

# 多波長スペクトルデータと AI を用いた 岩種・風化・亀裂の定量的な判別手法の研究

(株)地圏総合コンサルタント ○中井 康生, 福岡 航治, 中川 清森, 清水 桜  
北海道大学 中村 真一郎

## 1. はじめに

構造物の計画・設計・施工に利用される岩盤分類は、岩種、風化の程度、亀裂の性状などの要素から評価される。これらの多くは目視等の定性的な判断に基づく。そのため、技術者の主観や技術的能力差が入りやすいことや、実際の施工状況における地質性状との差異が生じることが指摘されている<sup>1)2)</sup> (例えば、青砥ほか, 2004. 宇津木, 2018)。したがって、定量的な判別手法の構築が必要と考える。

本研究では、野外露頭で取得したハイパースペクトル(以下、HS) データ、および RGB 画像を用いて、岩種・風化の程度・亀裂の AI 判別モデルを作成し、岩盤の分類要素の定量的な判別手法を検討した。

## 2. 方法

### 2.1 撮影対象と目視観察結果

本研究では、異なる性状の岩盤を一度に撮影できる場所として、愛媛県松山市内に分布する和泉層群砂岩泥岩互層<sup>3)</sup>の露頭2箇所 (Loc. 1, Loc. 2) を撮影対象とした (図-1)。

【Loc. 1】上位層 (Ss1) は弱風化砂岩が分布する。色調は灰～褐灰色を示す。層理面 (N68° 54° S) に沿った亀裂 (N16° E58W) や高角 (N32° W88° E) の亀裂が10～20cm 間隔で発達する。下位層 (Ms1) は弱風化の砂質泥岩が分布する。色調は暗灰～灰色を示す。層理面に沿った亀裂 (N62° E32° S) が5～10cm 間隔で発達する。

【Loc. 2】上位層 (Ss2) は弱風化砂岩が分布する。色調は灰～褐色を示す。約30cm 毎に高角の亀裂 (N2° W66° S) が発達し、亀裂面は風化している。下位層 (Ms2) は風化泥岩が分布する。色調は暗褐～褐色を示す。1～3cm 間隔で亀裂が発達し、角礫状を呈する。




図-1 対象露頭における岩種、風化程度、亀裂性状

### 2.2 使用機材

HS データは、HS カメラ: Specim IQ (Spectral Imaging 社) で露頭を撮影し取得した。Specim IQ は撮影対象からの光を400～1,000nm の波長領域で、204のバンドに分光したスペクトルデータが得られる機材である。RGB 画像は、iPhone13 (Apple 社) の内蔵カメラで撮影した。

### 2.3 AI 画像認識を用いた判別モデルの作成

岩種・風化の程度、亀裂の定量的な評価の手法として、AI 画像認識を用いた判別モデルを作成した。

岩種と風化程度の判別モデルは、HS データを使用し、畳み込みニューラルネットワーク (以下、CNN) の手法で作成した。学習の際は、取得した HS データから「Ss1」、「Ms1」、「Ss2」、「Ms2」、「背景」に該当する領域を取り出し、それぞれの領域に当該のラベルを付けた。作成した岩種・風化判別モデルを HS-CNN モデルと呼ぶ。

亀裂の判別モデルは、RGB 画像を使用し、セマンティックセグメンテーション (以下、SS) の一つである SegNet を用いて作成した。SS はピクセル単位で対象物を認識し判別する画像認識の手法である。学習の際は、無造作に選択した亀裂に「亀裂」のラベル付けし、残りの領域に「背景」のラベル付けをした。

撮影方向による輝度差を利用して亀裂を明確に判別するため、RGB 画像を3方向から撮影した。上記の3枚の RGB 画像を、鳥瞰画像変換により全て正面方向の画像 (多視点 RGB 画像) に変換した (図-2)。通常の RGB 画像から作成した亀裂判別モデルを RGB-SegNet モデル、多視点 RGB 画像から作成したモデルを多視点 RGB-SegNet モデルとし、判別精度を比較した。

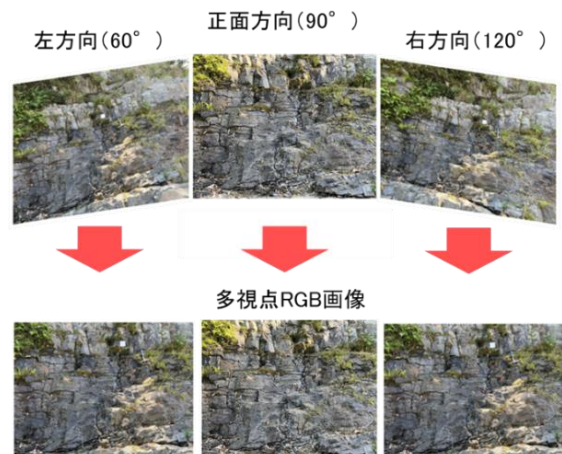


図-2 多視点 RGB 画像の作成イメージ

### 3. 結果・評価

#### 3.1 岩種・風化判別モデル

未学習データを用いてモデルによる判別を行い、判別結果の正答率（判別精度）を評価した。判別精度は95.2%と高い結果が得られた。図-3に、対象とした露頭写真と判別結果を可視化した画像を併せて示す。可視化画像は、岩種・風化程度の分布を色毎に表示している。

可視化画像上での岩種の分布境界（層理面）は、目視観察の結果と概ね一致した。また、同一岩種でも、風化程度の違いを明確に判別した。今回作成した岩種・風化判別モデルは、岩種と風化程度の分布状況を認識できる手法と評価できる。

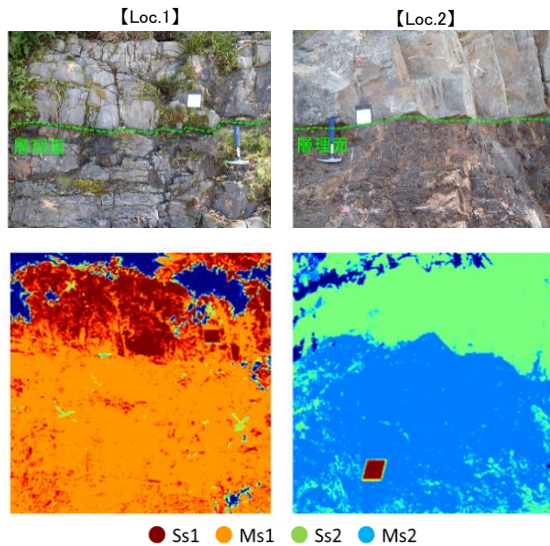


図-3 HS-CNN モデルによる判別結果の可視化画像

#### 3.2 亀裂判別モデル

##### (1) モデル作成結果と評価

未学習データを用いてモデルによる判別を行い、ラベル付けした亀裂に対する抽出率（判別精度）を評価した。RGB-SegNet モデルの判別精度は、Loc. 1：80.1%，Loc. 2：85.4%であった。多視点RGB-SegNet モデルの判別精度は、Loc. 1：86.4%，Loc. 2：84.7%であった。両モデルとも高い判別精度が得られた。図-4に、ラベル付けした亀裂箇所と、可視化した RGB-SegNet モデルおよび多視点 RGB-SegNet モデルによる判別結果を示す。可視化画像上で、亀裂と判定したピクセルを黄色で表示している。




図-4 亀裂判別モデルによる判別結果の可視化画像

両モデルともに、ラベル付けした亀裂については高い精度で抽出したが、ラベル付けしていない亀裂は抽出しなかった。また、RGB-SegNet モデルでは、亀裂として不確実な構造を亀裂として抽出した。一方、多視点 RGB-SegNet モデルによる判別は、学習した亀裂ラベルに基づいた確実な亀裂のみを抽出した。

##### (2) 亀裂間隔の算出

多視点 RGB-SegNet モデルによる判別結果の可視化画像を用いて、亀裂の間隔を算出した（表-1）。算出の際は、亀裂領域の外周線を抽出し、最も距離の近い亀裂領域との距離を亀裂間隔として求めた。

算出した亀裂間隔の平均はそれぞれ、Ss1：14.8cm，Ms1：5.1cm，Ss2：17.3cm，Ms2：39.7cmであった（表-1）。亀裂を抽出できなかった Ms2を除き、算出結果は目視観察結果の範囲内に収まっていた。

表-1 亀裂間隔の算出結果

露頭	岩盤	判別結果からの算出	目視観察
Loc. 1	Ss1	14.8cm	10~20cm
	Ms1	5.1cm	5~10cm
Loc. 2	Ss2	17.3cm	約30cm
	Ms2	39.7cm	1~3cm

##### 3.3 岩盤分類への活用の可能性

HS-CNN モデルは高い精度で岩種、風化の程度を判別できた。また、多視点 RGB-SegNet モデルは、ラベル付けした亀裂の構造を明瞭に抽出し、亀裂間隔の算出も可能であった。ただし、ラベル付けしていない亀裂は抽出できなかったため、より正確な亀裂の抽出にはラベルの付け方について検討する必要がある。上記の課題を解決し、これら2つのモデルを組み合わせることで、岩盤分類に活用できる可能性がある。

### 4. まとめと今後の展望

本研究では、HS データ、および RGB 画像から、岩種・風化・亀裂の AI 判別モデルを作成し、目視観察の結果と同等の評価を行うことができた。今後は、実用化に向けて、他地点の砂岩層・泥岩層を対象に、本研究のモデルの精度検証やモデル精度の向上が必要である。

#### 《引用・参考文献》

- 1) 青砥澄夫, 菊山浩喜 (2004) : ボーリングコア観察定量化への試み-コアの帯磁率測定による地層区分・風化度指標-, 全地連技術フォーラム2004論文集, 論文 No. 121.
- 2) 宇津木慎司 (2018) : マルチスペクトルカメラ, AI を利活用した施工現場地質状況自動評価システムの構築, 建設機械施工, Vol. 70, No. 11, p15-11.
- 3) 20万分の1地質図福「松山」(第2版) (2016) : 国立研究開発法人 産業技術総合研究所 地質調査総合センター.