

# 深層学習によるトンネル切羽評価 Tunnel Face Evaluation by Deep Learning

畑 浩二 Koji Hata  
中岡 健一 Kenichi Nakaoka

## 1. はじめに

日本列島は急峻な地形形状とともに非常に複雑な地質構造を成している。そのため、山岳トンネル工事では、断層破砕帯や突発湧水などの極めて施工が難しい事態に遭遇することが少なくない。工事を安全安心に推進するとともに、工期・工費を可能な限り縮小させるためには切羽(掘削最先端)を良く観察し、地質の特徴を読み解くことが求められる。しかし、多くの現場では地質学的知識を有した専門家が常駐しているわけではなく、また必ずしも数多くの観察を経験した技術者が従事しているわけではない。そのため、出現する地質を適切に判断できるとは限らない。

切羽評価 AI は、現場技術者が地質を適切に判断できるように支援する技術である。本技術には、人工知能(以下、AI)の一つである深層学習(以下、ディープラーニング)を利用している。過去の大林組施工トンネル記録における切羽画像と地山評価を分析・分類し、画像から地質の特徴を提示することで現場判断の一助にしようとするのを目的に開発した。使用できる機器や場所を固定制限することなく活用してもらえを念頭にクラウド化し、大林組全店トンネル現場に展開している。

## 2. 山岳トンネル切羽評価

山岳トンネルでは、計画段階に地表踏査や物理探査により地質構造を評価し、施工法や支保構造の当初設計を行う。しかし、この段階で地下深部の地質構造を正確に評価することは技術的に困難で、施工中に得られる情報を元に修正設計を行うのが基本である。その際、最も重要なことは、地山の素顔が出現している切羽(Photo 1)をよく観察し、特徴や性状を適切に評価することである。具体的には、地質学的特徴として岩種や生成年代を、物理・力学的特徴として岩質の硬軟、脆さ程度、割目の頻度や卓越方向などが重要な情報として扱われる。

地山の特徴は、以下の7項目で表すことができる。通常、各項目をそれぞれ4~6の細分化した特徴に分類し、定量的に判別することで支保工の修正や対策工選定に利用されている。

- ①圧縮強度
- ②風化変質
- ③割目間隔
- ④割目状態
- ⑤走向傾斜
- ⑥湧水量
- ⑦湧水による劣化度合

## 3. ディープラーニングの利用

人間が自然に行っている学習能力と同等あるいはそれ以上の機能をコンピュータで実現しようとする技術や方法が機械学習(マシンラーニング)である。これを実現するため多くの方法が考えられているが、その一つがディープラーニングである。さらに、ディープラーニングを実行するアルゴリズムもしくは数値モデルには、人間の複雑な脳構造を模したニューラルネットワーク(以下、NN)がある。

NN(Fig. 1)は、特徴抽出フェーズと分類フェーズからなる。前者の特徴抽出フェーズでは、入力画像に対して色調(RGB)変化を元にした画像の局所的な特徴を捉える畳込み層と、得られた局所特徴量を元に平均値や最大値を取って画像のサイズ圧縮を行うプーリング層からなる。次いで、分類フェーズでは、特徴抽出フェーズで出力された結果の数(ニューロン)だけデータが与えられ、これらを重ね合わせることで多量のデータから特徴や類似性を学習し、新たなデータを分類・判定する。近年ではこの層構造をより多数にした複雑系となる傾向にある。そのため、画像処理に特化した処理装置(GPU)が不可欠とも言われている。なお、狭義では4層以上を構成するNNをディープニューラルネットワーク(以下、DNN)と称する。



Photo 1 切羽観察状況  
Observation of Tunnel Face




Fig. 1 ニューラルネットワーク(NN)の構造  
Construction of Neural Network

#### 4. 「切羽評価 AI」の概要

##### 4.1 使用する DNN

トロント大学で開発された AlexNet<sup>2)</sup>を使用した。このアルゴリズムは、2012 年の ILSVRC(International Large Scale Visual Recognition Challenge)で、識別エラー率で二位チームを大きく引き離し優勝したことから、その後世にディープラーニングブームを起こした先駆的な存在である。特徴抽出フェーズ 5 層および分類フェーズ 3 層から構成されており、層構造が少なく GPU を備えていないコンピュータでも負荷なく使用できる。また、ImageNet と称する画像データベースにより既にディープラーニング用として教育されている特長を有する。

##### 4.2 学習データの作成

過去多くのトンネルを施工した大林組データに基づき、学習データを作成した。作成に際して、鮮明な切羽画像が必要であることから、6 現場 70 切羽を選択した。AlexNet では 227×227 に分割した画像を利用することから、70 切羽画像のうち約 2000 枚を学習データに、約 1000 枚を検証データに使用した。なお、大林組の岩盤力学と地質の専門家により基本データを見直し、切羽画像と 2 章で示した 7 つの地山特徴とを結びつけた。

##### 4.3 切羽評価 AI の特長

切羽評価 AI の特長を以下に示す。

- (1) クラウド化 使用できる機器や場所を固定制限しないことを目的にクラウド化した(Fig. 2)。運用端末は、タブレット端末もしくはパソコンである。切羽を撮影しクラウドに送信後、地山の特徴が項目ごとに運用端末に返信される。Photo 2 は、国土交通省近畿地方整備局発注冠山峠道路第 2 号トンネル工事での試行状況である。
- (2) 評価の細分化 従来、切羽を上、左右に 3 分割し地山の特徴を判定していたが、ここでは約 70 分割に細分化した領域で評価する(Fig. 3)。そのため、局所的に不安定なヶ所を把握することが可能となる。
- (3) 高い的中率 地山の特徴 7 項目について、Table1 のように 73%以上の的中率を達成した。

#### 5. まとめ

切羽評価 AI システムの開発概要や特長、および実施状況を示した。進歩の早い AI 分野では古典的と思われる AlexNet を利用しているが、過去のデータを詳細に見直し質の高い学習データを提供することで、的中率は 73% 以上を得た。現状では現場技術者の判断を不要にする域には至っていないが、判断支援には十分実用に耐え得ると考えられる。また、経験の浅い現場技術者が日々研鑽し、地質の特徴を読み解く技量を向上させるための教育ツールとしても有効である。

我が国では多種多様な岩種が分布していることから、




Fig. 2 クラウドシステム  
Cloud System



Photo 2 実施状況  
Application Status

- [凡例]
- 1:概ね新鮮
  - 2:割目沿いの風化変質
  - 3:岩芯までの風化変質
  - 4:土砂状風化、未固結土砂



Fig. 3 風化変質のヒートマップ  
Heat Map of Weathered Alteration

Table 1 的中率  
Predictive Value

地山の特徴項目	項目分類数	的中率 (%)
圧縮強度	6	96
風化変質	4	73
割目間隔	5	73
割目状態	5	83
走向傾斜	5	81
湧水量	4	88
湧水による劣化度合	4	97

学習の質を向上させ、的中率の向上を図っていきたい。

#### 参考文献

- 1) 畑 浩二, 中岡健一: 山岳トンネル切羽評価への人工知能適用に関する研究, 第27回トンネル工学研究発表会 トンネル工学報告集, 第26巻, I-9, pp. 1-6, 2017.11
- 2) Alex Krizhevsky, Ilya Sutskever and Geoffrey E. Hinton: ImageNet Classification with Deep Convolutional Neural Networks, Conference and Workshop on Neural Information Processing Systems (NIPS)2012