ高算定法に関する研究，土木学会論文集 B2 (海岸工学)，Vol. B2-65, No. 1, pp. 936-940, 2009.