

山岳トンネル工事への2段階AI分析による地山評価手法の開発

国土交通省近畿地方整備局 笹嶋和彦
清水建設(株) ○邊見涼, 長谷川裕員
谷村浩輔, 鳥居敏
長谷陵平, 淡路動太

1. はじめに

山岳トンネル工事において、地山が持つ地質リスクを正確に評価することは、安全かつ合理的な施工をするうえで非常に重要である。毎日の切羽観察による地山評価は、切羽状態から支保工選定を行うと共に地山状況を把握して安全に施工を行うために必要な作業である。地山評価の基準としては「トンネル地山等級判定マニュアル(試行案)」¹⁾などがあり、風化変質の程度や割れ目状態、圧縮強度を目視の観察によって評価する。本手法は地質リスクを知る最も効果的な手法の一つであるが、観察者の知識や経験によって評価にバラツキが生じることが課題としてあげられてきた。

AIによる地山評価手法は、主観的になりがちな目視による切羽観察を補完する客観的な手法として、近年数多くの開発が進められてきている。事前に習熟技術者の知識と経験をAIに学習させ、習熟技術者と同様の評価を行えるAIを開発するというものである。しかし、切羽観察時における習熟技術者の複雑な判断基準や視点をひとつのAI分析によってルール化し評価することは困難であった。

そこで筆者らはディープラーニングと機械学習(勾配ブースティング決定木)の2段階のAI分析手法を用いた新たな地山評価手法を開発した²⁾。本手法では切羽の特徴量の抽出と切羽評価点の点数付けをそれぞれ別の手法で学習したAIによって分析させることで、切羽観察時に必要な多角的な視点を再現することができた。本稿では、切羽画像と切羽三次元データ(DEM画像)、切羽穿孔エネルギー値の3種類のデータを用いて技術者判断との関連性を学習させたAIモデルにより、切羽評価項目9項目について判定を行ったのでその結果について述べる。和歌山県にある泥岩主体の堆積岩地山を対象とした。

2. 現場概要

すさみ串本道路(仮称)二色トンネルは、和歌山県串本町に位置し、トンネル延長365m、掘削断面積116m²、内空幅が11.56mの大断面トンネルである。トンネル延長の約40%は地山強度比が0.4~1.6の低強度塑性地山と予想され、延長の約60%は小土被りである(図-1)。

地質は新第三期中新世の熊野層群敷屋累層の泥岩および泥岩優勢の砂岩泥岩互層からなる。多くは層状岩盤であったが、部分的に砂岩が卓越する箇所は塊状であった。土被りが浅いことから、地下水等により酸化風化し、茶褐色に変色した切羽が多くみられ、一部岩芯まで風化している様子が認められた。岩片は比較的硬質であったが、部分的に割れ目が開口しており、割れ目沿いに流入粘土や小規模な断層が発達して、割れ目を利用した小崩落や剥落等が発生していた。湧水は適水程度しか確認されず、地下水位はトンネル掘削高さより下方にあったと考えられる。

設計時の地山等級は低土被り部を除きDⅠとCⅡが混在していたが、切羽評価の結果、ほとんどはDⅠと判定された。




図-1 二色トンネル地質縦断面図

キーワード 切羽AI, 山岳トンネル, ディープラーニング, 切羽観察, 機械学習

連絡先〒104-8370 東京都中央区京橋2丁目16-1 清水建設(株)グローバルプロジェクト室

3. 2段階 AI 分析による地山評価

本手法では、切羽画像、DEM 画像、穿孔エネルギー値を使用した。DEM 画像は複数の切羽画像を SfM 変換した三次元データからの数値標高モデル画像であり、切羽の凹凸を 2 値（白黒）で表現する。切羽画像は風化度合いの評価に、DEM 画像は割れ目状態の評価に、穿孔エネルギー値は切羽の硬軟（圧縮強度）の評価に用いた。それぞれの特徴量を数値化し、目視観察による技術者の評価との相関を AI に学習させた（図-2）。




図-2 AI による地山評価フロー

(1) 切羽の特徴量の抽出

a) ディープラーニングを用いた切羽の風化及び割れ目状態の特徴量の数値化

切羽画像と DEM 画像は深層学習の一手法である CNN（畳み込みニューラルネットワーク）の画像分類モデルを用いて特徴量化した。画像はそれぞれ縦 6×横 12 の 72 分割し、1 ブロックを RGB 形式で 300×300 ピクセルの解像度とした。分割することで、AI 学習用の教師データを多く取得できるようになった。また細かく評価できるため切羽全体だけではなく局所部を考慮することが可能となった。DEM 画像は特徴量をよりはっきりするため事前に 2 値化処理を行った。画像は風化用（1180 枚）、割目用（364 枚）を風化・割れ目の度合で各 3 段階のクラスに分けし、教師データとして転移学習に用いた。3 段階のクラス分けは、AI による判定精度を高めるために視覚的に判別しやすい特徴を利用した。風化の場合、風化に伴い岩石が茶褐色に変色することを利用し、色を特徴として分類した。割れ目の場合は、開口状態や規則性を考慮し、割目の大きさで分類した（図-3）。分類モデルは十分な学習精度を確保した（図-4）。




図-3 ディープラーニングを用いた画像分類モデルの分類例

分類	Precision	Recall	分類	Precision	Recall
1	95%	90%	1	100%	89%
2	76%	77%	2	85%	88%
3	79%	82%	3	81%	88%

風化モデル精度 割目モデル精度

図-4 各モデルの学習精度

学習した AI モデルを用いて 3 クラスに分類した結果、切羽の風化の程度と割れ目状態の分布状況について 1 ～ 3 点で表現される特徴量の数値化データを獲得した (図-5)。




図-5 数値化した切羽 (左: 風化の程度、右: 割れ目の状態)

b) 穿孔エネルギー値による切羽の硬軟の評価

毎切羽、同じ 10 か所からドリルジャンボを用いて取得した穿孔エネルギー値を統計処理し、得られた切羽毎 (1m) の数値を切羽の硬軟を示す特徴量の数値化データとして解析に用いた (図-6)。併せて代表的な切羽の転石を用いて点載荷試験を行い、評価基準の参考値 ($100\text{J}/\text{cm}^3 \approx 37.5\text{MPa}$) とした。




図-6 数値化した切羽 (穿孔エネルギー値)

(2) 機械学習した AI モデルによる判定

獲得した切羽の特徴量の数値化データと技術者が評価した評価点との相関関係を学習させることで、AI による地山評価が可能となった。9 項目の評価項目に関連する数値化データを選択し、通常の切羽評価と同様に切羽の天端、左肩、右肩のそれぞれの部分において分析を行った (図-7)。教師データでは、選択した数値化データを説明変数とし、技術者の評価を目的変数とした。特徴量は複数選択可能で同時に分析可能なため、これにより技術者が判断する際の多角的な視点を表現した。

(3) 実装したアルゴリズム

本手法でのディープラーニングおよび機械学習は Apple CoreML フレームワークを用いて Swift5 言語で MacOS10.15 上に実装した。切羽画像と DEM 画像からの特徴量の抽出では Apple CreateML ImageClassifier (CNN による転移学習) を用いて数値化を行った。また特徴量の数値化データと評価点との関連付けの機械学習には CreateML Boosted Tree (勾配ブースティング決定木) アルゴリズムを用いて分類モデル構築を行った。

	風化	割目	穿孔E
①切羽の状態	●	●	●
②素地面の状態	●	●	●
③圧縮強度			●
④風化変質	●		
⑤割目の頻度		●	
⑥割目の状態		●	
⑦割目の形態		●	
⑧湧水	●	●	●
⑨水による劣化	●	●	●
⑩新方向縦断	●	●	●
⑪新方向横断	●	●	●

図-7 選択した特徴量

4. AI による地山評価結果と技術者との比較

(1) 教師データ数による比較

坑口から 100m までの観察結果を教師データとした AI モデルと、同様に 200m までの観察結果を教師データとしたモデルとの比較を示す (図-8)。目視による観察結果の評価点は、坑口から 30m 程度は点数が低くなる (地山が良くなる) 傾向が見られ、それ以降はあまり大きなばらつきがなく、2.1～2.3 点前後で推移した。

それぞれの AI モデルについて切羽観察をしていない未知のデータに対して予測を行った結果、どちらについても教師データと同じ傾向の評価結果となった。それぞれについて二乗誤差を比較すると、100m までのモデルは 0.1908 に対し、200m までのモデルは 0.1508 と誤差が小さくなり、教師データを増やすことにより切羽観察結果と AI 予測結果が全体的に近づき精度が向上することがわかった。




図-8 教師データ数ごとの評価結果の違い

(2) AI による判定結果と考察

切羽評価項目の9項目についてAIによる評価と切羽観察結果を比較した。未知のデータを分析した代表的な結果を図-9, 10に示す。本切羽は層状の砂質泥岩と泥質砂岩からなり、黒灰色を呈していた。全体的に風化している様子が見られ、茶褐色に変色している様子が見られた。風化に伴う岩石強度の低下は見られなかったが、割目が非常に細かく部分的に開口しており、左肩では割れ目を利用して頻繁に剥落する様子が観察された。




図-9 ディープラーニングによる分析結果

ディープラーニングの分析結果では、風化が顕著な箇所について風化あり（濃い青色）と分類されていることがわかった。割れ目については、大きな割れ目が卓越する箇所、細かい割れ目が見られる箇所についてAIが認識していることがわかった。

AIによる切羽評価点と目視による切羽評価点が一致した例を図-10に示す。9項目の中では、圧縮強度、割れ目の頻度、水による劣化で一致したが、その他については観察結果とAI予測の点数が一部異なっていた。予測は、教師データ内の数値化データの値と配列パターンに一番近い観察結果を評価点として選択する。9項目のうち圧縮強度は、評価区分ごとに閾値が大きく異なることから比較的予測結果が一致しやすいと考えられる。一方

で、湧水の項目は、今回採用した3つの特徴量（風化、割れ目の状態、圧縮強度）のどれとも関連性が薄く適切な判定が難しかったと考えられる。また、風化変質については、今回風化を色によって分類したため、色の違いが顕著な「1. なし・健全」と「2. 岩目に沿って変色」の区分は可能だが、色合いがあまり変化

1. 切羽基礎情報

掘削年月日	2020/02/20
測点	No.175+50 m
坑口からの距離	204 m
土被り高さ	19.6 m

区間区分	評価
------	----

切羽No.	204
-------	-----

2. AI地山判定システムの予測

評価区分（掘削地点の地山の状態と挙動）					
(A) 切羽の状態	1. 安定	2. 壁面から岩塊が抜け落ちる	3. 壁面の押し出しが生じる	4. 壁面は自立せず崩れ、あるいは流出	5. その他
(B) 未掘削の状態	1. 自立（音速不要）	2. 時間がたつと崩れ落ちる（後遺症）	3. 自立困難掘削後早期に失保する（先遺症）	4. 掘削に先行して山崩れを受けておく必要がある	5. その他
(C) 圧縮強度	1. $\sigma_c \geq 100 \text{ kPa}$ ハンマー打撃はね返る	2. $100 \text{ kPa} < \sigma_c \leq 200 \text{ kPa}$ ハンマー打撃は砕ける	3. $200 \text{ kPa} > \sigma_c \geq 500 \text{ kPa}$ ハンマー打撃は砕ける	4. $500 \text{ kPa} > \sigma_c \geq 1000 \text{ kPa}$ ハンマー打撃は砕ける	5. その他
(D) 風化変質	1. なし・健全	2. 岩目に沿って変色、強度やや低下	3. 全体的に変色、強度相当に低下	4. 土砂状、粘土状、硬質、当初より未固結	5. その他
(E) 割れ目の頻度	1. 間隔 $d \leq 1 \text{ m}$ 割れ目なし	2. $1 \text{ m} < d \leq 20 \text{ cm}$	3. $20 \text{ cm} > d \leq 5 \text{ cm}$	4. $5 \text{ cm} > d$ 硬質、当初より未固結	5. その他
(F) 割れ目の状態	1. 密着	2. 部分的に開口	3. 開口	4. 粘土を挟む、当初より未固結	5. その他
(G) 割れ目の形状	1. ランダム形状	2. 柱状	3. 層状、片状、鱗状	4. 土砂状、細片状、当初より未固結	5. その他
(H) 湧水	1. なし・湧水程度	2. 湧水程度	3. 集中湧水	4. 全面湧水	5. その他
(I) 水による劣化	1. なし	2. 腐みを生ず	3. 軟弱化	4. 崩壊、流出	5. その他
(J) 掘削方向（切羽をみて）	1. 水平 ($10^\circ > \theta > 0^\circ$) 2. さし目 ($30^\circ > \theta > 10^\circ$, $80^\circ > \theta \geq 60^\circ$) 3. さし目 ($60^\circ > \theta \geq 30^\circ$) 4. 流れ目 ($60^\circ > \theta \geq 30^\circ$) 5. 流れ目 ($30^\circ > \theta \geq 10^\circ$, $80^\circ > \theta > 60^\circ$) 6. 垂直 ($6^\circ \geq \theta \geq 80^\circ$) (切羽面の見かけの傾斜角をとる)				
(K) 掘削方向（切羽をみて）	1. 水平 ($10^\circ > \theta > 0^\circ$) 2. さし目 ($30^\circ > \theta > 10^\circ$, $80^\circ > \theta \geq 60^\circ$) 3. さし目 ($60^\circ > \theta \geq 30^\circ$) 4. 流れ目 ($60^\circ > \theta \geq 30^\circ$) 5. 流れ目 ($30^\circ > \theta \geq 10^\circ$, $80^\circ > \theta > 60^\circ$) 6. 垂直 ($6^\circ \geq \theta \geq 80^\circ$) (切羽面の見かけの傾斜角をとる)				

評価点 = $\{ \sum (\text{左肩} \times \text{重み係数}/100) + \sum (\text{右肩} \times \text{重み係数}/100) + \sum (\text{2. 天端} \times \text{重み係数}/100) \} / 4$
 ※ () 内の計算は小数点第2位を四捨五入

重み係数	観察結果			AI予測		
	左肩	天端	右肩	左肩	天端	右肩
16	3	2	2	2	2	2
8	2	2	2	2	2	3
26	2	2	2	2	2	2
13	3	2	2	3	3	3
6	3	3	3	3	3	3
3	3	3	2	2	2	2
6	3	3	3	3	2	3
9	1	1	1	1	1	2
13	2	2	2	2	2	2
評価点対象外	5	5	5	4	5	4
	5	5	5	5	1	5
評価点	2.3			2.3		

図-10 AIによる評価点予測結果

しない評価区分 2 と 3 については分類が難しかったと考えられる。

5. 2 段階 AI 分析による地山評価手法の今後の展開

現場での実験結果より、教師データを増やすことで精度向上が図れることが確認できた。今後、さらに多くの数値化データのパターンを AI に学習させることで、さらなる精度の向上が図れると考えられる。一方で、今回の湧水のように、関連が薄い教師データを用いて学習させた場合、評価点が分散したり、評価点が教師データの分布数の影響を受けたりして、適切な評価が行えない可能性が考えられた。そのため各切羽評価項目に関連する特徴量を教師データとして新たに採用することと、より評価区分の評価視点にそった特徴量を選択していく必要があり、そうすることでさらに高度な AI による地山評価手法が確立できると考えられる。

6. まとめ

堆積岩地山である二色トンネルにおいて、2 段階 AI 分析による地山評価手法を適用した結果、得られた知見は以下のとおりである。

- ディープラーニングによる分析結果では、切羽の風化の程度と割れ目状態に関して、特徴量ごとに高い精度で分類することができた。視覚的に判別しやすい特徴を用いることで、切羽の特徴量を抽出することが可能であることがわかった。
- AI による切羽評価点の判定結果は、技術者の目視による観察結果と傾向が一致した。
- 教師データ数の異なるモデルを比較した結果、教師データ数が多いモデルほど誤差が小さくなったことから、教師データ数を増やすことで精度の向上が図れることが確認できた。
- 今後、採用する特徴量を増やし評価項目に沿ったモデルを構築することで、より高度な AI による地山評価手法が確立できると考えられる。

7. 参考文献

- (1) 近畿地方整備局道路部工事課：トンネル地山等級判定マニュアル（試行案）、2016 年
- (2) 長谷川裕員，邊見涼，鳥居敏，谷村浩輔，淡路動太：山岳トンネル地山評価における深層学習とアンサンブル学習の適用，人工知能学会（第 34 回），2020 年