

## CNN によるトンネル切羽の剥落危険度評価

## A prediction of rock fall from the tunnel face by convolutional neural network

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

<sup>\*1</sup> 鹿島建設株式会社  
 Kajima Corporation

Tunnel construction requires accurate prediction of occurrence of rock fall from the tunnel face, by evaluating rock mass properties, such as weathering grade, crack distribution, and others. Those evaluations are commonly based on subjective visual inspections, the results of which are likely to vary from person to person. Therefore, to achieve consistent determination of that, we developed a quantitative analytical method applied with image analysis based on engineering geology. In this method, occurrence of rock fall from tunnel face with high and/or low developmental level of weathering and crack can be predicted with a probability of approximately 80%, on the other hand, that with moderate level of weathering and crack can be done only with that of 40-60%. For improving probability, we attempted prediction of rock fall by convolutional neural network, and the result showed approximately same value as that by the above method.

## 1. はじめに

山岳トンネル工事では掘削直後の不安定な切羽に作業が集中するため、切羽からの剥落が重大災害につながる危険性を有している。そのため、切羽への接近前に切羽観察によって剥落しやすい部分を判断し、予め叩き落とすか、仮設のコンクリートを吹き付けるなどの対策工を実施する。しかし、現状の切羽観察は熟練の技術者による目視判断に依存しているため、判断に個人差や見落としが発生しやすい。切羽の安全性を向上するためには、個人差のない定量判断基準と、網羅的にすべての切羽を判断できる手法の確立が重要である。

切羽の剥落の発生は、岩盤の性状に大きく影響を受ける。そのため、技術者は、風化程度、割目の方向・連続性、岩盤強度、湧水量などの岩盤性状に着目する。そのため、こうした性状を定量評価する技術が確立できれば、個人差が低減し、切羽の安全性が向上すると期待できる。

筆者らは、これまで画像解析技術を応用し、切羽の岩盤性状のうち、風化と割目の性状を定量評価する技術を開発し、現場に適用してきた。今回、この技術に人工知能技術である ResNet-50 を組み合わせることにより、剥落の予測精度の向上を試みたので、報告する。

## 2. 画像解析による切羽の岩盤性状の定量評価法

## 2.1 風化程度の定量評価法

岩盤では、一般的に未風化部分より風化の進んだ部分において剥落が発生しやすい。そのため、切羽に占める風化部分の割合が大きいほど、剥落が発生しやすくなると考えられる。岩盤の風化(化学的風化)は、岩石中のイオンの溶脱と粘土鉱物生成の過程を経る。そのため、風化程度は、粘土鉱物の含有量を X 線回折分析することにより定量評価できる。しかしこの分析は数日間を要するため、迅速性を必要とする切羽の判定にそのまま用いることができない。

そのため筆者らは、風化によって岩盤の色調が変化する性質に着目し、切羽の色調を画像解析することにより風化程度を定量評価する手法を開発した(図 1)[戸邊 2018]。この手法により、切羽全体に占める風化部の面積率を定量評価できる。




図 1 風化程度の判定例

## 2.2 割目交差箇所の定量評価法

岩盤の割目は岩盤中の力学的な弱面であり、トンネル掘削時にはこの割目の面に沿って岩盤が分離しやすい。そのため、割目の集中する箇所ほど、剥落が発生しやすい。

割目は切羽では凹凸を有する筋として現れやすく、凹部と凸部では照明の反射率に差が生じる。そのため、写真では、割目は輝度に大きな差を生じる部分として現れやすい。この性質を利用し、画像中での輝度の変化点を白点として描画すると、切羽表面の割目を検出することができる(図 2)。

剥落は、前述のように、割目の集中している箇所において発生するが、同一方向の割目だけでは発生しにくく、異なる方向の割目が交差する箇所(割目交差箇所)において発生しやすい。この箇所を検出するため、割目の画像をメッシュに分割し、メッシュ内の主要な 2 方向の割目(第 1, 第 2 成分)を検出して(図 3)、隣接するメッシュ間で主要な割目方向を比較した。そして類




図 2 割目の検出例




図 3 メッシュ内の主要割目方向の検出例

連絡先: 戸邊 勇人, 鹿島建設株式会社 技術研究所 岩盤・地下水グループ, 東京都調布市飛田給 2-19-1, 電話:042-489-6594, Fax:042-489-8436, Email:tobeh@kajima.com

似した割目方向をもつメッシュ間を線で連結し(図 4 の緑線), この連結線が交差する箇所を交差箇所とみなした(図 4). この交差箇所のコンターを作成した結果が図 5 である. この図における, 割目交差箇所の集中域(黄色部分)が広い切羽ほど, 剥落が発生しやすいと考えられる.




図 4 割目交差箇所の検出 図 5 割目交差集中域の検出例

3. カテゴリ分類による切羽剥落評価

風化と割目の発達程度を, 切羽ごとに定量的に比較・分類し, 剥落の評価に結びつけるため, 下記に示す基準でカテゴリ分けを行った. まず, 切羽全体に占める風化部分の面積率を算出し W1~W4 の 4 つのカテゴリに分類した. すなわち, 風化程度の高い切羽は W1 とし, 風化程度の低い切羽は W4 とした. 中程度の風化程度を示す切羽の場合には, 風化部分が偏在しているものを W2, 偏在していないものを W3 とした(表 1 左). 割目交差箇所の集中域についても, 同様の方法により C1~C4 のカテゴリに分類した(表 1 右).

この 4×4=16 のカテゴリに 9 箇所の現場から集めた 307 の切羽を分類した. さらに, 307 の切羽から, 実際に剥落した 183 の切羽を抽出し, 各カテゴリにおける剥落の発生確率を算出した(表 2). この表によると, 左上のカテゴリほど風化・割目の発達性が高く, 剥落の発生率も高い結果となった(領域 1: 約 80%). また, 風化・割目の発達性が低いカテゴリでは, 剥落の発生率も低い結果となった(領域 3: 約 0%). そのため, 風化・割目の発達程度が高いあるいは低い切羽, すなわち風化・割目に特徴のある切羽では, 高い確率で剥落の有無を判定できるといえる.

表 1 風化・割目のカテゴリ分類

風化性状	風化領域の面積率	偏り	割目性状	割目交差集中域の面積率	偏り
W1	60%以上	---	W1	40%以上	---
W2	10~60%	あり	W2	10~40%	あり
W3		なし	W3		なし
W4	10%以下	---	W4	10%以下	---

表 2 風化と割目のカテゴリ評価による剥落発生確率

		割目性状 Cross			
		C1	C2	C3	C4
風化性状 Weathering	悪 ↑	100%	82%	79%	82%
		領域①			
		100%	77%	39%	56%
	良 ↓	100%	83%	53%	57%
		100%	50%	47%	0%
		領域③			

4. CNN による切羽剥落評価

領域 1,3 に対し領域 2 のように風化・割目の発達度に特徴のない, 中程度の風化・割目発達度を示す切羽では, 剥落発生確率が 40~60%程度と算出されており, この値は施工の安全判断に用いるには十分な精度といえない. このような切羽における剥落の有無を明確に評価するためには, 前述の画像解析では抽出できない岩盤の特徴を切羽画像から抽出し比較する

ことが重要と考えられる. そのため, CNN(畳み込みニューラルネットワーク)による剥落の判定を試みた.

剥落の判定は, 図 6 に示す手順により実施した. 入力する切羽画像は, 1 辺 300 画素(実切羽では約 3m に相当)で RGB3 チャンネルとした. この切羽画像の特徴の抽出には学習済みの ResNet-50 を使用し, 出力は 2048 次元の特徴ベクトルとした. 抽出された特徴量は, 1 次元化後, 学習データ全体で平均 0, 分散 1 となるように正規化するとともに, ノルム 1 になるように標準化した. そして, その後 FC により剥落の有無を判別した. 切羽画像を 300 画素にした理由は, 入力する画像数を増大させるため, 元々の切羽画像を分割したためである.

データセットを A,B,C,D に 4 分割し, 剥落の有無をクロスバリデーションにより判定させた結果, 正解率は 40~63%であった. この結果は, カテゴリ評価の領域 2 における剥落発生確率である 39~57%に近く, 精度としては充分といえない. このような結果となった主な原因には, 下記の 3 つが考えられる. 1 つ目は, 学習データに複数の岩種が混在していたためである. 異なる岩種の切羽が入力データとなっている場合, 剥落に影響を及ぼす岩盤性状の差異より, 岩種の差異のほうが特徴量として強調されやすいと考えられる. 2 つ目の理由としては, 「剥落無」として入力データのうち偶然剥落しなかった切羽が機械学習に悪影響を及ぼしたためと考えられる. すなわち, トンネル工事では切羽出現後 1 時間程度でコンクリート吹付工を実施するため, 剥落しやすい特徴を有している切羽の中に, 吹付けまでの間に偶然剥落しなかったため「剥落無」に分類された, いわば「ラッキーデータ」が存在すると考えられる. 3 つ目の理由としては, 画像だけでは剥落を精度よく予測できない切羽が存在すると考えられることである. 技術者は, 目視やカメラ画像だけで剥落の有無を判断できない切羽では, 岩盤の硬さ, 切羽からの湧水量なども判断に用いている. そのため, これらの性状を機械学習に加えることにより, 剥落予測の精度向上が期待できる.




図 6 CNN による判定方法

表 3 CNN による剥落有無の判定

データ区分	正解データ数		不正解データ数		総データ数	正解率
	剥落有	剥落無	剥落有	剥落無		
A	78	25	33	95	231	45%
B	16	110	82	18	226	56%
C	68	21	18	113	220	40%
D	10	128	72	8	218	63%

5. おわりに

今回の結果から, 風化・割目の発達度に特徴のある切羽では高精度で剥落の有無が判定可能であるが, これらの特徴のない切羽では十分な精度での判定ができず, CNN による判別でも精度に大きな差がないことがわかった. 今後の課題としては, CNN による判別精度の向上のため, データセットから異岩種やラッキーデータを排除しデータの品質を向上させることや, 画像以外の岩盤の性状を CNN に入力できる可能性を検証することなどが挙げられる. これらの課題については, 現在, 解決を試みているところである[西澤 2019].

参考文献

[戸邊 2018] 戸邊勇人, 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.  
[西澤 2019] 西澤勇祐, 本間伸一, 戸邊勇人, 宮嶋保幸, 福島大介: マルチモーダル深層学習による切羽剥落の予測, 人工知能学会全国大会第 33 回, 2019. (投稿中)