

畳み込みニューラルネットワークを用いた切羽性状の評価に関する検討

飛島建設 正会員 ○鈴木 亮汰
 飛島建設 正会員 松田 浩朗
 飛島建設 正会員 兼松 亮

1. はじめに

2012年に AlexNet が画像認識競技会：ILSVRC にて他のモデルに大差をつけて優勝して以降、深層学習は情報学にとどまらずに様々な分野で注目が集まっている。本研究は、この深層学習のうち、画像認識で広く使われている畳み込みニューラルネットワーク(CNN)をトンネル現場で行われる切羽評価に適用させることを検討したものである。

2. 支保パターンの推定

まず、切羽全体を写した写真を用いてその地点の支保パターン(CI, CII, DI...)を推測する識別型 CNN 作成を試みた。できあがったネットワークは 8~9 割程度の高い正答率で支保を予測できたが、Grad-CAM¹⁾を用いて判別に関する影響度分布を可視化すると、図 1 に示すように鏡面ではなく支保部材の存在が大きく影響していることが確認された。

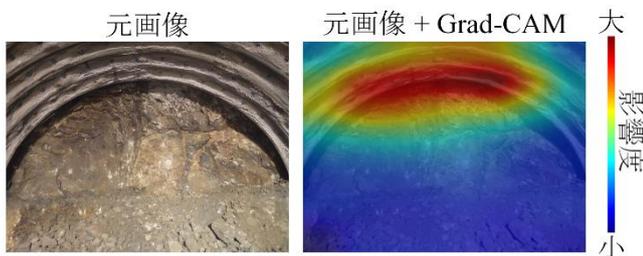


図 1 Grad-CAM による支保判定の可視化の一例

3. 切羽画像のトリミング

本質的な切羽評価になるよう、支保部材が写らない

ようなデータセットを作成した。画像収集の流れを図 2 に示す。切羽観察簿では、天端・右肩・左肩の 3 つに切羽を分けてそれぞれ評価を行っているので、トリミングもこれに従って行った。また、CNN では正方形の画像を入力として使用するの、ここからさらにランダムに複数回トリミングを行ってデータを蓄積させた。これにより、100 枚程度の切羽画像から 5000 枚程度の教師データを取得することができた。

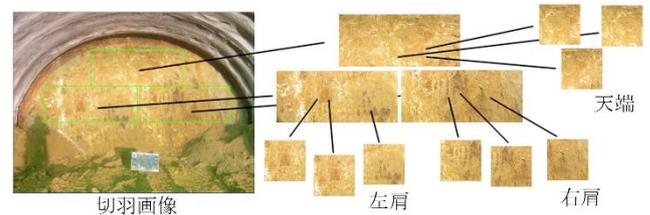


図 2 データセット作成方法の概略図

4. 識別型 CNN の設定と推定結果

トリミングされた画像から、切羽観察簿の評価項目に合わせて識別型 CNN を作成した。本研究では、Google 社の研究チームが公開している Inception-v3²⁾から転移学習を行っており、中間層ではあらかじめ学習されたパラメータを使用し、最終層である全結合層で評価項目に合わせた出力次元の調整を行っている。例えば一軸圧縮強度の場合、切羽観察簿では 6 段階に評価していたので、出力は 6 次元に設定され、全体のレイヤ構成は図 3 のようになる。

このようにして得られた CNN と、学習とは独立させ

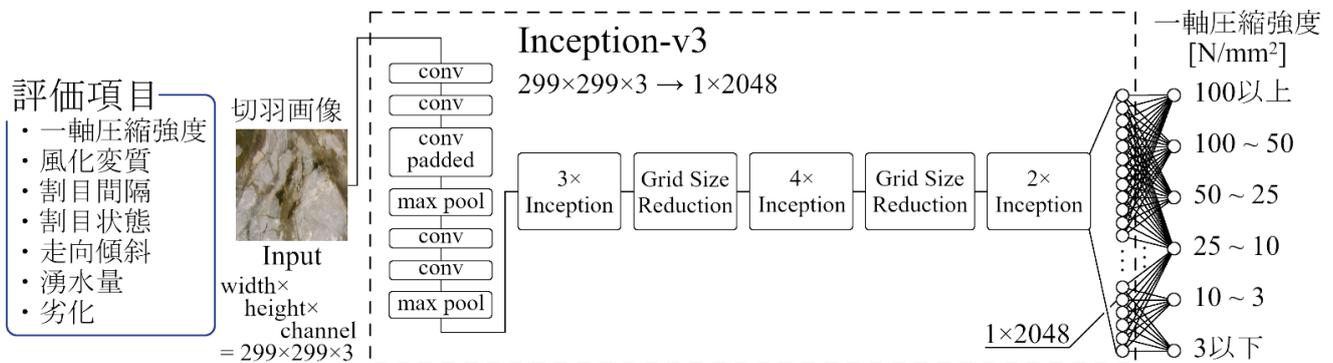


図 3 識別型 CNN の構成概略図 (一軸圧縮強度識別の例)

キーワード 切羽評価, 画像処理, 深層学習, 畳み込みニューラルネットワーク

連絡先 〒270-0222 千葉県野田市木間ヶ瀬 5472 飛島建設(株) 技術研究所 TEL04-7198-7572

て用意した切羽画像を用いて識別テストを行った。結果は表1の通りであり、いずれの項目も70%以上の割合で正しく識別することができた。また、誤答についても極端な間違いはなく、最終的な支保パターン選定へは大きく影響しない程度の誤差であった。しかし、本研究において識別できるだけのばらついたデータを集めることができたのは、一軸圧縮強度と風化変質の2項目に関してのみであり、他の評価項目についてはデータが拡充しておらず、CNNを作ることができなかった。このように、取り扱うデータの偏りによって学習が実行不可になるということが課題として抽出された。

表1 識別の正答率

識別項目	画像点数	正答数	正答率
一軸圧縮強度 (6段階評価)	185	142	76.8%
風化変質 (4段階評価)	178	126	70.8%

5. 回帰型 CNN の設定と推定結果

評価点に偏りのあるデータセットでも学習ができるよう、回帰型 CNN を構築する。このネットワークでは、出力は1次元に設定され、正解として設定した値と出力との差で損失関数を取る。本研究では、識別型 CNN と同じデータセットを用いて一軸圧縮強度の推定について回帰型 CNN を検討した。損失関数については、以下に示す RMSE を用いて最適化計算を行った。なお、 y は出力値[N/mm²], \hat{y} は正解値[N/mm²], m は損失算出のために扱うデータ数を表している。

$$RMSE = \sqrt{\{\sum_{i=1}^m (y^i - \hat{y}^i)^2\}/m}$$

また、レイヤ構成については以下の表2に示す通りとし、適宜 Batch Normalization³⁾を導入して出力の正規化を行った。

表2 回帰型 CNN の構成

Type	patch size/stride	input size
conv	5 × 5/3	224 × 224 × 3
batch-norm		74 × 74 × 64
average pool	2 × 2/2	74 × 74 × 64
conv padded	4 × 4/1	37 × 37 × 64
batch-norm		37 × 37 × 128
average pool	3 × 3/2	37 × 37 × 128
conv padded	3 × 3/1	18 × 18 × 128
batch-norm		18 × 18 × 128
conv padded	3 × 3/1	18 × 18 × 128
fully connected	regression	18 × 18 × 256

学習から得られた予測器を使って切羽画像から一軸圧縮強度を求めた結果を図4に示す。正解値と出力値

とで正の相関を取ることが理想であるが、相関係数は0.28、全体の RMSE 値は 28.9 となり、実際の切羽評価に使えるほどの精度は得られなかった。しかし、識別型 CNN でなくても一軸圧縮強度を算出できる可能性を確認できた。

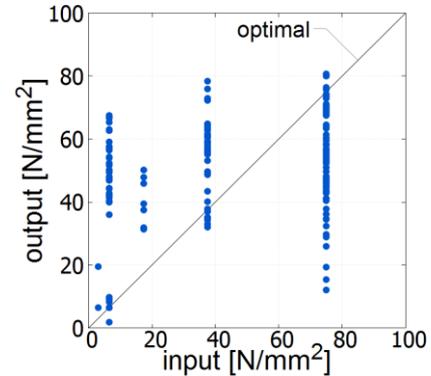


図4 一軸圧縮強度の推定結果

6. まとめ

CNN を用いてトンネル切羽の性状評価について検討を行った。結果をまとめると以下の通りである。

- ・ 切羽全体の画像を使用し、支保パターンを推測する CNN から、支保部材の写り込まないデータセットが本質的な切羽評価には必要と分かった。
- ・ 鏡面でトリミングを行い、そこから転移学習によって識別型 CNN を作成した。圧縮強度と風化変質について70%以上の正答率で識別することができたが、CNN を作るためにはさまざまな評価のデータを集める必要があり、教師データ拡充の難しさが課題として挙げられた。
- ・ 切羽鏡面の一軸圧縮強度を推定する回帰型 CNN を提案した。現場の切羽評価に使えるほどの精度は得られず、データの収集方法やレイヤ構成等に再検討が必要と考えられるが、教師データの評価点がばらついていなくても学習できるモデルを作ることができた。

参考文献

- 1) R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, D. Batra: Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization. In ICCV, 2017.
- 2) C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, Z. Wojna: Rethinking the Inception Architecture for Computer Vision. In CVPR, 2016.
- 3) S. Ioffe, C. Szegedy: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. In ICML, 2015.