

深層学習を応用したトンネル覆工面画像からの劣化・損傷の抽出

山梨大学 学生会員 ○朱奕繪

山梨大学 正会員 吉田純司

1. はじめに

日本の経済基盤は20世紀後半の建設ラッシュにより大きく発展を遂げた。しかし近年これらの多くが建設後50年以上を経過し、老朽化が大きな問題となっている。特にトンネルに関してみると、平成24年12月に発生した山梨県中央自動車道笹子トンネル天井板崩落事故は記憶に新しく、トンネル本体や設備全体を含めた適切な維持管理・更新の重要性が強く叫ばれている。現在のトンネルの定期点検は近接目視や打音検査が基本である。そのため、交通規制や熟練技術者による適切な判断が必要となっており、コスト削減、熟練技術者の確保が大きな問題となっている。これらを解決するためにトンネル覆工面の劣化・損傷を低コストかつ効率的に行うシステムの構築が必要となる。

そこで本研究では、深層学習を応用し、高速道路のトンネル覆工面画像から劣化・損傷を抽出するシステムの構築を目的とする。

2. システムの概要

トンネル覆工面画像には照明や排気口などの設備が多く存在しており、それらを損傷と誤認する可能性がある。そこで、本研究では、まず、それらの設備等を抽出するニューラルネットワーク(Neural Network: NN)¹⁾を構築した。

次に、上記のNNを適用し、「設備等」の画素の輝度値を変更したトンネル覆工面画像(以後、コンクリート覆工面画像と呼ぶ)から劣化・損傷を抽出するNNを構築した。

最後に、上記2つのNNを統合して、トンネル覆工面画像から劣化・損傷を自動で抽出するシステムを構築した。

3. トンネル覆工面画像からの設備等の抽出

(1) 学習用のラベル付け画像の作成

本研究で用いたトンネル覆工面画像は、サイズが約7000×4000画素と非常に高解像度である。そこで、本研究では、情報量を考慮し、上下左右に3割のオーバーラップを許容して約800×800画素に分割し、NNの学習用画像を作成した。

本学習では、画像を画素単位で分類するセマンティックセグメンテーション¹⁾を用いる。具体的には、「設備等」と「それ以外(コンクリート覆工面)」の2分類とする。この分類には、[図-1](#)に示すSegnet²⁾を採用し、ラベル付け画像を4976枚、手作業で作成して、学習に用いた。

(2) 設備等の抽出結果

全ラベル付け画像のうち学習用に8割、検証用に2割を用い、学習条件およびSegnet²⁾の構造・パラメータを調整しながら、学習を行った。そのうち、最も精度が良かったものは、検証データでの判別精度で98.74%となった。[図-2](#)に学習の推移を示す。

最も精度が良かったネットワークを、未知のトンネル画像に適用した例を[図-3](#)に示す。図より電灯や排気口などほとんどの設備を正確に抽出できていることがわかる。

4. コンクリート覆工面画像からの劣化・損傷の抽出

(1) コンクリート覆工面画像からの設備等の除去

ここでは、まず、3節で構築したネットワークをトンネル覆工面画像に適用する。次に、そこで抽出された設備等の領域の輝度値をRGBともに最大値に設定し、その画像(コンクリート覆工面画像)を、オーバーラップを許容して再分割し、目視で劣化・損傷を抽出し学習用のラベル付け画像を作成する。

この劣化・損傷の抽出では、NNを用いたセマンティックセグメンテーションにより「crack」、「water crack」、「quasi-crack」、「quasi-water crack」、「non-crack」の5つのカテゴリに、画素ごとに分類する。具体的には、3節と同様に、Segnet²⁾を採用し、その学習用にラベル付け画像を手作業で2520枚作成した。学習の際には、試行錯誤的に、学習条件や重み等のパラメータを変化させながら学習を行い、そのなかで最も高精度のNNにおける検証データでの判別精度は99.43%であった。

(2) 劣化・損傷の抽出結果

最も高精度なNNを、学習に用いた画像に適用した事例を[図-4](#)に示す。また、未知のコンクリート覆工面画像に適用した例を[図-5](#)に示す。これらの図をみると、明確なクラックや漏水については、目視での判定と概ね一致していた。

最後に、上述した2つのNNを統合し、オリジナルのトンネル覆工面画像から、劣化・損傷を一貫して抽出できるシステムを構築した。未知のトンネル覆工面画像に本システムを適用した結果を[図-6](#)に示す。図より、主要な劣化・損傷をおおむね抽出できていることが分かる。

6. まとめ

本研究では深層学習を応用し、トンネル覆工面画像から自動で劣化・損傷を抽出するシステムを構築した。本システムは、2つのNNからなり、1つ目のNNで設備等を抽出・除外し、その結果に2つ目のNNを適用して、劣化・損傷を抽出している。現段階では、劣化・損傷の学習用データを著者らの目視判断で作成しているが、今後は、専門家が判定した画像を学習データとして取り入れ、さらなる精度の向上を目指していく。

参考文献

- (1) 斎藤康毅:ゼロから作るDeep Learning—Pythonで学ぶディープラーニングの理論と実装, オライリー・ジャパン, 2016.
- (2) V.Badrinarayanan, A. Kendall, and R. Cipolla: Segnet: A deep convolutional encoder-decoder architecture for image segmentation, IEEE transactions on pattern analysis and machine intelligence, Vol.39, No.12, pp.2481-2495, 2017.

キーワード: 維持管理, 診断・補修・補強, 深層学習, 画像認識

〒400-8511 山梨県甲府市武田4-3-11, TEL: 055-220-8521, e-mail: jyoshida@yamanashi.ac.jp




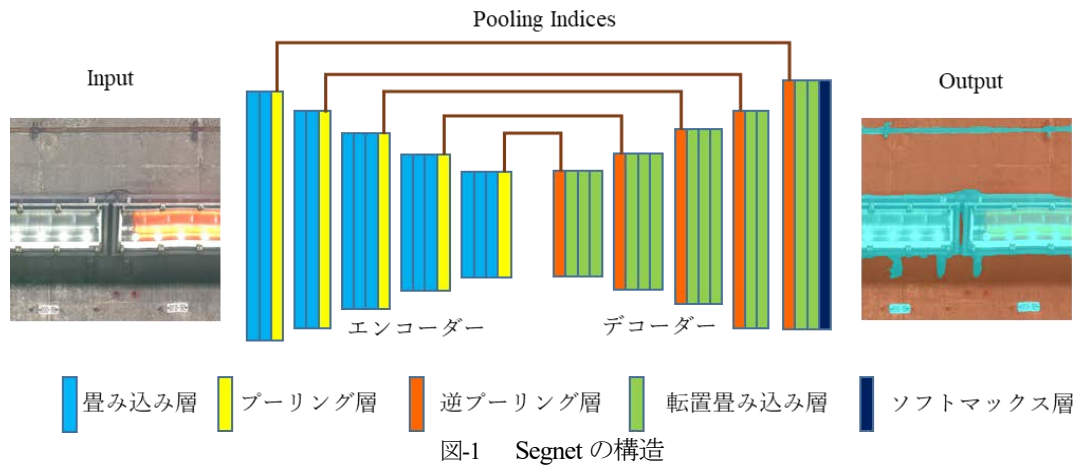


図-4 NN を学習に用いた画像に適用した事例 (黄色：crack, 青色：water crack, 橙色：quasi-crack, 紫色：quasi-water crack, 黄緑色：non-crack)




図-5 NN を未知の覆工面画像に適用した事例 (黄色：crack, 青色：water crack, 橙色：quasi-crack, 紫色：quasi-water crack, 黄緑色：non-crack)




図-6 本システムをトンネル覆工面画像全体に適用した判別結果を色付けした例 (黄色：crack, 青色：water crack, 橙色：quasi-crack, 紫色：quasi-water crack, 黄緑色：non-crack)