

深層学習による山岳トンネル切羽の岩盤評価および支保設計に関する研究

関西大学環境都市工学部 教授 ○楠見晴重、尹禮分

1. 研究背景および目的

NATM (New Austrian Tunneling Method) 工法地山の強度を活用して周囲の地層と一体化することでトンネルの強度を得ている。そのため、地山等級区分に基づき標準的な支保パターンが設定されるが、トンネル施工時には技術者の目視による掘削断面すなわち切羽の状況（岩判定）を観察・計測し、その結果から最適な支保パターンが決まる。「安全性」および「経済性」を確保した合理的な施工を行うために、切羽面の岩盤評価に基づいた適切な支保パターンの決定が重要となり、通常の岩盤評価は各現場における技術者によって、あらかじめ決められた評価項目にしたがって点数付けを行う。一方、熟練した技術者や建設現場での人材不足などのなかで、人工知能（Artificial Intelligence, AI）や情報通信技術（Information and Communication Technology, ICT）を建設現場に取り入れ、人間の判断や経験を活かしながら客観的かつ標準的な評価手法として確立しようとする動きがある。

そこで、山岳トンネル施工時の作業における熟練技術者の目視から支保パターンの判定までの過程に機械学習を導入し、技術者を支援するトンネル切羽の岩盤判定システムおよび支保パターン決定システムの構築を目的とする。トンネル建設現場から収集されたデータを用いて検証する。具体的には、深層学習を用いて、9項目4段階の切羽観察様式の割れ目の3項目や風化変質に関する評価項目を活用し、トンネル切羽面の岩盤評価に対する適用性について検討する。割れ目の3項目では、CNN（以下 Convolutional Neural Network）を用いて検証し、風化変質の項目では、CNNとHSV色空間を用いて解析を行った。また、CNNの可視化技術である Gradient-weighted Class Activation Map (Grad-CAM) を適用し、CNNが実際に岩盤亀裂を判断根拠として評価できるかを検証する。最後に、上記で得られた、割れ目、風化変質の評価点を基に、Support Vector Machine（以下 SVM）を用いて支保パターン設計を行う。

2. 切羽の岩盤評価および支保パターン

岩盤判定において切羽を観察する際、国土交通省が設定した基準となる、評価区分判定の目安として統一された9つの項目（表-1）を、切羽を図1で示すように右肩、天端、左肩の3つに分けて評価し、1つの切羽に対して計27個の項目に1~4点の点数が施工者の判断によって付けられる。その後、定められた計算方法によって、1つの切羽につき1つの点数が求められる。この点数を評価点とする。評価点に基づき、切羽から地山の状態を確認した後、地山を支えるために適切な支保構造を設定するが、その支保パターンにはB, CI, CII, DI, DII, DIIIがある。

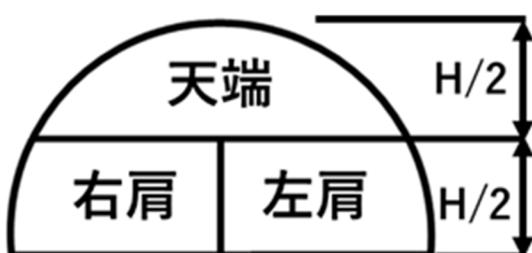


図1 天端、左肩、右肩の分け方 (H : 上半掘削高さ)

表 1 切羽面の評価項目一覧

評価項目	評価点 1	評価点 2	評価点 3	評価点 4
切羽の状態	安定	鏡面から岩塊が抜け落ちる	鏡面の押し出しを生じる	鏡面は自立せず崩れ、あるいは流出
素掘面の状態	自立	時間がたつと緩み肌落ちする	自立困難掘削後早期に支保する	掘削に先行して山を受けておく必要がある
圧縮強度	$\sigma_c \geq 100\text{MPa}$ ハンマー打撃跳ね返る	$100\text{MPa} > \sigma_c \geq 20\text{MPa}$ ハンマー打撃で碎ける	$20\text{MPa} > \sigma_c \geq 5\text{MPa}$ 軽い打撃で碎ける	$4.5\text{MPa} \geq \sigma_c$ ハンマー刃先食い込む
風化変質	なし・健全	岩目に沿って変色、強度やや低下	全体に変色、強度相当に低下	土砂状、粘土状、破碎、当初より未固結
割れ目の頻度	間隔 $d \geq 1\text{m}$ 割れ目無し	$1\text{m} > d \geq 20\text{cm}$	$20\text{cm} > d \geq 5\text{cm}$	$5\text{cm} > d$ 破碎 当初より未固結
割れ目の状態	密着	部分的に開口	開口	粘土を挟む、当初より未固結
割れ目の形態	ランダム方形	柱状	層状、片状、板状	土砂状、細片状、当初より未固結
湧水	なし・滲水程度	滴水程度	集中湧水	全面湧水
水による劣化	なし	緩みを生ず	軟弱化	崩壊、流出

3. CNN と Grad-CAM の概要

CNN は昨今、画像認識分野で広く活用されている深層学習の一種で、画像を入力データとしていくつかの特徴的な機能を持った層に通して画像分類を行う。層の構成は、複数の畳み込み層、プーリング層からなる特徴抽出部と全結合層からなる識別部に分かれている。入力画像データは、まず、畳み込み層で複数のフィルタを活用して画像の特徴を検出し、次にプーリング層で計算量を削減するために、畳み込み層から入力された特徴量マップのサイズを縮小する。これらの処理が繰り返され、全結合層でこれまでの層で検出された特徴の組み合わせから予測結果に分類する。そして、順伝播（入力から出力へ情報が伝わる）で得られた出力値と予め用意されている教師値との誤差を求め、それを逆伝播（出力から入力へ情報がさかのぼる）し、勾配降下法を使用して各層の重みとバイアスを調整、誤差を最小化することで最適なモデルを構築する。

Grad-CAM は CNN による出力結果の判断根拠を可視化する技術であり、予測値と全結合層の前の畳み込み層で生成された各特徴量マップとの勾配を利用する。まず、順伝播で特徴量マップと出力結果を求め、次に求めた出力結果を利用して逆伝播し、各特徴量マップの勾配を計算する。勾配の大きい pixel ほど予測結果に寄与しているため、計算された勾配をヒートマップ化することで CNN が画像のどの部分に着目して判定しているのかを確認できる。

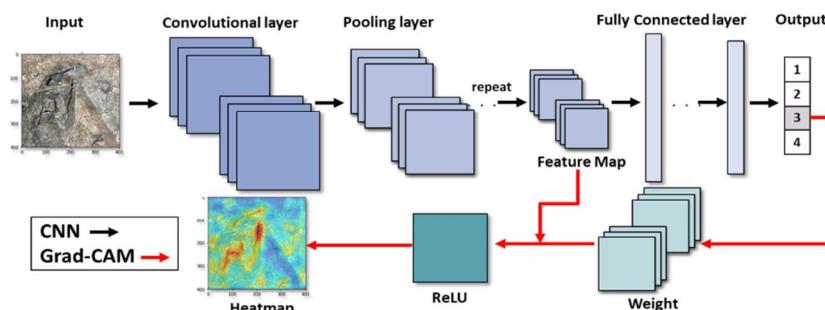


図 2 CNN と Grad-CAM の概略図

4. HSV (Hue · Saturation · Value) 色空間

HSV 色空間とは、色を「色相(Hue)」、「彩度(Saturation)」、「明度(Value · Brightness)」の 3 要素で表現する方式である。色相は、赤や緑といった具体的な色を定義する要素、彩度は、色相で定義された色の鮮やかさ・濃さを表す要素、明度は、色相で定義された色の明るさ・暗さを表す要素である。HSV 色空間の利点としては、細かな色の調整が可能である点や、色の調整が容易であるといった点が挙げられる。図 3 に 3 要素を示す。

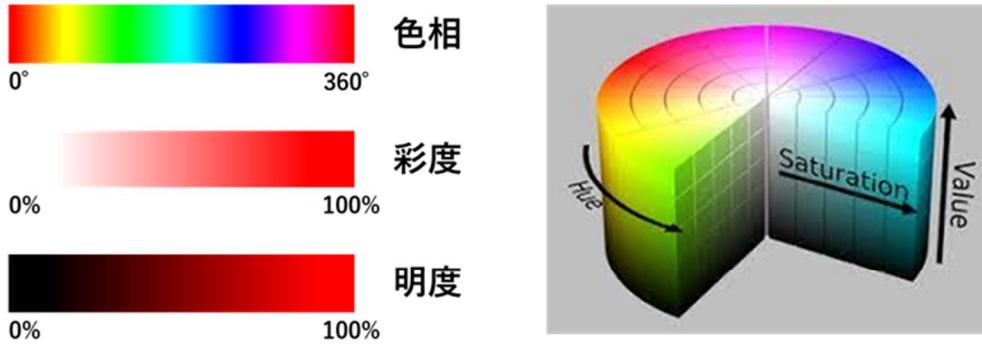


図 3 HSV 色空間の 3 要素

5. SVM の概要

本章では、機械学習の一種であるサポートベクタマシン (Support Vector Machines, 以下 SVM いう)について述べる。SVM は、特にパターン分類や関数近似の効果的な方法として注目を集めている。この方法の大きな特徴としては、マージン最大化による分離超平面の生成およびカーネル法を用いることである。

例えば、学習データ $\{(\mathbf{x}_i, y_i), i = 1, \dots, \ell\}$ に対し、 $y_i = +1$ or -1 のいずれをとる 2 値の分類問題を考える。通常、与えられた問題は線形分離が不可能であり、このとき、ある非線形関数 Φ を用いて高次元の特徴空間へ写像 ($\mathbf{z} = \Phi(\mathbf{x})$) する（図 4）。これによって、線形分離可能な状態となり、以下のような分離超平面を見つけることになる：

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{z} + b \quad (1)$$

その後、 $f(\mathbf{x}_i) \geq 0$ ($y_i = +1$)、 $f(\mathbf{x}_i) \leq 0$ ($y_i = -1$) のように分離されるとする。

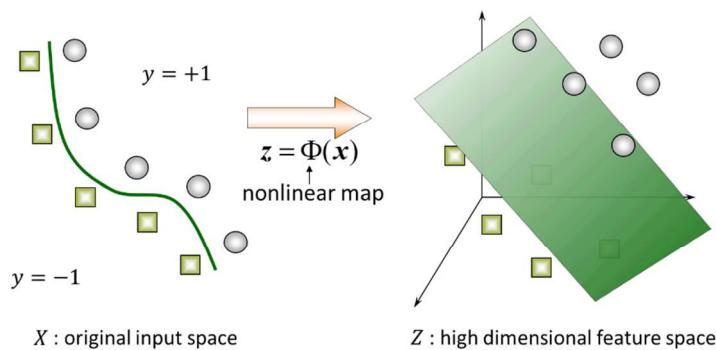


図 4 データの高次元特徴空間への写像

6. 評価指標

表 2 に多クラス分類の混同行列を示す。データサイエンス技術を用いて「予測モデル」を生成した際に、そのモデルの性能を定量的に計測することが必要である。評価指標とはモデル性能を図るために

の計算式である。本研究では、予測結果全体がどの程度真値と一致しているかを表す正解率(Accuracy)、陽性と予測したものの内、実際に陽性だったものの割合を表す再現率(Recall)、実際に陽性であるもの内の、陽性と予測することが出来た割合を表す適合率(Precision)の 3 指標を使用する。また、正解率は式(2)、再現率は式(3)、適合率は式(4)で表すことが出来る。

表 2 多クラス分類の混同行列

		CNNによる予測結果		
		A	B	C
実際の評価点	A	TrueA (TA)	FalseB(A) (FBA)	FalseC(A) (FCA)
	B	FalseA(B) (FAB)	TrueB (TB)	FalseC(B) (FCB)
	C	FalseA(C) (FAC)	FalseB(C) (FBC)	TrueC (TC)

$$\text{正解率} = \frac{TA + TB + TC}{TA + FBA + FCA + FAB + TB + FCB + FAC + FBC + TC} \times 100 \quad (2)$$

$$\text{再現率} = \frac{TA}{TA + FBA + FCA} \times 100 \quad (3)$$

$$\text{適合率} = \frac{TA}{TA + FAB + FAC} \times 100 \quad (4)$$

7. CNN による岩盤亀裂に関する評価点判定

(1) 解析概要

本解析では、切羽画像を入力データ、9 項目 4 段階切羽観察様式の割れ目に関する評価項目 (E) 割れ目の頻度、(F) 割れ目の状態、(G) 割れ目の形態の評価点を出力データとし、CNN の学習、モデルの構築、検証を行い、岩盤亀裂に対する評価を実施する。入力前の画像処理は、図 5 に示すように、現場で撮影された切羽全景画像を支保が映り込まない範囲でトリミングをし、実際の 1m に相当する 400px×400px の単位で左肩、右肩部を 10 分割、天端部を 14 分割する。分割した画像から鏡吹付や鏡ボルトが映っている画像を除去したものを解析データとして扱う。また、実際の現場では分割画像ではなく、天端、左肩、右肩で評価点を付けているので、出力された複数の分割画像に対する評価点を天端、左肩、右肩に集約して再評価を行う。

教師データを表 2 に示す。表 3 の教師データは、熟練技術者が各分割画像に対して修正した評価点である。過去に、全景に対する評価点を分割画像に流用して解析を行ったが、明らかに健全な切羽分割画像を評価点 3 や 4 という扱いにして学習をしていた問題を確認した。この問題を解決する為に、各分割画像に対して評価点の修正を行った。テストデータは、表 4 に示した切羽全景画像を 2307 枚に分割した画像を使用する。また、使用した切羽画像は、主に火成岩（花崗閃緑岩）と堆積岩（砂岩・泥岩）で構成されている。

本研究で使用する CNN は、4 つの畠み込み層、3 つのプーリング層、3 つの全結合層で構成されており、プーリング層は Max Pooling、活性化関数は CNN 部と NN 部では ReLU 関数、出力層では Softmax 関数を使用し、多層の学習の際に生じやすい過学習を防止するために Dropout 層を NN 部に追加する。尚、学習する

際の epoch 数を 300 回, batchsize を 16 と設定し, 予測値と教師値を求める損失関数, 重みとバイアスを調整する勾配降下法のアルゴリズムは, それぞれ categorical crossentropy, Adagrad を使用する.

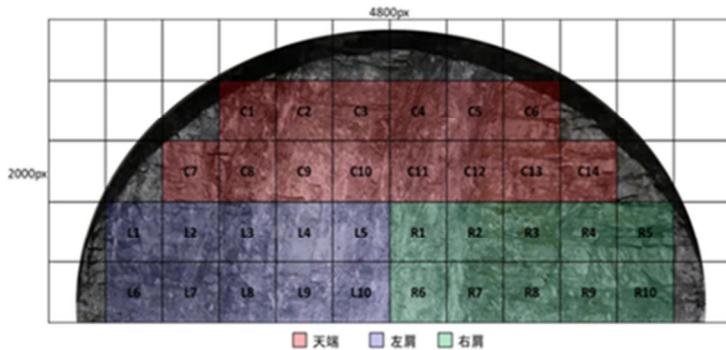


図 5 切羽画像と分割メッシュのマッピング関係

表 2 評価点判定の教師データ

評価項目	全データ (枚)	1 点 (枚)	2 点 (枚)	3 点 (枚)	4 点 (枚)
(E)	476	69	159	139	109
(F)	460	69	214	96	81
(G)	307	71	10	150	76

表 3 評価点判定のテストデータ (分割前)

評価項目	全データ (枚)	1点(枚)	2点(枚)	3点(枚)	4点(枚)
(E)	315	2	122	181	10
(F)		35	233	40	7
(G)		81	3	223	8

(2) 解析結果

図 6 は, CNN による岩盤亀裂に関する評価点判定結果である. 評価項目 E の正解率は 77.5%, 評価項目 F の正解率は 76.4%, 評価項目 G の正解率は 74.1%という結果になった. 評価項目 E の評価点 1 の再現率 (recall), 適合率 (Precision) が低い理由はテストデータの枚数が不十分であるからと考えられる. また, 誤判別している切羽画像の多くが, 割れ目間隔が非常に狭く, 割れ目深さが浅い切羽画像だった. このような切羽画像を CNN は健全と判断していた. 評価項目 F で誤判別している切羽画像の多くが評価点 2, 3 点の画像であった. 評価項目 F の評価基準である, 「2. 部分的に開口」と「3. 開口」の違いが CNN にとって判断が困難であるという結果となった. 評価項目 G で誤判別している切羽画像の多くは, 学習枚数の少ない評価点 2 の画像であった. しかし, 学習枚数が極端に少ないにも関わらず, 正解に判別できていた画像もあったことから, 学習枚数を増やすことでこの問題は解決されると考えられる.

次に Grad-CAM の結果を示す. 評価項目 E と評価項目 F の Grad-CAM の解析では, 亀裂のある岩盤の判断基準は正しいが, 4 点である土砂と 1 点である健全な岩盤の判断基準が似ているといった問題点があった. 図 7 に評価項目 G の評価点 4, 1 の画像を示す. 図 7-(a)のような評価基準が岩盤亀裂を対象としていない 4 点の画像において, CNN の着目度が亀裂部分で低く, その周辺の土砂・細片状態で高いことを確認した. また, 図 7-(b)のような亀裂がない 1 点の岩盤では, 画像全体において CNN の着目度が高くなっていることを確認した. このことから, 評価項目 G では評価基準に沿った判断が出来ていることを確認した.

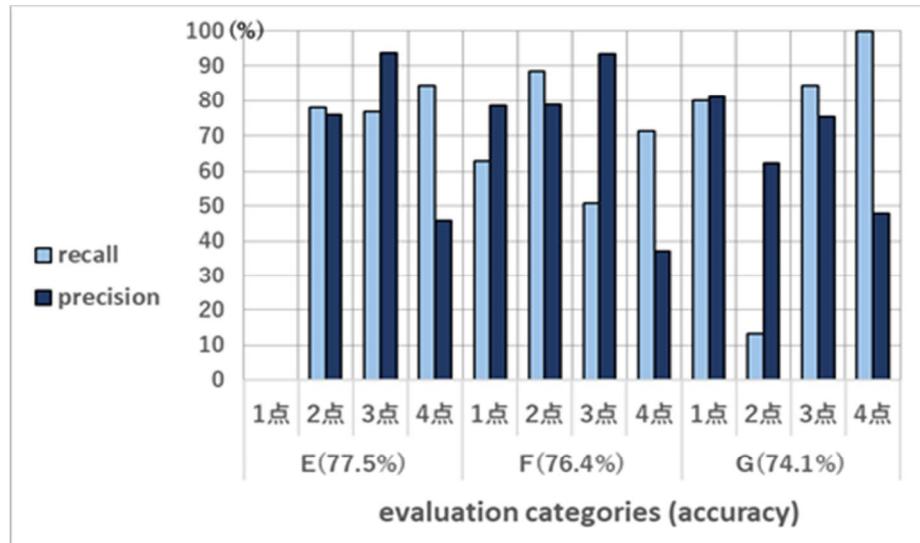


図 6 CNN による岩盤亀裂に関する判定結果

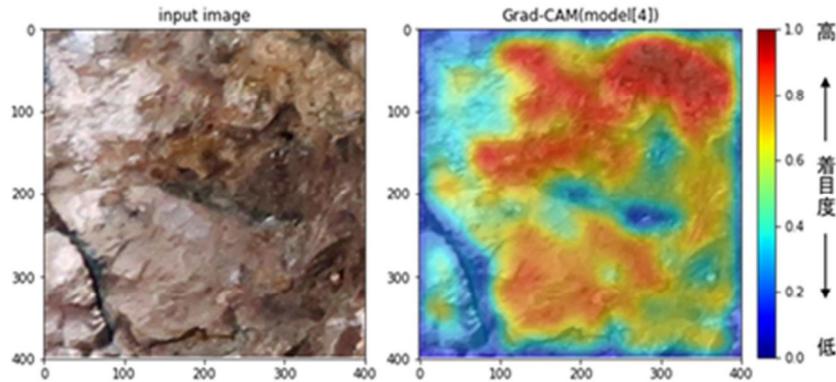


図 7-(a) Grad-CAM の結果(G の 4 点の場合)

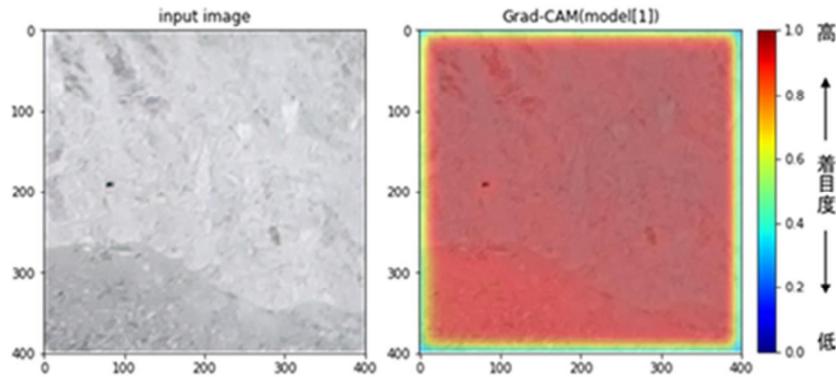


図 7-(b) Grad-CAM の結果(G の 1 点の場合)

8. CNN による岩盤風化に関する評価点判定

(1) 解析概要

本解析では、切羽画像を入力データ、9項目4段階切羽観察様式の風化変質に関する評価項目（D）風化変質の評価点を出力データとし、CNNの学習、モデルの構築、検証を行い、岩盤風化に対する評価を実施する。入力前の画像処理は、図5に示すような切羽全景画像を、800px×2000px（天端、左肩、右肩単位）で分割する。分割した画像から鏡吹付や鏡ボルトが映っている画像を除去したものを解析データとして扱う。表4に本解析で使用した画像データを示す。この画像を教師学習用とテスト用8:2の割合で分けてCNN解析を行った。CNNモデルの学習・検証方法は、より正当な評価を行うために、k分割交差検証（k=5）を

適用する。これは、全データを 5 つのグループに分け、4 つのグループで CNN モデルの学習を行い、残り 1 つのグループでモデルの検証を実施し、それを 5 回繰り返す方法で、それを 2 セットして作成された検証損失が最小値時の 10 個のモデルで評価を行う。学習の際のモデルの構造、ハイパーパラメータは 7 章と同様の条件で行う。

表 4 岩盤風化解析で使用した画像

評価項目	合計 (枚)	1点(枚)	2点(枚)	3点(枚)	4点(枚)
(D)	1350	170	858	139	109

また、風化変質の評価は風化変色箇所に重きを置いて評価することが多いので、HSV 色空間を用いて切羽画像の風化変色箇所を抜き取った、図 8-(b)のような加工画像も解析に使用し、無加工画像を用いた解析と加工画像を用いた解析で正解率に変化があるのかを比較検討する。



図 8-(a) 元の切羽画像

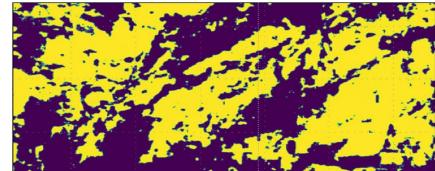


図 8-(b) HSV 加工画像（黄：風化変色箇所）

(2) 解析結果

図 9 は CNN による岩盤風化に関する評価点判定の結果である。図 9 を見てわかる通り、風化面積抽出加工を施した画像での解析は、無加工画像での解析よりも正解率が約 13% 向上した。このことから、風化変質を評価する際に実際の現場では色相を重要視していることが分かった。CNN の予測が外れた原因として考えられるのは、写真のみでは岩芯部の固さを考慮することが出来なかったからであると考えられる。本解析では、風化変質の表面的な要素を強調して解析を行ったので、この解析に圧縮強度、穿孔エネルギー等の内面的な情報を与えて解析を行うことで、表面的な要素と内面的要素の 2 つを考慮した解析を行うことが可能になるのではないかと考えられる。

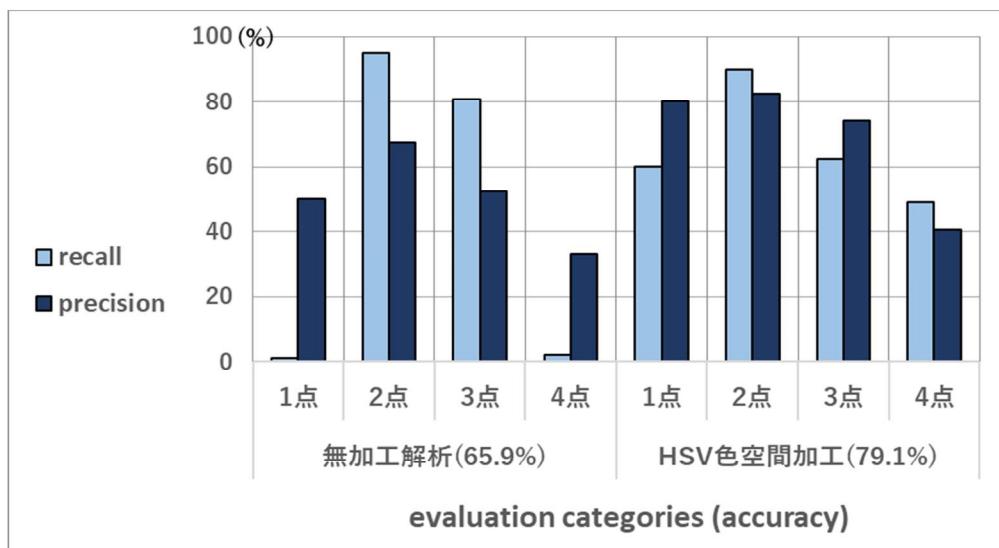


図 9 CNN による岩盤風化に関する判定結果

9. SVM を用いた支保パターン設計

(1) 解析概要

7 章、8 章で CNN は岩盤亀裂及び岩盤風化評価において一定の水準で評価することが出来るという結果を得た。そこで、本解析では先程紹介した CNN 解析方法を用いて切羽画像の評価点を予測し、その結果を入力データ、支保パターンを出力データとして SVM の学習、モデルの構築、検証を行う。この解析で用いる教師データ（5503 個）の採用支保概要を表 5、テストデータ（467 個）の採用支保概要を表 6 に示す。具体的な解析方法として、2 パターンのテスト用データを用いて解析し、比較を行う。1 パターン目は、9 項目 4 段階切羽観察様式全ての評価点を現場技術者が実際に評価した評価点を使用する。それに対して、2 パターン目のテストデータは、9 項目 4 段階切羽観察様式の内、(D) 風化変質、(E) 割れ目の頻度、(F) 割れ目の状態、(G) 割れ目の形態の 4 項目を、技術者の評価点から CNN で評価した評価点に置き換えたデータを使用する。この 2 つのテストデータの結果を比較することで、本研究の CNN 解析方法が現場の評価点設定、及び支保パターン選定に適用可能か判断することが出来ると考えた。尚、教師データは両者共通のデータを使用する。

表 5 SVM による支保パターン判定（教師データ）

支保パターン	合計	CI	CII	DI	DII
データ数	5503	236	3167	1973	127

表 6 SVM による支保パターン判定（テストデータ）

支保パターン	合計	CI	CII	DI	DII
データ数	467	52	183	206	26

(2) 解析結果

表 7-(a) は、1 パターン目のテストデータを用いた結果である。表 7-(b) は、2 パターン目のテストデータを用いた結果である。この両者の結果を比較すると、後者のテストデータを用いた解析の正解率が高いという結果となった。また、両混同行列において、誤判定の分布が非常に類似していることを確認した。この結果より、(D) 風化変質、(E) 割れ目の頻度、(F) 割れ目の状態、(G) 割れ目の形態の 4 項目において、CNN を用いて設定した評価点は、実際の支保パターン判定で適用可能であることを確認した。

表 7-(a) パターン 1 の SVM 結果

正解率 69.8%		SVM によって予測された 支保パターン			
		CI	CII	DI	DII
実際の 支保 パターン	CI	0	52	0	0
	CII	0	138	45	0
	DI	0	25	181	0
	DII	0	0	19	7

表 7-(b) パターン 2 の SVM 結果

正解率 72.2%		SVM によって予測された 支保パターン			
		CI	CII	DI	DII
実際の 支保 パターン	CI	0	51	1	0
	CII	0	157	26	0
	DI	0	32	174	0
	DII	0	0	20	6

10. おわりに

地山等級判定における切羽の観察から割れ目、風化変質に関する評価点の判定までの過程に深層学習の一種である CNN を導入し、トンネル切羽面の岩盤評価に対する適用可能性について検討した。また、本研究で提案した CNN 解析方法で決定した評価点を基に、SVM を用いて支保パターン判定を行った。今回得られた成果は効率よく適正な施工に役に立つと期待する。