

礫浜の構成物を自動分類するための最適なデータセットに関する一検討

岐阜工業高等専門学校 学生会員 ○ 井上 雄太
 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井田海岸では、海岸侵食が顕在化して久しい。現地海岸の地形変化特性を解明するには、構成物の分布特性を把握することが重要である。

矢島ら¹⁾は、礫浜の構成物の時空間分布特性を明らかにするため、UAV (Unmanned Aerial Vehicle, 無人航空機) 測量結果からオルソモザイク画像を分割出力し、画像1枚1枚を目視で分類した。しかし、数千枚に及ぶ画像を目視で判別するには、多大な時間と労力を要する。そこで、著者ら²⁾は、CNN (Convolutional Neural Network, 畳み込みニューラルネットワーク) を用いて、オルソモザイク画像から礫浜の構成物を判別するモデルを構築した。しかし、各クラス間の判別精度に差が生じた。そこで、本検討では、最適なデータセットの構築に役立てることを目的に、各画像に対する機械の判別根拠の可視化を行う。

2. Grad-CAMの概要

本研究では、Grad-CAM³⁾を用いて、CNNの判別根拠を可視化した。本手法では、クラスごとの確率スコアへの影響が大きい画像箇所を勾配の平均化によって特定する。特定された箇所は、ヒートマップで表され、確率スコアへの影響が大きい箇所ほど赤くなり、青色から赤色の範囲で表示される。

3. 解析条件

2019年8月22日に、七里御浜井田海岸においてUAV測量を行った。撮影画像から3Dモデルを作成するとともに、オルソモザイク画像を200 pix.四方(5 mm/pix.)に分割して出力した。そして、オルソモザイク画像を1枚1枚目視で確認し、「礫」・「漂流物」・「植生」・「消波ブロック」の4クラスに分類した。本検討では、著者ら²⁾のデータセットを一部改変し、学習モデルの構造を変更せずに機械に学習させ、Grad-CAMを用いて判別根拠の可視化を行った。表

-1に、学習に用いた画像枚数を示す。Case1ではグレー画像、Case2ではカラー画像とした。

4. 各クラスに対する機械の判別根拠の可視化

(1) グレー画像に対する判別結果

20回の反復学習によって検証データの損失は約0.35、精度は約80%にそれぞれ収束した。図-1に、各クラスの判別結果を示す。同図より、「礫」は、精度よく判別できていることがわかる。しかし、その他のクラスは誤判別が多く確認できる。

図-2に、機械が正解ラベルを正しく予測した画像を示す。同図(c)より、植生の形が捉えられておらず、着目点がばらついていることがわかる。「礫」と同様、画像全体をまんべんなくみていることがわかる。

「漂流物」に対しては、着目点は少ないものの、流木に注目している。また、「消波ブロック」については、影に着目していることがわかる。

(2) カラー画像に対する判別結果

20回の反復学習によって検証データの損失は約0.15、精度は約90%にそれぞれ収束した。図-3に、各クラスの判別結果を示す。同図から、「植生」と「消波ブロック」は、精度よく判別できていることがわかる。しかし、「礫」と「漂流物」に関しては、誤判別が多く、それぞれを区別できていなかったり、「消波ブロック」と予測したりしていることがわかる。ソフトマックス関数の出力値を確認したところ、「礫」や「漂流物」と判別する際は、出力値が各クラス同等の値となっており、低い確率で判別されていた。紙面の都合上割愛するが、「礫」と「漂流物」

表-1 学習に使用した画像枚数

クラス	訓練用 [枚]	検証用 [枚]
礫	1345	339
漂流物	1377	305
植生	1325	359
消波ブロック	1338	344

予測 正解	礫	漂流物	植生	消波 ブロック
礫	328	6	2	3
漂流物	71	190	26	18
植生	9	49	294	7
消波 ブロック	12	25	5	302

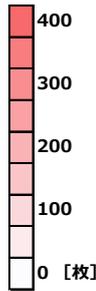


図-1 各クラスの判別結果 (Case 1)

予測 正解	礫	漂流物	植生	消波 ブロック
礫	277	24	0	38
漂流物	32	227	5	41
植生	0	1	357	1
消波 ブロック	6	11	2	325

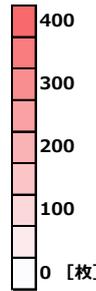


図-3 各クラスの判別結果 (Case 2)

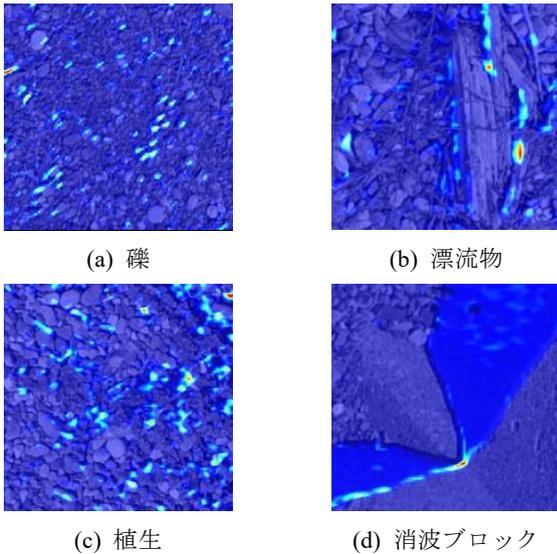


図-2 機械が正しい判別をした画像の例 (Case 1)

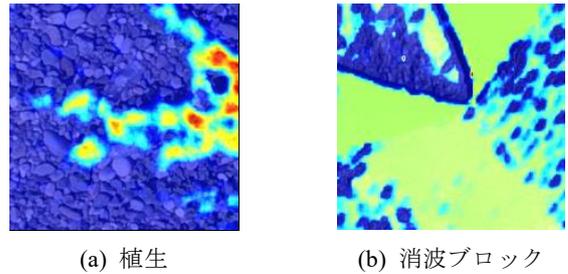


図-4 機械が正しい判別をした画像の例 (Case 2)

については、図-2(a)および(b)と着目点がほとんど変わらないことを確認した。この2クラスについては着目点が少ないために、誤判別が多いと考えられる。

図-4に、機械が正解ラベルを正しく予測した画像を例示する。「植生」と「消波ブロック」とともに着目点が多く、確率スコアも高い。そのため、機械の誤判別が少ないと考えられる。

図-5に、機械が正解ラベルを誤判別した画像の一例を示す。同図(a)より、画像左下に映る漂流物には反応していないことがわかる。画像に映り込んだ流木や容器など様々な物体を「漂流物」としていたため、学習精度が下がったと考えられる。「漂流物」を流木のみにするなど、データセットの更なる改善が必要といえる。また、同図(b)より、大きな礫があると、「消波ブロック」と誤判別してしまうことがあるとわかる。機械は主に色に注目しており、形ではなく、色合いの似た範囲の広さに着目していると考えられる。そのため、礫浜の構成物を分類する場合には、カラー画像を用いることが重要といえる。

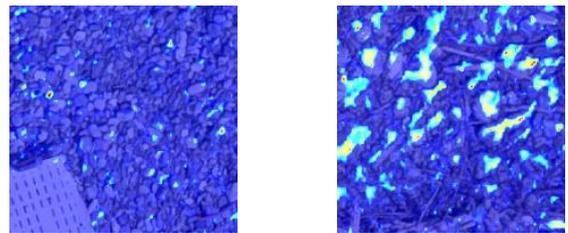


図-5 機械が誤った判別をした画像の例 (Case 2)

5. 結論

本検討により、データセットには、カラー画像を用いることが重要であるとわかった。また、「漂流物」を流木のみにすることや、「消波ブロック」は色の面積に着目しているため、画像自体を大きくして消波ブロックの形をより捉えやすくする必要がある。これらの改善を行い、データセットを増加させ、判別精度の高いモデルを構築する。

参考文献: 1) 矢島幹大, 菊 雅美, 中村友昭, 水谷法美: UAVによる空撮画像から算定した礫浜の中央粒径の変化に関する一考察, 平成 29 年度土木学会中部支部研究発表会講演概要集, II-062, pp. 187-188, 2018. 2) 井上雄太, 菊 雅美, 中村友昭, 水谷法美: 機械学習による礫浜の構成物の自動分類に関する一検討, 令和 2 年度土木学会全国大会第 75 回年次学術講演会概要集, II-97, 2020. 3) R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, D. Batra: Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization, In Proceedings of the IEEE International Conference on Computer Vision, pp. 618-626, 2017.