

山岳トンネル切羽評価への人工知能 適用に関する研究

畑 浩二¹・中岡 健一²

¹正会員 大林組 技術研究所 地盤技術研究部 (〒204-8558 東京都清瀬市下清戸4-640)

E-mail:hata.koji.ro@obayashi.co.jp

²正会員 大林組 技術研究所 地盤技術研究部 (〒204-8558 東京都清瀬市下清戸4-640)

E-mail:nakaoka.kenichi@obayashi.co.jp

山岳トンネルでは、設計段階での事前調査技術の限界や地質の複雑性から、施工時の切羽状況を基に、実質の地質特性に合致するような支保規模に修正している。したがって、地質の成因に基づく力学的・水理学的特性を可能な限り正確に読み取ることが必要である。

本研究では、切羽評価の合理化を目指し、近年注目を集めているAI技術の適用性を試行した。深層学習の一つであるディープニューラルネットワークを適用し、切羽画像を用いて風化変質や割目の頻度や状態を判断させると、技術者が判定した結果に対し69～89%の的中率で整合する結果を得た。したがって、AIを利用した切羽評価法の実用化のめどが立った。

Key Words : Tunnel, Artificial Intelligence, Deep Learning, Deep Neural Network, Diagnostic Image

1. はじめに

1997年、IBMが開発したDeep Blueがチェスの世界チャンピオンを破って以来、人工知能（以下、AI）が注目を集めることになった。決定的な事件は、2011年Deep Blueと同様にIBMが開発したWatsonが米国のクイズ番組「Jeopardy!」で最多連勝記録保持者と累積最高賞金記録保持者の2人のチャンピオンに勝利したことである。Watsonは質問応答システム・意思決定支援システムと称され、Cognitive Computing Systemと定義されている。その後、将棋や囲碁にまでAIの旋風が吹いている。一方、産業界に目を向ける車の自動運転、医療・介護用ロボットなど枚挙にいとまがない。

1980年代から1990年前半をAI第2次世代と言われる。その間、建設業界でも基礎から実用化まで、さまざまな研究開発が行われた。著者らも、山岳トンネルの支保選定支援にAI的技術を試行し、エキスパートシステムを構築した経緯がある。このシステムでは、観察的方法として切羽の画像処理とニューラルネットワークによるパターン分類を、観測的方法としてワイブル分布曲線による内空の最終変形量予測と非弾性領域の広がり予測を、解析的方法として2次元弾塑性解析を現場PCで実行できるようにした。また、3つの方法が連携するよ

うに、切羽評価点としてRMR値を並行して算定し、それに整合する岩盤物性を2次元弾塑性解析に自動入力するとともに、標準支保工耐力は支保内圧として作用できるようにテーブル形式で与える工夫を施した。当時、数値解析は現場とは遠く離れた本社部署や研究所での作業が普通であったが、このような工夫により現場でパラスタ解析を可能にした。ただし、当時のPCの能力ではAIの本来あるべき姿を具現化できていない。例えば、ニューラルネットワークの本来あるべき姿は、人工ニューロンを多数組み合わせる複雑系の関数をより良く近似させることにあるが、当時は正解が確定したパターン分類として利用した。近年のAIに関する取り組みは第3世代に属し、コンピュータの高速化やアルゴリズムの革新性なども相まって再びブームになっている。

本報告では、AIの深層学習技術を山岳トンネルの切羽観察評価に利用する取り組みを示し、その適用性や課題について述べる。

2. 深層学習（ディープラーニング）の利用

人間は、過去から現在に至る中で獲得した知識と経験を基に事象の判定や推論を行っている。このように人間

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。一方、深層学習（ディープラーニング）とは機械学習を実現するための一つの手法であり、アルゴリズムに相当する。昨今、耳にすることが多くなったニューラルネットワークは、その一つの手法である。近年では畳込みニューラルネットワークもしくはディープニューラルネットワーク（以下、DNN）と称され、その基本的な構造は図-1 のように表される。

画像分析の視点からニューラルネットワークを説明すると以下のようになる。まず、入力画像に対し、特徴抽出フェーズと分類フェーズを通過することで結果の出力を行う。特徴抽出フェーズは、鮮鋭化フィルターやノイズ処理フィルター等を介して 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（convolution layer）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（画像を数ピクセル領域に低減）を行うプーリング層（pooling layer）からなる。つまり、畳込み層では、あるピクセル領域内の特定ピクセルにしかなかった確定情報が、特徴を表す分析情報に変換されることになる。その結果、例えば入力画像が少し平行移動

した場合でも特徴を表す同種の画像であると認識され、いわゆるロバスト性が高い学習データを得ることが可能になる。次いで、分類フェーズでは、全結合層（full connected layer）により前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認識精度を高める働きをしている。初期のニューラルネットワークでは、この畳込み層とプーリング層が1層もしくは少なかったが、近年ではより多くの層からなり、より複雑な情報処理を行っている。

3. トンネル切羽評価へのDNN適用性検討

トンネル施工において、切羽の地山性状を観察し、例えば、図-2 に示すような切羽観察記録表を作成して地山




図-1 DNNの基本構造

切 羽 観 察 記 録

トンネル名	〇〇トンネル	位置	起点からの距離 k m 坑口からの距離 k m 支保No.
土 被 り	△△m	総合判断	地山区分あるいは パターン区分の判定
岩 種	G	岩 石 名	砂岩及び頁岩
特殊条件 状 態	膨張性土圧・偏圧・流動性・土被り小 () m・重要構造物接近・谷の直 その他特殊な条件:		
補助工法	長尺先受け (本)・短尺先受け (本)・鏡ボルト (本)・地盤改良		
地質構造	1. 互 層 2. 不整合 3. 岩脈貫入 4. 褶 曲 5. 断 層 6. その他		
掘削地点の地山の状態と挙動			
A	切羽の状態	安定	2. 鏡面から岩塊が抜け落ちる
B	素掘面の状態	自立	3. 自立困難 掘削後早期に支持する
C	圧縮強度	1. $\sigma_c \geq 100\text{MPa}$ ハンマー打撃ではね返る	2. $100 > \sigma_c \geq 20$ ハンマーの軽い打撃で砕ける
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
E	破碎部の切羽に占める割合	1. 5% > 破碎	2. 20% > 破碎 $\geq 5\%$
F	割れ目の頻度	1. 間隔 $d \geq 1\text{m}$	2. $1\text{m} > d \geq 20\text{cm}$
G	割れ目状態	1. 密着	2. 部分的に開口
H	割れ目形態	1. ランダム形状	2. 柱状
I	湧 水 目視での量	1. なし、滲水程度	2. 集中湧水
J	水による劣化	1. なし	2. 緩みを生ず

合 計 24

割れ目の方向性	縦断方向 (切羽鏡面)	1. 水平 ($10^\circ > \theta > 0^\circ$) 2. さし目 ($30^\circ > \theta \geq 10^\circ$, $80^\circ > \theta \geq 60^\circ$) 3. さし目 ($60^\circ > \theta \geq 30^\circ$) 4. 流れ目 ($60^\circ > \theta \geq 30^\circ$) 5. 流れ目 ($30^\circ > \theta \geq 10^\circ$, $80^\circ > \theta \geq 60^\circ$) 6. 垂直 ($\theta \geq 80^\circ$) [最大傾斜角]
	横断方向 (切羽鏡面)	1. 水平 ($10^\circ > \theta > 0^\circ$) 2. 右から左へ ($30^\circ > \theta \geq 10^\circ$, $80^\circ > \theta \geq 60^\circ$) 3. 右から左へ ($60^\circ > \theta \geq 30^\circ$) 4. 左から右へ ($60^\circ > \theta \geq 30^\circ$) 5. 左から右へ ($30^\circ > \theta \geq 10^\circ$, $80^\circ > \theta \geq 60^\circ$) 6. 垂直 ($\theta \geq 80^\circ$) [目掛けの傾斜角]

未固結地山の場合は、下記項目の追記を要す			
地山の状態	地層の状態	1. 単一土層 2. 互層 (1. 水平 2. 傾斜) 3. レンズのはさまみ層 (1. なし 2. あり) 4. その他 ()	
	特殊な状態	1. 崖錐層 2. 段丘堆積物 3. 火山砕屑岩 4. 泥流層 5. 岩盤との境界 6. 断面外の上部に軟弱層あり 7. 埋土・盛土 8. その他 ()	
土質	不連続面	1. 割れ目発達 2. シーム 3. 断層 4. 不整合 5. その他 ()	
	土質	1. 粘性土 2. 砂質 3. 礫質土 4. 特殊土 (1. まさ土 2. 火山灰土 3. しらす 4. 有機質土) 5. その他 ()	
状態標準	粘性土	1. 軟らかい ($4 > N$) 2. 中位 ($8 > N \geq 4$) 3. 硬い ($15 > N \geq 8$) 4. 非常に硬い ($30 > N \geq 15$) 5. 固結 ($N \geq 30$)	
	砂質土・礫質土	1. 緩い ($10 > N$) 2. 中位 ($30 > N \geq 10$) 3. 密な ($50 > N \geq 30$) 4. 非常に密な ($N \geq 50$)	
特殊な状態	礫質土・砂質土	1. ルーズ	2. 締っている
	礫径	1. 2~5cm 2. 5~20cm 3. 20~75cm 4. 75~300cm 5. 300cm以上	礫分の比
地山の特性	N値	透水性	1. 透水性 2. 不透水性 3. 両者の両方 4. その他 ()
地下水頭 (掘削時)	FLより土	m上	備考
【切羽画像・スケッチ】			
天端部に岩塊抜け落			
岩塊抜け落			
【記 事】			

記載者氏名 〇〇〇〇

図-2 切羽観察記録の一例

の特徴を把握するとともに、その特徴に適した支保規模を選定し、必要に応じて修正を図ることが重要になる。そのためには、担当技術者は地質性状を正確に読み解く技量や目を持つことが求められる。通常、土木技術者がその役割を担当するが、地質学的な専門教育を受けていることは少なく、地山を正しく評価できていないこともある。そこで、著者らは、地質技術者が注目する地山特徴とその評価プロセスをデータベース化し、切羽写真をPCに入力するだけで特徴抽出から分析が即座に行えるようなシステム開発を目指し、まずはDNNによる試行を実施した。

図-2に示すように掘削地点の地山の状態と性状は、総じて①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劣化度合の7項目で表すことができる。そこで、本試行では、切羽画像からその特徴を得やすいと考えられる②風化変質、③割目間隔および④割目状態に着目した。

(1) 試行DNNモデル

本試行では、トロント大学で開発された多層型のDNNを使用した。開発者の名前を冠してAlexNet^{2,3}と称される。本モデルは、2012年のILSVRC (International Large Scale Visual Recognition Challenge) というコンペティションにおいて、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、その後の深層学習が脚光を浴びるきっかけを作ったDNNである。図-3に特徴抽出フェーズおよび分類フェーズの層構造を示す。図中、Convは畳込み層を、Poolはプーリング層を示す。分類フェーズにおけるfcは全結合層を示す。ここでは、4096ニューロンが2層と1000ニューロン1層で構成されている。AlexNetには、以下に示す他のモデルに無い特徴があることから、本試行研究で採用した。

- ・特徴抽出フェーズ5層および分類フェーズ3層から構成されるため、GPUを使用しなくても演算時間が少なく済む。
- ・画像から物体そのものを認識するための特徴量のみならず、他の物体と弁別する特徴量を抽出できる。
- ・画像データベースImageNetを用いて、学習用120

万画像、テスト用15万画像および検証用5万画像を元に構築されたモデルである。

(2) AlexNetにおける学習用データ

当社が過去施工したトンネルの内6件を選定し、AlexNetの学習データとして利用可能な70ヶ所の切羽観察記録を試行モデルとした。これらのデータは、学習用：テスト用に7：3の比率で無作為抽出し使用した。岩種は、砂岩、粘板岩、泥岩、頁岩、花崗岩、流紋岩、凝灰岩、凝灰角礫岩と多種にわたり、地山等級はDIII～CIまでを網羅している。また、上記②～④の評価項目で選定された評価区分は現場で記載した情報をそのまま「正」として取り扱った。なお、学習用データを生成するためには、図-4に示すように、前処理として画像サイズの統一、切羽部分のみの切出し、および画像の天端・左右肩部の3つの領域(図-5参照)に分割した。さらに、AlexNetの使用条件から227×227×3(ピクセル、RGB)に画像分割(図-6参照)した。

なお、今回の試行で使用したデータ数はAlexNetが有する学習用データに比べ格段に少ない。したがって、特徴抽出にデータを追加しても精度向上には繋がらない可能性が高い。むしろ、過学習を引き起こし、以降の分類




図-4 前処理から学習用データの生成に至る流れ




図-3 AlexNetの層構造

フェーズにおける境界設定で悪影響を及ぼす可能性が危惧されたことから、特徴抽出フェーズには切羽画像情報を追加させない転移学習とし、分類フェーズのみに考慮した。

(3) 作業手順と用いた手法

前処理を施した分割画像データを元に、AlexNet による深層学習を施し、②～④の評価項目で選定された評価区分フォルダーにそれぞれの画像による評価区分データを格納する。これによって画像の特徴と評価区分が関連づけられる。なお、AlexNet には全フェーズを通して処理する機能があるが、画像特徴と評価区分を繋ぎ合わせる分類計算には、サポートベクタマシン（以下 SVM）を利用した。分類器には、決定木やロジスティック回帰など種々存在するが、SVM は解析精度や識別境界の算定で他の方法に比べて優位性があることから利用した。




図-5 切羽の3領域分割



図-6 切羽画像の227×227分割

4. 試行結果

入力画像（図-7 参照）に対し、図-3の特徴フェーズにおける畳込み層での処理画像（分割画像の合成）を図-8に示す。この種の深層学習では処理が進めば進むほど画像の抽象化が進み、判別が困難な画像が出力されることになる。今回の試行でも、Conv 1を除いて同様な画像の抽象化が進んでいる。第一処理の Conv 1 で他の処理より画像が不鮮明になっている理由は不明である。

このように特徴抽出が進んでいないような一見矛盾し



図-7 入力切羽画像例




図-8 各畳込み層における出力画像例

た結果を出力するのが深層学習の特徴で、仮に人間が判別できるような結果を出力するのであれば、わざわざDNNを利用しないで、計算量も少ない他の画像処理と機械学習を組み合わせる方が効果的と言える。

次いで、分類フェーズで設定した画像の特徴と評価区分の関連づけを検証する。テスト用データとして図-6のように分割した画像総数は1,035である。これら全てにおいて、②風化変質における実質評価と予測評価を対比した結果を表-1に示す。表中、縦欄に切羽観察記録に記載された評価区分を、横欄に予測した評価区分を示し、該当する画像数の累積数を示した。すなわち、この表内で赤網掛の対角部分が実質と予測が合致した「正」と見なされ、それ以外は「誤」となる。例えば、概ね新鮮と区分されたカテゴリでは、総数110画像（74+35+1+0）

に対して正解は74となり、的中率は67%となる。全体平均で見ると、的中率は87%となった。個別に見ると、「土砂状風化、未固結土砂」を示すカテゴリを除いて、的中率は「誤」の2倍以上もあることから良い結果を得たと考える。「土砂状風化、未固結土砂」のカテゴリの的中率が低いのは、全体総数が17画像と少なく、そのため分類フェーズで適切に弁別ができるほどの情報が不足したものと考えられる。

③割目間隔における実質評価と予測評価を対比した結果を表-2に示す。この場合、全体平均で見ると、的中率は69%となった。「 $1\text{m} > d \geq 50\text{cm}$ 」と「 $50\text{cm} > d \geq 20\text{cm}$ 」の間で分類判別に混乱が生じていることが的中率を低下させた原因と考えられる。一方、画像からは2つのカテゴリ弁別は本来無理があるのかも知れない。

表-1 風化変質における実質評価と予測評価のまとめ

	評価区分	予測した評価			
		概ね新鮮	割目沿いの風化変質	岩芯まで風化変質	土砂状風化未固結土砂
実質評価	概ね新鮮	74	35	1	0
	割目沿いの風化変質	41	742	17	2
	岩芯まで風化変質	1	22	80	3
	土砂状風化、未固結土砂	0	9	2	6

表-2 割目間隔における実質評価と予測評価のまとめ

	評価区分	予測した評価				
		$d \geq 1\text{m}$	$1\text{m} > d \geq 50\text{cm}$	$50\text{cm} > d \geq 20\text{cm}$	$20\text{cm} > d \geq 5\text{cm}$	$5\text{cm} > d$
実質評価	$d \geq 1\text{m}$	2	1	3	0	0
	$1\text{m} > d \geq 50\text{cm}$	0	176	126	2	3
	$50\text{cm} > d \geq 20\text{cm}$	1	129	448	3	2
	$20\text{cm} > d \geq 5\text{cm}$	0	0	4	57	24
	$5\text{cm} > d$	0	1	3	22	28

表-3 割目状態における実質評価と予測評価のまとめ

	評価区分	予測した評価				
		割目は密着	割目の一部が開口 幅 $\leq 1\text{mm}$	割目の多くが開口 幅 $\leq 1\text{mm}$	割目が開口 1mm<幅 $< 5\text{mm}$	割目が開口 幅 $\geq 5\text{mm}$
実質評価	割目は密着	34	42	0	0	0
	割目の一部が開口 幅 $\leq 1\text{mm}$	21	770	9	2	0
	割目の多くが開口 幅 $\leq 1\text{mm}$	0	7	64	4	6
	割目が開口 1mm<幅 $< 5\text{mm}$	0	9	3	41	4
	割目が開口 幅 $\geq 5\text{mm}$	0	5	0	3	11

いずれにしろ、的中率の向上を図ることが必要である。

④割目状態における実質評価と予測評価を対比した結果を表-3に示す。この場合、全体平均で見ると、的中率は89%となり、3つの評価分類の中では一番高い的中率を得た。しかし「割目は密着」のカテゴリーで的中率が劣ることから、この部分の予測性を高めることで的中率の向上が可能である。

5. おわりに

今回、トンネルの切羽評価に対してAI的方法の適用性を試行した。試行段階ではあるが、切羽画像を入力しただけで風化変質、割目間隔および割目状態がそれぞれ87%、69%、89%的中率で予測することができた。特徴抽出フェーズでは転移学習を採用したにもかかわらず、比較的高い的中率が得られた。今回選択した切羽観察記録では、評価の高いおよび低いカテゴリーでデータが少なかったため分類フェーズでの評価精度が低かったものと推察される。今後、このカテゴリーの地山評価情報を追加することで、的中率の向上が期待できる。

また、今回の試行では、実質評価は図-5に示すように天端・左右肩部の3つの領域で、それぞれ代表値で表されている。予測評価は、 227×227 ピクセルの領域ごとに評価点が出力される。前者は全体的な平均的評価であり、後者は局所的な評価である。両者の間で評価領域が異なることになることから、両者を正確に比較するため

には、切羽の実質評価領域をAlexNetでの分割領域に合致させるか、もしくは細分化されて出力された予測評価を3つの領域で何らかの平均化処理をする方法が考えられるが、今後の課題としたい。一方で、このような局所的な地山評価を出力することで、キープロック発現のような局所的現象把握に活用できることを示唆した。

いずれにしても、AI試行は始まったばかりであるが、比較的高い的中率を得たことで、実用化への可能性が見えてきた。今後はサンプルデータ数の追加、観察評点の見直し、学習用データの再生成、他の解析アルゴリズムの適用試行等を積極的に進め、実用化を目指したい。

謝辞：本研究に関し、MathWorks Japanの井原瑞希氏にご協力いただいた。ここに記して感謝の意を表す。

参考文献

- 1) 畑 浩二, 吉岡尚也：トンネル支保工選定支援システムの開発, トンネルと地下, 第27巻, 1号, pp.65~71, 1996.
- 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.
- 3) Wei Yu, Kuiyuan Yang, Yalong Bai, Tianjun Xiao, Hongxun Yao and Yong Rui : Visualizing and Comparing AlexNet and VGG using Deconvolutional Layers, Proceeding of the 33rd International Conference on Machine Learning, 2016..

(2017. 8. 11 受付)

STUDY ON APPLICATION OF ARTIFICIAL INTELLIGENCE TO TUNNEL FACE EVALUATION

Koji HATA, and Kenichi NAKAOKA

In the tunnel, the engineer observes the tunnel face under construction and determine appropriate support members. For that purpose, it is necessary the ability to accurately grasp the geological condition.

In this study, AI technology was examined in order to reasonably evaluate tunnel face. Using by Deep Neural Network(DNN) which is one of deep learning, It was estimated weathering alteration, frequency and condition of fracture from tunnel face images. As a result, it was grasped at a precise score of 69 to 89% when compared with engineering judgement. Therefore, the practical application of the feather evaluation method using the AI was established.