

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

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. 背景と目的

三重県南部の七里御浜海岸では、ダムの建設や港整備などによって土砂の供給量が減少し、海岸侵食が深刻化している。有効な侵食対策を行うには、現地海岸の地形変化や構成物分布の特性を解明する必要がある。

著者らは、七里御浜海岸にて、UAV（Unmanned Aerial Vehicle、無人航空機）により空撮された画像に SfM（Structure from Motion：カメラの撮影位置の推定および撮影対象の3次元形状復元）/MVS（Multi View Stereo：多視点ステレオ）技術を適用する UAV-SfM/MVS 測量を定期的の実施している。本測量では、比較的低高度で空撮するため、撮影画像から構成物を読み取ることが可能である。この特性を活かして矢島ら¹⁾は、七里御浜井田海岸における UAV-SfM/MVS 測量結果からオルソモザイク画像を分割出力し、画像に写る構成物を読み取ることで「礫」・「細粒地」・「植生」・「消波ブロック」・「漂流物」の空間分布図を作成した。しかし、礫浜の構成物分布を作成するにあたり、大量の画像を目視により判別するには多大な労力を必要とする。自動的に画像内の構成物を判別・分類できれば、構成物の空間的・時間的変化を考究する上で大変有用である。そこで、本検討では、機械学習によってオルソモザイク画像から礫浜の構成物を判別し、分類するモデルを構築する。

2. データセットの作成

2019年8月22日に、七里御浜井田海岸において UAV-SfM/MVS 測量を行い、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。本検討では、学習用のデータセットとして、全 7437 枚の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。図-1 に、各クラスのオルソモザイク画像の一例を示す。分類の際、画像の一部に「漂流物」・「植生」・「消波ブロック」のい

ずれかがあればそれぞれのクラスに分類し、なければ「礫」とした。分類の結果、「礫」は 5287 枚、「漂流物」は 1245 枚、「植生」は 242 枚、「消波ブロック」は 663 枚であった。クラスごとに画像枚数が大きく異なるため、各クラスの画像枚数を等しくした。表-1 に、学習に用いた画像枚数を示す。枚数の多いクラス「礫」については、画像をランダムに抽出し、学習に使用する画像枚数を減少させた。その他のクラスについては、画像を反転および回転することで枚数を増加させた。各クラスの画像を訓練用(80%)と検証用(20%)に分けて学習に用いた。

3. 解析条件

本検討では、深層学習ライブラリとして Tensorflow を使用し、Keras を用いてコードを簡略化した。学習条件として、損失関数に交差エントロピー、最適化関数に





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	1359	335
漂流物	1378	314
植生	1317	377
消波ブロック	1363	329

キーワード 礫浜，構成物，機械学習，自動分類

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



予測 正解	礫	漂流物	植生	消波 ブロック
礫	321	6	0	8
漂流物	67	229	4	14
植生	2	2	373	0
消波 ブロック	4	22	0	303


図-3 各クラスの判別結果

Adam 法, モデルの評価に精度をセットした. バッチサイズは 20 とし, 学習データを分割して, シャッフルしながら 20 回反復学習させた. 各反復の最後に, 検証用データを使用してモデルの精度を確認した. 学習モデルは, 入力層・2 つの畳み込み層とプーリング層・出力層で構成した. 活性化関数には, ReLU 関数とソフトマックス関数を使用した.

4. 構築したモデルの評価

判別結果を図-2 に示す. 同図から, 20 回の反復学習によって訓練データの損失は 0, 精度は 100%にそれぞれ収束していることがわかる. ただし, 同図の検証データに着目すると, 5 回目の学習以降は損失・精度ともに増減を繰り返しながら横ばいになっている.

図-3 に, 各クラスの判別結果を示す. 同図から, 機械は「礫」・「植生」・「消波ブロック」を概ね予測できている. 一方, 「漂流物」については, 他のクラスに比べて誤判別が多い. 機械が正解クラスと異なるクラスを予測した画像の例を図-4 に示す. 同図(a)の画像は, 「消波ブロック」とすべきところ, データセットの作成時に誤って「礫」と分類してしまった画像である. すなわち,



誤判別ではなく, 機械は消波ブロックの特徴を捉えて予測できている. 一方, 同図(b)および(c)の画像は, 画像の一部に写り込んだ漂流物や植生に基づいてクラス分けしたものの, 機械は画像中の大部分に写り込む礫から「礫」と判別していると考えられる. したがって, 画像中の大部分に写り込むものに基づいてクラス分けを行うことで, モデルの判別精度が高まると考えられる. 一方, 今後, 構成物の時空間分布を把握する際, 消波ブロックの埋没状況を把握するため, 同図(d)に示すような, 画像の一部に消波ブロックが写り込んでいる場合も「消波ブロック」と分類されることが望ましい. そのため, 画像の一部にある消波ブロックの判別精度を高める必要がある. また, 図-3 に示したように, 消波ブロックが「漂流物」と判別されるなど, 「漂流物」クラスの判別精度が低い. これは, 「漂流物」とクラス分けされた画像には, 木材やペットボトルなど様々な物体が写り込んでいるためと考えられる. したがって, 「漂流物」の画像をさらに学習させ, 判別精度を高める必要がある.

5. 結論

本検討では, UAV-SfM/MVS 測量により得られたオルソモザイク画像に機械学習を適用することで, 礫浜の構成物を自動分類可能であることを示した. 今後は, 構成物の判別精度を高めるとともに, 学習済みモデルを用いて構成物の時空間分布変化について検討する.

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.