

## 深層学習によるトンネル切羽の岩種判定の検討 A Study on Rock Mass Classification of Tunnel Face with Deep Learning

荒木 光一<sup>1</sup> 青木 宏一<sup>2</sup> 石濱 茂崇<sup>2</sup> 手塚 仁<sup>2</sup> 蔣 宇静<sup>3</sup>  
Kouichi Araki Kouichi Aoki Shigetake Ishihama Hitoshi Tezuka Yujing Jiang

### 1. はじめに

山岳トンネルでは、掘削の先端部である切羽での岩盤の状態を直接目視して行う切羽観察が行われ、この結果から地山を評価し、支保パターン選定などに反映している。この切羽観察では、切羽スケッチや写真、岩盤の強度や風化変質、割れ目の状態及び湧水等を記録表に整理する。切羽スケッチでは、地盤の地質時代や名称を記載する項目があり、現場技術者が現地及びトンネル切羽写真を元に岩種判定を行う。しかしながら、トンネル切羽写真からの岩種判定には個人差が生じやすく、正確な判定のためには、十分な経験と知識が必要である。また、工事の進捗に合わせてトンネル切羽写真は撮影されることから、切羽と照明位置の関係から、照度の違いや影の入り方など写真毎に撮影条件が異なってくる。

本研究では、岩種判定の省力化を目的とし、実環境下で撮影されたトンネル切羽写真から深層学習で岩種判別がどの程度可能なのかを基礎検討として確認する。

これまでに、切羽観察記録に対する人工知能の活用[1]は存在するが、切羽スケッチ作成には適用されていない。また、人工知能による岩種判定の研究[2]も存在するが、トンネル切羽の撮影には高価なスペクトルカメラを用いている。本研究では通常の施工管理で用いるデジタルカメラで撮影したトンネル切羽写真で岩種判定を行う。

### 2. データ作成方法


#### 2.1 分割写真と正解となる岩種

深層学習による岩種判定で用いるデータは、図 1 に示すように、トンネル切羽写真をグリッド状に分割した分割写真とした。支保工が一部でも写っている分割写真と複数の岩種が写っている分割写真は、基礎検討としての岩種判定には大きな影響を及ぼすと考え、今回は除外した。したがって、分割写真には一つの岩種だけが写っていることとなる。

各分割写真の正解となる岩種は、トンネル切羽写真と同一箇所の切羽スケッチから取得した。切羽スケッチには技術者による岩種判定が記載されており、トンネル切羽写真のどの辺りがどの岩種であるのかが記載されている。トンネル切羽写真と切羽スケッチのサイズを一致させて重ね合わせることで、各分割写真の正解となる岩種が分かる。

#### 2.2 データ拡張

訓練データの分割写真枚数を増加させるために、ガン



トンネル切羽写真

図 1 分割写真の作成方法

表 1 分割写真の枚数

	128x128	64x64	32x32
訓練データ	3,780	37,800	162,000
検証データ	30	60	180
テストデータ	60	180	1,200

マ補正、回転と反転を行う。ガンマ補正は写真の明るさを変更できるため、分割写真の元となるトンネル切羽写真がどのような明るさであっても対応できるようになると考えられる。回転は 90 度、180 度と 270 度、反転は左右反転と上下反転をオリジナルの分割写真とガンマ補正後の分割写真に対して行う。

### 3. 評価実験

#### 3.1 訓練・検証・テストのデータ作成

分割写真は、実際のトンネル掘削現場で撮影された 475 枚のトンネル切羽写真から作成した。適切な分割サイズを確認するために、128pixel × 128pixel、64pixel × 64pixel と 32pixel × 32pixel で分割した。ガンマ補正はエッジが消えないように、様々なガンマ値で Caddy エッジ抽出により検討した。この結果、今回は 0.5 と 2.0 で補正した。ガンマ補正後に回転と反転を行うことで、1 枚の分割写真から 17 枚の分割画像を作成した。

判定する岩種は、撮影された砂岩、ひん岩、砂岩粘板岩互層、粘板岩、チャートと輝緑凝灰岩の 6 種類とした。各岩種の分割写真の枚数は大幅に異なったため、分割写真の枚数が最も少ない岩種を基準に、全岩種の分割写真の枚数を均等にした。表 1 に、訓練データ、検証データとテストデータの分割写真の枚数を示す。表中の枚数は全岩種の分割写真を合計したものである。また、訓練データはデータ拡張後の枚数である。

#### 3.2 SE-VGGNet9 による学習と推論

学習時間を考慮して、VGGNet[3]に SE-Block[4]を適用した 9 層の SE-VGGNet9 で学習と推論を行った。図 2 に、SE-VGGNet9 の構成を示す。図中の conv は畳み込みニューラルネット、Batch Normalization と ReLU で構成されており、括弧内の数値はフィルタ数を示す。各 conv の畳み込みニューラルネットは 3x3 フィルタで、フィルタは 1 スライドで適用される。maxpool では 2x2 フィルタの 2 スライドで中間層の特徴マップを縮小する。FC は全結合層

1 五大開発株式会社 Godai Kaihatsu Corporation

2 熊谷組 Kumagai Gumi Co., Ltd.

3 長崎大学 Nagasaki University

表2 SE-VGGNet9のハイパーパラメータと正解率

データパターン	学習率	L2正則化	バッチサイズ	正解率 (%)
128x128	0.0001	1e-8	64	48.3
64x64	0.001	1e-5	256	64.4
32x32	0.001	1e-6	512	59.6
64x64を128x128にリサイズ	0.001	1e-8	128	64.4
32x32を64x64にリサイズ	0.001	1e-6	256	63.8
32x32を128x128にリサイズ	0.001	1e-7	128	65.0

を示し、括弧内はノード数を示す。FC間はDropoutが挿入されており、Dropoutの無効化確率は0.5とした。SE-Blockにおける次元削減の係数は8とした。

表2に、ハイパーパラメータと各データパターンの正解率を示す。3つの分割サイズだけでなく、64 pixel×64 pixelと32 pixel×32 pixelに関してはリサイズした分割写真での学習と推論も行った。正解率はテストデータによる推論結果から取得した。

6つのデータパターンにおいて、32 pixel×32 pixelを128 pixel×128 pixelにリサイズさせて学習したモデルが最も正解率が高くなった。これは、訓練データ数が多く、リサイズにより中間層で多くの特徴を得られたからだと考えられる。

### 3.3 SE-VGGNet13による学習と推論

32 pixel×32 pixelを128 pixel×128 pixelにリサイズさせて学習させたSE-VGGNet9のモデルで、層を追加したSE-VGGNet13をファインチューニングした。図3に、SE-VGGNet13の構成を示す。図中のconv, maxpool, FCとSE-Blockの係数はSE-VGGNet9と同様である。

推論には32 pixel×32 pixelを128 pixel×128 pixelにリサイズさせたテストデータを用いた。正解率を向上させるために、5つのSE-VGGNet13のモデルで推論し、訓練データと同じデータ拡張でTest Time Augmentationを行った。

表3に、各岩種の推論結果を示す。全体の正解率は73.0%となった。粘板岩とチャートは正解率は86.5%と

表3 SE-VGGNet13による推論結果

		SE-VGGNet13での推論結果					
		砂岩	ひん岩	砂岩粘板岩互層	粘板岩	チャート	輝緑凝灰岩
正解	砂岩	134	12	23	12	4	15
	ひん岩	11	144	21	4	5	15
	砂岩粘板岩互層	19	19	113	30	6	13
	粘板岩	3	6	14	173	4	0
	チャート	0	5	4	11	179	1
	輝緑凝灰岩	13	24	24	0	6	133

89.5%と高くなった。一方、砂岩粘板岩互層は56.5%となり、他より大幅に低くなった。砂岩粘板岩互層を砂岩、ひん岩と粘板岩に判定しているため、より質の良い砂岩粘板岩互層の分割写真を用いる必要がある。

### 4. まとめ

明るさが異なるトンネル切羽写真から深層学習で岩種判定を行った。SE-VGGNet13での正解率は73.0%となり、岩種によっては高い正解率で判定できることを確認した。

今後は、省力化に繋がる実用的な正解率を目指すためにディープニューラルネットワーク選定などを行う予定である。

### 参考文献

- [1] 畑浩二, 中岡健一, “山岳トンネル切羽評価への人工知能適用に関する研究”, トンネル工学報告集, 第27巻, I-24 (2017).
- [2] 安藤ハザマ, “マルチスペクトル画像を活用した地質状況自動評価システムの構築”, <http://www.ad-hzm.co.jp/info/2018/pre/20180202.html>, 2019年4月参照.
- [3] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-scale Image Recognition”, International Conference on Learning Representations (2015).
- [4] J. Hu, L. Shen and G. Sun, “Squeeze-and-Excitation Networks”, International Conference on Computer Vision and Pattern Recognition (2018).



図2 SE-VGGNet9の構成




図3 SE-VGGNet13の構成