人工知能による切羽評価で抽出される 特徴の可視化とその利用方法

中岡健一1*·畑浩二1

¹株式会社大林組 技術研究所(〒204-8558 東京都清瀬市下清戸4-640) *E-mail: nakaoka.kenichi@obayashi.co.jp

筆者らはトンネルの切羽画像を人工知能によって解析し、切羽評価を行う研究を進めている.人工知能 は処理内容が不明であり、結果についての考察や説明が困難という問題があった.人工知能が切羽評価を 行う時に着目する特徴が分かれば、結果の説明性が高まると考えた.まず、一つの特徴として色に着目し、 画像の色あいが評価精度におよぼす影響を調べた.その結果切羽評価においては、色は重要な特徴とはさ れていないことが分かった.次に、ニューラルネットワークの各層が抽出する特徴を可視化した.その結 果、深い層ほど複雑な模様が抽出されていることが分かった.さらに、各評点に分類される典型的な画像 を作成した.その結果、切羽評価の際に参考になる可能性がある画像が得られた.

Key Words : tunnel, AI, deep newral network, deep learning, DeepDream

1. はじめに

筆者らは切羽画像を人工知能(以後,切羽評価AI)によって解析し,切羽評価を行うための研究¹⁰⁾を行っている. 切羽評価AIにはディープニューラルネットワーク(以後, DNN: Deep Neural Network)を用いており,風化変質,割 目間隔,割目状態の項目において高い的中率を得ている.

DNNに入力された画像は、ネットワークの各層において、学習済みのフィルターによって変換され、特徴量が抽出される。例えば、ネットワークの第一層では、フィルターに入力されるデータは画像データであり、その画像の模様がフィルターに近似的であれば、抽出される特徴量は大きくなる。このフィルターは可視化できるため、この層から抽出される特徴は把握できる。しかし、第二層以降のフィルターは基本的に可視化できない。このことから、一般的にネットワークの層はブラックボックスとして扱われており、AIによって判定された結果について説明することが困難であった。

本研究では、切羽評価AIが評価を行う際に着目する特 徴が分かれば、結果に対する説明性が高まると考え、ま ず分かりやすい特徴として色に着目し、色が予測結果の 的中率におよぼす影響を調べる.

次に、ネットワークの各層で抽出される特徴を把握す るために、第一層についてはフィルターを直接可視化す る、第二層以降については、各層のフィルターからの出 カが大きくなるような入力画像を生成する. この画像は 直接フィルターを可視化したものではないが, そのフィ ルターが抽出する特徴を表す.

最後に、結果を出力する層について同じ方法を用いる ことにより、特定の切羽評価点(例えば評価項目が風化 変質の場合は、評点1が「概ね新鮮」など)に対応する特徴 量のみが大きくなる画像を生成する.生成された画像は 典型的な評点1,評点2の画像を表わしていることになり、 評点付けを行う際の参考になる可能性がある.

2. 切羽評価AIの概要

本研究では、特徴量を抽出するために、2012年の ILSVRC (International Large Scale Visual Recognition Challenge) においてもっとも高い認識率を得たAlexNet³⁴⁴とよばれ るDNNを用いている.近年はさらに高精度のモデルも 提案されているが、これらのモデルはAlexNetと比べて 構成が複雑になる傾向があり、ネットワークを構成する 各層の処理内容の解釈がより困難になる.

AlexNetと切羽評価AIの層構造を図-1に示す.図から, AlexNetは特徴量抽出フェーズとして5層の畳込み層と, 分類フェーズとして3層の全結合層からなる.3層の畳込 み層の後には、プーリング層が設けられている.この層 は、畳み込みの結果の、ある領域内での平均値や最大値



図-1 切羽評価AIの構造

を領域の値とすることで、画像サイズが縮小され、位置 感度を低下させる働きがある.最後の畳込み層 (fc1000) からは1000種類のカテゴリー (例えば、犬、猫) それぞれ に対する特徴量が出力され、その値の最も大きいカテゴ リーが分類結果となる.

色による影響を調べるためのモデルは,図-1の AlexNetの分類フェーズの2層目の結果を分類器 (SVM) に 入力し、切羽評点に対応したそれぞれのカテゴリーに分 類するもので、今までの切羽評価AIもこの方法である.

それぞれの評点に対応した典型的な画像を作成するためのモデルは、分類フェーズの第2層まではAlexNetを用い、そのあと、新たに作成した全結合層を一つ接続する. 本研究では、図-1の分類器とfcNewに学習させた.

ここで、AlexNetの学習データには、切羽そのものは ほとんど含まれないが、1000種のカテゴリーには'stone wall'や'rock crab (岩場に棲む一種のカニ)'、'volcano (火山)' のように、被写体に岩石が写っているものが含まれる. また、学習で用いられた画像は100万枚以上で、画像認 識のために最適化されたフィルターが用いられているた め、切羽においても特徴を適切に抽出できると判断した. このように、既存の学習済みモデルを流用することによ って、少ない追加学習で高い効果を得る方法は転移学習 と呼ばれており一般的に利用されている.

3. 切羽評価AIIにおける色の影響について

(1) 学習用データとテスト用データ

学習用とテスト用データは, 画像の前処理, AlexNet

の入力データサイズ (227×227ピクセル) への分割なども 含めて既存の研究¹と同じとする.ここでは、色による 影響を調べるために、学習用とテスト用のデータを従来 通りカラー画像としたCaselと、画像から色の情報を省 くため、Caselの画像をグレースケール画像に変換した Case2の評価を行い、それらの結果を比較する.

(2) 切羽評価結果

表-1~表-6にそれぞれの地山評価項目における分類結 果を示す.表中の「実際の値」とは、現場の観察者によっ て付された評点を表しており、地質の専門家による見直 しを行い、さらに信頼性を高めることを検討している. 表の数字の意味として、例えば、表-1の実際の値が2で 予測評価値が3のカラムに着目すると、17個の画像が、 正解の評点が2であったにも関わらず、3と分類された、 ということを表している.そのため、対角線上にある数 値が的中した画像の数であり、それ以外のカラムは的中 しなかった画像の数である.

表-1~表-4から風化変質と割目間隔についてはCaselと Case2でほぼ同等の的中率が得られており,画像の色合 いによる影響はほとんどないことが分かった.一方,割 目状態については,特に評価値5の予測精度が大きく低 下している.その理由として,以下の2つが挙げられる.

- ・割目状態の,特に評価値5の予測には色情報が必要 である.
- ・評価値5の画像数が少なく、色合いに偏りがあるため、今回の試行では色合いが重要な情報となったものの、実際には色は重要な特徴とはなっていない.

いずれが正しいのか判断するためには学習データの画 像数を増やし、同様の比較を行う必要がある.

4. 特徴を強調した画像の生成

図-2にAlexNetの層構造を示す.入力画像データのサ イズは227×227×3で、サイズの最後の成分(この場合は 3)はチャネルと呼ばれ、第1層では色(RGB)を表わして いる.DNNの第1層(Convl)では、96種類、サイズ11×11 ×3のフィルターによって畳み込まれる.各フィルター によって畳み込まれた画像は、次の層のチャネルとして 格納される.そのため、出力されるチャネル数はフィル ターの種類と同じ96となる.Conv1の場合、フィルター の3つのチャネルはそれぞれRGBに対応しており、96種 類の11×11ピクセルの画像として可視化できる.

Conv2ではConv1から出力された96チャネルのデータを, サイズ5×5×48, 256種類のフィルターによって畳み込 まれる. 各フィルターによって畳み込まれたデータは, ピクセル (5×5=25個) ごとに全チャネルにわたって加算

予測評価値 評価 区分 1. 概ね新鮮 実 2. 割目沿いの風化変質 際 3. 岩芯まで風化変質 \mathcal{O} 4. 土砂状風化、 値 未固結土砂 風化変質の分類結果:的中率 86.1% (Case2) 表--2 予測評価値 評価 区分 1. 概ね新鮮 実 2. 割目沿いの風化変質 際 3. 岩芯まで風化変質 \mathcal{O} 4. 土砂状風化、 値 未固結土砂 割目間隔の分類結果:的中率 68.7% (Case1) 表--3 評価 予測評価値 区分 実 $1.d \ge 1m$ 0 176 際 2. $1m > d \ge 50cm$ \mathcal{O} 3. 50 cm > d \geq 20 cm 4. $20 \text{cm} > d \ge 5 \text{cm}$ 値 5. 5cm > d 表-4 割目間隔の分類結果:的中率 68.8% (Case2) 予測評価値 評価 区分 実 $1. d \ge 1m$ 際 2. $1m > d \ge 50cm$ \mathcal{O} 3. 50 cm > d \geq 20 cm 4. $20 \text{cm} > d \ge 5 \text{cm}$ 値 5. 5cm > d 割目状態の分類結果:的中率 88.9% (Case1) 表-5 予測評価値 評価 区分 割目は密着 実 2. 割目の一部が 際 開口幅 ≦1mm 3. 多くが幅 ≦1mm \mathcal{O} 4.1 < 開口幅 < 5mm 値 11 5. 開口幅 ≧ 5mm

表-1 風化変質の分類結果:的中率 87.2%(Casel)



評価		予測評価値					
区分		1	2	3	4	5	-
実際の値	1	42	34	0	0	0	 割目は密着 割目の一部が 開口幅 ≦1mm 多くが幅 ≦1mm 4.1<開口幅 < 5mm 開口幅 ≧ 5mm
	2	47	742	6	6	1	
	3	2	8	- 59	3	9	
	4	0	9	1	42	5	
	5	0	3	10	5	1	

される. そのため, Conv2から出力されるデータ(抽出さ れた特徴)は, Conv1のそれぞれのフィルターによって抽 出された特徴を組み合わせたものとなる. Conv3のフィ ルターサイズは3×3×256, Conv4とConv5はそれぞれ3×



図-2 AlexNetの層構造

3×192である. Conv2よりも深い層のフィルターは縦横 のピクセル数が少なく,模様を描くことが出来ない.

(1) Deep Dreamによる特徴の可視化

Deep Dreamは特定のネットワークの層の,特定のチャ ネルを強く活性化する画像を生成する方法である.具体 的には,入力した画像(例えばランダムなノイズ画像)を, 選択したチャネルの値のみ大きくなるように,徐々に変 化させていく方法である.DNNにこの方法を用いると, 特定のフィルターが大きな特徴量を出力する入力画像が 生成される.ここで,一つのフィルターからの出力は, 例えば第1層であれば,55×55の配列である.Deep Dreamでは,配列全体の平均値が大きくなるように入力 画像を変化させる.また,切羽評価AIのfcNew層にこの 方法を適用すると、特定の評点に対応する特徴量のみ大 きくなる画像が生成される.この画像は、特定の評点に 分類される典型的な画像であると言える.

(2) DNNの各層で抽出される特徴

図-3にConvl層に使われている96種類のフィルターを 示す.フィルターは11×11ピクセルであり,元画像の一 部である11×11ピクセルの画像がフィルターと近似して いるほど出力値が高くなる.つまり,Convl層の処理は, 元画像から,図-3に示したフィルター画像と類似した部 分を抽出する処理,ということが出来る.図より, Convl層では画像内の縦や斜めのストライプや,原色系 のグラデーションのような基本的な特徴が抽出されるこ とが分かる.

図-4に、Conv2層のフィルター256種類のうち、ランダ ムに選んだ100種類からの出力値が大きくなるように生 成された画像を示す.図-3に見られる基本的な特徴に比



図-3 Convl層の96種類のフィルター



図-4 Conv2層のフィルターに対するDeep Dream画像(100種類)

べ,まだら模様と,赤と緑のグラデーションの組合せ (例えば,図-4左上)が抽出されている.



図-5 Conv3層のフィルターに対するDeep Dream画像(100種類)



図-6 Conv4層のフィルターに対するDeep Dream画像(100種類)



図-7 Conv5層のフィルターに対するDeep Dream画像(100種類)



図-8 fc6層のフィルターに対するDeep Dream画像(16種類)

図-5に、Conv3層のフィルター384種類のうち、100種 類からの出力値が大きくなるように生成された画像を示 す.図よりConv2層で抽出された特徴が組み合わされ、 さらに複雑な特徴が抽出されている.例えば図-4の多く の画像は原色が目立ち、鮮やかであることに対し、図-5 の画像は色が複雑に混ざっているため、鮮やかさに欠け ている.また、図-5にはまだら模様と細かいグラデーシ ョンの組み合わせもみられる(左から9、上から5).

図-6と図-7にConv4層とConv5層のフィルター384種類 と256種類のうち、100種類から抽出される特徴を示す. 図-5に比べて図-6の模様は細かいため、この画像サイズ ではまだら模様が目立たなくなり、全体的には単調に見 える.図-7も同様に単調に見えるものの、このサイズで は違いを見分けることは難しい.

図-8と図-9にfc6とfc7層の4096チャネルのうち16チャネ ルの出力が大きくなるように生成された画像を示す.こ こで見られる模様は、AlexNetが学習している1000種類に およぶカテゴリーの分類に役立つパターンであり、具体 的に表している物やその一部を認めることはできない.

図-10にfc8層の1000チャネルのうち,16チャネルの出 力が大きくなるように生成された画像を示す.この最後 の層による各チャネルの出力値は、それぞれのカテゴリ ーの特徴量を表している.図より、学習された特徴が抽 出されていることが分かる.

(3) 評点ごとの典型的な画像の生成

ここでは図-1に示すfcNew層の各チャネルからの出力 値が大きくなるような画像を生成する.風化変質を対象 とするため、チャネル数は4である.得られた画像は転 移学習モデルが抽出した各評価値に対応した特徴を可視 化したものであり、それぞれの評点が付される典型的な 画像といえる.図-11に生成された画像を示す.

評点1(概ね新鮮)の画像は亀裂,または、岩塊の輪郭



図-9 fc7層のフィルターに対する Deep Dream 画像(16種類)



図-10 fc8層のフィルターに対するDeep Dream画像(16種類)

のような筋状の模様や、岩塊の陰影のような模様が見ら れる. また、切羽の学習データには含まれないような鮮 やかな朱色や黄緑色の模様が描かれている. これは図-9 に示すAlexNetから抽出された特徴を用いていることに よると考える. 評点2 (割目沿いの風化変質) も同じよう に筋状の模様や、岩塊状の模様が見られる. 評点1に比 べれば、筋状の模様はやや不明瞭になっている. 岩の先 鋭な形状が形成しにくくなり,丸みを帯びた形状を表し ていると解釈することが出来る. 評点3(岩芯まで風化変 質)では筋状の模様は評点2に比べてさらに不明瞭で、部 位によっては見られない. また, 凹凸も少なく平面的に 見える. 評点4 (土砂状風化, 未固結土砂) では再び全面 的に筋状の模様が現れ、他の評点に比べて密度が高い. 細かく入った亀裂や土砂状の模様を表していると考える ことが出来る、このような画像を把握しておけば、切羽 評価結果に対する考察や説明がある程度可能になると考 える.





5. まとめ

本研究では、人工知能が評価した結果について考察や 説明を可能にすることを目的に、人工知能が画像を評価 する際に着目する特徴の把握を試みた.

まず,一つの特徴として色に着目し,学習データとテ ストデータにカラー画像を用いたケースと,グレースケ ールに変換した画像を用いたケースの的中率の比較を行 った.その結果,両者の的中率に大きな違いはなく,色 合いよりもむしろ,模様が重要な特徴となっていること が分かった.

次に、AlexNetの各層について特定のチャネルの出力 値が大きくなる画像を生成するために、Deep Dreamを用 いた.それにより、各層で抽出される特徴を画像として 生成することが出来た.また、深い層ほど抽出される特 徴は複雑になることが分かった.

最後にDeep Dreamを用いて、風化変質についてそれぞ れの評点の典型的な画像を生成した.その結果、亀裂の ような筋状の模様や、岩塊の印影のような模様が現れた. また、評点1~3では風化変質が進むにつれて鋭い岩かど が形成されにくくなり、丸みを帯びた形状を表している と解釈できる画像が得られた.また、評点4では細かい 亀裂が入ったような画像が得られた.

以上から、人工知能の処理内容を部分的ではあるものの把握することができ、出力された評点が切羽画像のいかなる特徴によるものか、といった考察もある程度可能なったと考える.

今後の課題として、今回用いた学習用データの画像は 227×227ピクセルに細分化されている.その対になる評 点(正解)は、切羽の天端、左肩、右肩部の3つの領域の 代表値が与えられている.実際は同じ領域内でも地山の 状態はばらつくと考えられ、より精度を高めるためには 細分化された画像個々の評点を学習データとして与える ことが望ましい.

参考文献

- 加浩二,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,トンネル工学報告集,第 27 巻, 1-24, 2017.
- 2) 中岡健一,畑浩二:人工知能を用いた切羽評価に影響 をおよぼす岩盤の特徴分析,土木学会第 73 回年次学 術講演会講演概要集,Ⅲ-511, pp. 1021-1022、2018.
- 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.
- 4) 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 Conferenceon Machin Learning*, 2016.

A STUDY TO GRASP THE FEATURES EXTRACTED BY ARTIFICIAL INTELLIGENCE FOR TUNNEL FACE EVALUATION

Kenichi NAKAOKA, Koji HATA

We are executing the study to evaluate tunnel face using the AI. There is a problem in the method that it is difficult to discuss or explain the result. So we considered that if the feature of the images the AI focused on were known, it would be possible to explain the results. At first, we focused on the color as one of the features, it was proved that the color was not an important feature. Next, the features extracted by each layer of the neural network were visualized. As a result, it was found that more complex patterns were extracted from deeper layers. Finally, a typical image classified into each tunnel face score was created. These images have possibilities to be helpful for evaluating the tunnel face.