

Convolutional Neural Networkを用いた トンネル切羽面の岩盤亀裂評価への適用性 に関する研究

榎並 大希^{1*}・尹 禮分²・西尾 彰宣³・楠見 晴重²

¹関西大学大学院 理工学研究科環境都市工学専攻 (〒564-8680 大阪府吹田市山手町3-3-35)

²関西大学教授 (〒564-8680 大阪府吹田市山手町3-3-35)

³近畿建設協会 (〒540-6591 大阪府大阪市中央区大手前1-7-31 OMM)

*E-mail: taiki.9513@outlook.jp

NATM工法を対象とする山岳トンネルにおいて、切羽の岩判定は、トンネルの支保構造を決定する重要な項目の1つであるが、これを熟練技術者の目視に依存しているのが現状である。しかし、近年熟練技術者は不足しており、将来トンネル施工に支障をきたすことが懸念されている。このような問題を解決するため、本研究では、9項目4段階の切羽観察様式の割れ目に関する評価において、深層学習の1種であるConvolutional Neural Network (CNN) を使用し、切羽面の岩盤亀裂に対する定量的評価およびその適用性について検討した。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討した。

Key Words : New Austrian Tunneling Method, Rock mass rating, Convolutional Neural Network, Gradient-weighted Class Activation Map

1. はじめに

NATM工法における山岳トンネル施工時には、地山等級の判定が行われ、安全性や経済性を確保した合理的な施工ができるよう、設計時に設定された支保構造（支保パターン）を必要に応じて変更しなければならない。地山等級の判定は、トンネル先端部の断面（切羽）における岩の硬さや亀裂、湧水の有無等を観察し、その結果を現場の熟練技術者によって点数付けされ、地山を評価する。しかし、建設業では、近年、熟練者の定年や若者の不確保による人員不足が懸念され、また、施工現場は常に危険を伴う環境下にある。このような諸問題の解決策の1つとして、情報化施工が注目され、実際のトンネル建設現場でも、ICT（Information and Communication Technology）やAI（Artificial Intelligence）を現場の技術者によって行われていた作業に導入している。例えば、3Dレーザースキャナと画像処理技術を組み合わせてトンネル壁面の切羽の任意点の動きを追跡することにより、トンネルの変位を面的にかつ3次元で測定できる計測システムが開発されている²⁾。また、背景差分法と呼ばれる画像認識技術を駆使して、切羽の画像から崩落の予兆

を瞬時に検知するシステムも開発されている³⁾。

そこで、本研究の目的は、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割れ目に関する評価点の判定までの過程に深層学習を導入し、定量的な岩盤亀裂評価点システムを構築することである。具体的には、深層学習の1手法であるConvolutional Neural Network (CNN) を用いて、9項目4段階の切羽観察様式の割れ目に関する評価項目を活用し、トンネル切羽面の岩盤亀裂評価に対する適用性について検討する。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。

2. 切羽評価表

切羽面の観察結果を示す評価項目は、表-1に示す (A) 切羽の状態、(B) 素掘面の状態、(C) 圧縮強度、(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、(H) 湧水、(I) 水による劣化の9項目であり、それを切羽面を3つに分けた部分（左肩、

表-1 9項目4段階の切羽評価表⁴⁾

(A) 切羽の状態	1. 安定	2. 鏡面から岩塊が抜け落ちる	3. 鏡面の押し出しを生じる	4. 鏡面は自立せず崩れ、あるいは流出
(B) 素掘面の状態	1. 自立(普請不要)	2. 時間がたつと緩み肌落ちする(後普請)	3. 自立困難掘削後早期に支保する(先普請)	4. 掘削に先行して山を受けておく必要がある
(C) 圧縮強度	1. $\sigma_c \geq 100\text{MPa}$	2. $100\text{MPa} > \sigma_c \geq 20\text{MPa}$ ハンマー打撃で碎ける	3. $20\text{MPa} > \sigma_c \geq 5\text{MPa}$ 軽い打撃で碎ける	4. $5\text{MPa} > \sigma_c$ ハンマー刃先食い込む
(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、破砕、当初より未固結
(E) 割れ目の頻度	1. 間隔 $d \geq 1\text{m}$ 割れ目なし	2. $1\text{m} > d \geq 20\text{cm}$	3. $20\text{cm} > d \geq 5\text{cm}$	4. $5\text{cm} > d$ 破砕、当初より未固結
(F) 割れ目の状態	1. 密着	2. 部分的に開口	3. 開口	4. 粘土挟む、当初より未固結
(G) 割れ目の形態	1. ランダム方形	2. 柱状	3. 層状、片状、板状	4. 土砂状、細片状、当初より未固結
(H) 湧水	1. なし・滲水程度	2. 滴水程度	3. 集中湧水	4. 全面湧水
(I) 水による劣化	1. なし	2. 緩みを生ず	3. 軟弱化	4. 崩壊、流出

天端、右肩）各々に対し4段階で評価する。本研究では、割れ目に関する項目である（E）割れ目の頻度，（F）割れ目の状態，（G）割れ目の形態の3つを対象とする。

3. CNN・Grad-CAMの概要

(1) CNN

CNN⁵⁹⁾は昨今、画像認識分野で広く活用されている深層学習の1手法で、生物の脳の視覚野における特徴抽出の仕組みをモデル化し、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、「全結合層」からなる識別部に分かれている。入力画像データは画素と呼ばれる色の数値を格子状に並べたデータを保持したラスタ画像形式を取り扱い、ピクセルが保持するデータは、RGB（赤、緑、青）の3つで構成されているものとする。「畳み込み層」では、画像の特徴を検出するために、入力データに対して、重みとなるサイズの小さい格子状の数値データであるフィルタを重ね、重なり合う画素同士の積和を求め、バイアス項を加えて1つの数値に変換する処理が行われる。畳み込み演算で求められた値に活性化関数を適用し、入力の加重和に対して別の数値に変換され、「プーリング層」に入力される。「プーリング層」では計算量を削減するために、画像を各領域に区切り、各領域を代表する値を抽出し、並べて新たに縮小した画像が生成され、「全結合層」に入力される。「全結合層」では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正解値との誤差を損失関数を使って求める。それを逆伝播（出力から入力へ情報がさかのぼる）させ、勾配降下法を使って各層の重みとバイアスを更新して誤差を最小化することで最適なモデルが構築される。




図-1 切羽画像と分割メッシュのマッピング関係

(2) Grad-CAM

CNNは画像認識分野で人間と同程度の高い性能を実現する一方で、ブラックボックスになっている部分が多く、出力結果の解釈が非常に困難である。この問題を解決するための1手法として提案されたのがGrad-CAM⁷⁾であり、これを適用することで、出力結果の判断根拠を可視化することができる。Grad-CAMは、予測値と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した可視化技術で、まず、順伝播で特徴量マップと出力結果を求め、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。そして、その勾配の平均値を求めて、重みとした各マップの加重平均を計算し、活性化関数ReLUによる出力をヒートマップ化して元画像サイズにリサイズする。

4. CNNによる岩盤亀裂評価

本研究では、切羽画像を入力、9項目4段階の切羽観察様式の評価項目（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し、CNNの学習、モデルの構築、検証し、岩盤亀裂に対する評価を行う。また、CNNの可視化技術であるGrad-CAMは、評価項目（G）のみ適用し、岩盤亀裂の認識性を評価する。岩盤亀裂評価の過程は以下に示す。尚、CNNを実装するにあたって、プログラミング言語Pythonを使用し、Google Colaboratoryで環境構築を行う。画像処理にはOpenCV、CNNモデルの構築は深層学習ライブラリであるKerasを使用する。

(1) 画像データの処理

切羽画像は図-1に示すように、支保が映り込まない範囲でトリミングを行い、割れ目の評価において1m以上の区分を配慮し、400pixel*400pixelの単位で左肩、右肩部を10分割、天端部を14分割し、鏡吹付や鏡ボルトが映っている画像を除いたものを入力データとして扱う。分割された画像データの評価点は、実際に点数付けされた評価点と同じ点数で設定する。

表-2 CNNモデルの構成

Layer	Filter_size	Filters	Strides	Output_size
Conv_1	(3, 3)	16	(1, 1)	(None, 400, 400, 16)
Max_pool_1	(2, 2)	-	(2, 2)	(None, 200, 200, 16)
Conv_2	(3, 3)	32	(1, 1)	(None, 200, 200, 32)
Max_pool_2	(2, 2)	-	(2, 2)	(None, 100, 100, 32)
Conv_3	(3, 3)	64	(1, 1)	(None, 100, 100, 64)
Conv_4	(3, 3)	64	(1, 1)	(None, 100, 100, 64)
Max_pool_4	(2, 2)	-	(2, 2)	(None, 50, 50, 64)
Conv_5	(3, 3)	128	(1, 1)	(None, 50, 50, 128)
Conv_6	(3, 3)	128	(1, 1)	(None, 50, 50, 128)
Max_pool_6	(2, 2)	-	(2, 2)	(None, 25, 25, 128)
FC_7	-	-	-	(None, 128)
FC_8	-	-	-	(None, 32)
FC_9	-	-	-	(None, 4)

表-3 各評価項目における評価点別データ数

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




図-2 k分割交差検証 (k=5)

(2) CNNモデルの構成

CNNモデルの構成は表-2に示す通り、6つの畳み込み層、4つのプーリング層、3つの全結合層と深い層構造で構成されており、プーリング層では、一般的にCNNで適用されるフィルタ内の最大値を取るMax poolingを使用し、活性化関数はCNN部とNN部ではReLU関数、出力層では分類問題の際に適用されるSoftmax関数を使用する。また、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部にいくつか追加する。

(3) CNNモデルの学習・検証

CNNモデルを学習、検証するための分割済み切羽画像データは、表-3に示すように、評価項目 (E) は476枚、(F) は460枚、(G) は307枚使用する。検証方法は、より正当な評価を実施するために、k分割交差検証 (k=5) を適用する。これは、図-2に示すように、全データを5

つのグループに無作為に分け、4つのグループでCNNモデルを学習を行い、残り1つのグループでモデルの検証を実施し、それを5回繰り返す方法であり、それによって作成された5つのモデルで評価を行う。尚、学習する際のepoch数を300回、batchsizeを16と設定する。また、予測値と正解値の誤差を求める損失関数と重みとバイアスを更新する勾配降下法のアルゴリズムは、categorical crossentropy, Adagradをそれぞれ使用する。

5. 検証結果

図-3, 4はCNNモデルの各評価項目における全体の学習・検証精度の推移、図-5は各評価項目における各評価点の予測値と正解値の一致率、図-6は評価項目 (G) の評価点3におけるGrad-CAMの結果の一部を示している。5つのモデルを平均した全体の検証精度は、評価項目 (E) が75.9%, (F) が69.1%, (G) が87.9%の精度が得られている。モデルによっては評価項目 (E) では80%, (G) では90%以上の高い精度が得られ、この判別精度から、CNNは評価項目 (E), (G) に対する評




図-3 各評価項目における学習精度の推移




図-4 各評価項目における検証精度の推移

価が可能であると言える。一方で、評価項目 (F) では全てのモデルにおいて低い精度を示している。この原因として、図-3の学習精度の推移で、評価項目 (E)、(G) ではepoch数が300回に近づくにつれ、100%付近まで推移しているが、(F) は80%でとどまっており、十分に評価できていないことが明らかである。評価項目 (F) は実際に技術者が点数付けする際もばらつきが生じやすい項目であるため、評価にばらつきのない画像だけを選定して再度検証する必要がある。また、図-5の結果から評価項目 (F) の評価点3と (G) の評価点2の部分の精度が他の点数に比べて低いことが分かる。評価項目 (F) に関しては、前述の通りであり、(G) は評価点2のデータが他の項目に比べて極端に少ないことが原因と考えられる。また、図-6より、Grad-CAMによって範囲的ではあるが、CNNが岩盤亀裂を判断根拠として認識できていることが分かる。このことから評価項目 (G) において、CNNは岩盤亀裂を判断根拠として評価できていると言える。ただし、着目している部分が大域的であり、画像によっては岩盤亀裂とは全く違う部分を判断根拠として評価しているので、今後は画像の岩盤亀裂部をより強調する前処理を行う必要があると考える。




図-5 各評価項目における各評価点の精度




図-6 Grad-CAMの結果(評価点3の場合)

6. 結論

本研究では、山岳トンネル施工時に行われる岩判定の一部の作業において、深層学習の1手法であるCNNとその可視化技術であるGrad-CAMを用い、トンネル切羽面の岩盤亀裂評価に対する適用性について検討した。得られた結論を以下に示す。

- 5つのCNNモデルを平均した全体の精度は評価項目 (E) に対しては75.9%、(F) は69.1%、(G) は87.9%のようになった。
- 評価項目 (G) において、一部の画像を除いて、CNNモデルが岩盤亀裂を判断根拠として評価できていることが明らかになった。

以上の結果から、一部の評価項目を除いてCNNはトンネル切羽面の岩盤亀裂評価に適用性が十分にあると考える。今後は、評価項目 (E)、(F) に対するの精度の向上とCNNの判断根拠をより局所的に表現するために、Grad-CAMの拡張技術であるGuided-Grad-CAMの適用、岩盤亀裂を強調するための画像の形式変更処理を実施する予定である。

参考文献

- 1) 近畿地方整備局：トンネル地山等級判定マニュアル（試行案），2016。
- 2) 鹿島建設：3Dレーザースキャナ変位計測システム「3Dマッチ」を開発，2013。
<https://www.kajima.co.jp/news/press/201310/31c1-j.htm>
- 3) 大林組：切羽崩落検知システム「ロックフォールファインダー」を開発，2018。
https://www.obayashi.co.jp/news/detail/news20180219_01.html
- 4) 日本道路協会：道路トンネル観察・計測指針，2009。
- 5) Francois Chollet：Python と Keras によるディープラーニング，マイナビ出版，2018。
- 6) 鈴木達也，西尾真由子：橋梁定期点検における部材損傷判定への深層学習の適用に関する検討，土木学会論文集，No.1/F-3，pp.48-59，2019。
- 7) Ramprasaath, R., Selvaraju and Michael Cogswell：Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization, 2017

EVALUATION OF ROCK FRACTURES WITH TUNNEL FACE USING CONVOLUTIONAL NEURAL NETWORK

Taiki ENAMI, Yeboon YUN, Akinobu NISHIO and Harushige KUSUMI

In mountain tunnels for NATM, the rock mass rating with tunnel face is one of the most important tasks to determine the support design pattern and it is currently depended on the visual observation of experienced experts. However, the number of experts is decreasing in recent years and it is feared that it will affect tunnel construction in the future. To solve this problem, we tried to evaluate quantitatively rock fractures on tunnel face using CNN, a deep learning, with the evaluation of the 9 categories and 4 levels of tunnel face observation style for rock fractures. In addition, we applied Grad-CAM, a visualization technique for CNN, to investigate whether CNN can actually evaluate rock fractures as a basis for decision making.