# マルチモーダル深層学習による切羽剥落の予測 Prediction of Falling Rocks from a Tunnel Face by Multimodal Deep Learning

西澤 勇祐<sup>\*1</sup> 本間 伸一<sup>\*1</sup> 戸邉 勇人<sup>\*1</sup> 宮嶋 保幸<sup>\*1</sup> 福島 大介<sup>\*1</sup> Yusuke Nishizawa Shinichi Honma Hayato Tobe Yasuyuki Miyajima Daisuke Fukushima

> \*1 鹿島建設株式会社 KAJIMA Corporation

In mountain tunneling work, falls of rocks caused by oversight of tunnel face conditions have been a problem. Therefore, the authors have developed technologies to predict falling rocks using a part of rock properties. However, the accuracy is assumed to be not enough because other factors are not considered. In this paper, in order to verify the possibility of improving prediction accuracy, the authors predicted falling rocks by combining images and existing rock properties. As a result, the model combining images and the numerical values of the rock properties showed higher accuracy than the other models.

# 1. はじめに

山岳トンネル工事では地質の専門家による目視観察を通じて 切羽状況を把握しながら掘削を行っている.しかし,すべての 切羽状況を見落とすことなく完全に把握することは困難であり, 切羽の肌落ち災害の根絶には至っていない.当社では切羽画 像を処理し,風化変質度と割れ目交差密度を定量化することで, 剥落確率を予測する技術[戸邉 2018]を開発している.しかしな がら,データ数が不足していることや湧水などの剥落に影響す るとみられる他の要因が考慮されていないと考えられることから, データを自動的に収集する技術や他の要因を考慮する研究 [戸邉 2019]を進めているが十分な精度は得られていない.

一方,近年提案されているマルチモーダル深層学習は複数 種類のデータを統合して学習することで判別精度の向上を図る もので、この手法を用いることで予測精度の向上が期待できる.

本稿では切羽剥落予測精度向上の可能性を検証することを 目的に,既存の技術[戸邉 2018]で得られた岩盤性状の情報と 新たに切羽画像を処理して得られる情報を組み合わせて切羽 剥落予測を行った.

# 2. 実験方法

### 2.1 使用データ

### (1) 切羽画像

切羽画像は現場によって撮影環境が異なるほか,地質の違いによる色調の差が大きいことから,最も多くの切羽画像が得られている1現場の画像に絞って実験を行った.切羽面は半円形で外周部は判別対象外のため,切羽面の中央部のみを切り出し,画像数を増やすために4分割して使用した(図1).画像はRGBのカラー画像で,解像度は切り出した領域が剥落判別可能な約3m×3mのサイズとなる300×300ピクセルとした.



図1 切羽画像の切り出し

連絡先:西澤勇祐, 鹿島建設株式会社, 東京都港区赤坂 6-5-11, 03-5544-1405, nishizyu@kajima.com 切り出された切羽画像ごとに「剥落あり」「剥落なし」のラベリン グを行った.「剥落なし」には不安定だが運よく剥落しなかったも のも含まれることから,知見者によって特に安定と思われるもの のみを抽出して使用した.その結果,「剥落なし」の数が大きく 減少したため,データオーギュメンテーション(左右反転,上下 反転,90度回転,180度回転,270度回転)によって「剥落なし」 の画像数を増大させた(表 1).

	表1	使用した画像数		
	剥落あり	剥落なし(増大前)		
画像数	111	96 (16)		

#### (2) 岩盤性状の分布図

切羽画像を処理することで得られる風化変質度と割れ目交差 密度の分布図の例を図2に示す.一般的に剥落は風化の激し い箇所や割れ目の交差する箇所で発生しやすいとされる.風化 部は色調の変化から求め,割れ目交差密度は輝度の変化とし てあらわれる岩盤の割れ目の交差方向をメッシュごとに集計し て求めた.解像度は切羽画像と同じ300×300ピクセルとした.



#### (3) 岩盤性状の数値

前述の風化変質度の分布図において風化変質が著しい箇 所が切り出した切羽画像に占める割合と、割れ目交差密度が同 様に占める割合をそれぞれ算出し、数値データとして使用した.

#### (4) データセット

上記(1)~(3)を1つのデータセットに整理した例を表2に示す. データ数は「剥落あり」「剥落なし」あわせて207となった.

表 2 データセット例								
No.	切羽画像	岩盤性状の分布図		岩盤性状の数値(%)		剥落		
		風化変質度	割れ目交差密度	風化変質度	割れ目交差密度			
1				67	35	あり		
:								
207								

### 2.2 モデル作成

入力データの組み合わせによる精度比較のため,図3のような4パターンのモデルを作成した.切羽画像,岩盤性状の分布図(それぞれ風化変質度,割れ目交差密度)の入力は300×300ピクセルでRGBの3チャンネルとした.これらの特徴抽出には事前学習済みのResNet50を使用し,出力は2048次元の特徴ベクトルとなるようにした.岩盤性状の数値(それぞれ風化変質度,割れ目交差密度)はそれ自体が特徴量であるためそのまま使用した.特徴合成部では得られた特徴量を一つのベクトルに連結し、学習データ全体で平均0,分散1となるように正規化したほかベクトルのノルムが1になるように標準化した.判別部では3層の全結合ニューラルネットワーク(FC)により剥落の有無を判別した.



# 3. 結果と考察

データセットを4分割してクロスバリデーションを行い,得られ た平均正解率を表3に示す.切羽画像と岩盤性状の数値を入 力としたモデルがもっとも高い値を示したが,これは切羽画像か ら得られる特徴以外の情報を数値として明示的に与えたことが 要因だと思われる.そこで,切羽画像と岩盤性状の数値がとも に判別に寄与しているかを確かめるため,判別部の全結合ニュ ーラルネットワークの1層目の重みを集計した.その結果,岩盤 性状の数値に関する重みとその他の画像特徴量の重みの間に 大きな差は見られなかったため,切羽画像,岩盤性状の数値と もに判別に寄与している可能性が高いと思われる.一方で切羽 画像と岩盤性状の分布図を入力としたモデルが最も低い値とな ったが,これは特徴合成後の次元が6144と他と比較して極端に 大きいため学習が困難であったものと思われる.

実施したすべてのパターンで平均正解率が 90%を上回った ことについては、使用するデータを特定の現場で剥落の有無が わかりやすいものに限定したため、判別が比較的容易であった ものと思われる.

表3 各パターンの平均正解率				
入力	平均正解率 (%)			
切羽画像と岩盤性状の数値	98.5			
切羽画像と岩盤性状の分布図	92.5			
切羽画像のみ	95.5			
岩盤性状の数値のみ	94.8			

次に、モデルの汎化性能を確認するために、各パターンにおいてクロスバリデーションで作成された各モデルの中で最も高い 正解率を示したモデルを用いて他現場のデータを判別した。その結果、正解率は80%前後と高くなかったので(表 4)、「剥落あり」「剥落なし」の再現率を確認したところ(表 5)、岩盤性状の数値のみのモデルを除いて「剥落なし」の可現率が極端に低いことがわかった。これは他現場の「剥落なし」の切羽画像がモデル 作成に用いた現場の「剥落なし」の切羽画像がモデル 作成に用いた現場の「剥落あり」の切羽画像に似通っており、切 羽画像を入力に含むモデルで誤判別されたことが原因と考えられる。このことは他現場のデータを学習データに加える必要性 があることを示しているが、撮影環境や地質の違うデータをどの よう取り込むかという課題が残されている。

表4 他現場データの正解率					
入力	正角	择率(%)			
切羽画像と岩盤性状の数値	71.5				
切羽画像と岩盤性状の分布図	80.4				
切羽画像のみ	77.3				
岩盤性状の数値のみ	80.4				
表5 他現場データにおける「剥落	「剥落な	こし」の再現率			
入力	剥落あり	剥落なし			
	再現率	再現率			
切羽画像と岩盤性状の数値	0.85	0.12			
切羽画像と岩盤性状の分布図	0.98	0.02			
切羽画像のみ	0.93	0.07			

また,知見者によって切羽が不安定と判定されたことから取り 除いた「剥落なし」のデータ104件を,表3で平均正解率が最も 高かった切羽画像と岩盤性状の数値を入力データとしたモデ ルで判別した.その結果,およそ8割の82件が「剥落あり」と誤 判別された.このことから,「剥落あり」「剥落なし」の二者択一の ラベリングでは必ずしも切羽の剥落を予測するには十分ではな く,「剥落はないが不安定な状態にある切羽」に対するラベルを 追加するなどの対処が必要であることがわかった.

0.82

0.73

## 4. おわりに

岩盤性状の数値のみ

本稿では切羽画像と岩盤性状の情報を使用したマルチモー ダル深層学習を用いて切羽剥落予測を行った.その結果,切 羽画像と岩盤性状の数値を組み合わせたモデルで他のモデル より高い精度が得られた.一方,他現場のデータに対する汎化 性能が低かったため,今後は学習データを増やし,複数現場の データに対する汎化能力を向上させることが課題である.

### 参考文献

- [戸邉 2018] 戸邉勇人, 白鷺卓, 川端淳一, 宮嶋保幸: 画像処 理解析による山岳トンネルの切羽剥落危険度予測システムの開発, 土木学会第73回年次学術講演会, 2018.
- [戸邉 2019] 戸邉勇人,宮嶋保幸,福島大介,西澤勇祐,本間 伸一,山本拓治: CNN によるトンネル切羽の剥落危険度評 価,人工知能学会全国大会第 33 回, 2019.(投稿中)