

深層学習を用いた高速道路における舗装路面画像のクラックの分類

大日コンサルタント(株) 正会員 清水 裕介
山梨大学大学院 正会員 吉田 純司
(株)NEXCO 東日本エンジニアリング 正会員 小野 義道
東京工業大学 正会員 竹谷 晃一

1. はじめに

日本の社会基盤は戦後の高度経済成長期に大きく発展し、中でも道路は日本の経済や生活を支えてきた。しかし近年ではこれらの老朽化が社会問題となっており、さらに予算も縮小傾向にあるため効率的な維持管理と合理的な補修・改善が必要とされている。中でも高速道路は走行条件が厳しい。このことから NEXCO 東日本グループでは道路性状測定車の RoadEye によって撮影した路面画像からクラックを判定して点検を行っている。しかし、クラック判定は未だに専門員による目視が主となっており、手間・コストがかかることに加え、客観性に欠けるという問題点を有している。

そこで本研究では深層学習を用いて路面画像のクラックを分類し、かつジョイント部を除外することで高精度な健全度評価を実施できる解析システムの構築を目的とする。

2. 深層学習を用いた舗装路面のクラックの分類

本研究では Roadeye で撮影された路面画像を用いて、画像処理に優れた畳み込みニューラルネットワークを学習させた。Roadeye は路面全体を真上から一定の明るさで撮影することができ、また非常に高解像度であるため微小なクラックまで所得できる。路面画像は NEXCO の要領に従って、0.875m×1m の領域に分割した。クラックは NEXCO 専門員が目視で分類した結果を基に進行方向に平行な Longitudinal Crack (: L-Crack)、進行方向に垂直な Transverse Crack (: T-Crack)、面状に広がった Area Crack (: A-Crack) に分類した。分類例を図 1 に示す。分類したクラック画像とクラックのない路面画像 (: Nothing) を表 1 の通りに分け、学習と検証を行った。ニューラルネットワークは既存のニューラルネットワークの 1 つである VGG¹⁾の構造を参考に構築を行った。構築したニューラルネットワークの構造と学習条件は図 2 および表 2 に示す。なお、フィルターのストライドは全て 1 である。

学習の結果、学習用データでの精度は 99.08%、検証用データでの精度は 96.30% となった。検証用データでも高い精度を得られたことから汎化性能も得ることが出来たと考えられる。




図 1 クラックの分類例

表 1 クラック分類のデータセット

学習データ				
L-Crack	T-Crack	A-Crack	Nothing	合計
400	400	400	650	1850
検証データ				
L-Crack	T-Crack	A-Crack	Nothing	合計
52	50	62	106	270




図 2 ニューラルネットワークの構造

表 2 クラック分類の学習条件

学習条件	
学習法	adam
ミニバッチサイズ	32
最大エポック	100
初期学習率	0.001
学習中の学習率の低下	×0.9/10epoc
L2 正則化の係数	0.0001

3. 深層学習を用いたジョイント部の検出

NEXCO のクラック判定³⁾ではジョイント部分は除いて判定を行っている。そのため路面からジョイント部の検出を行った。

検出は畳み込みニューラルネットワークを用いて画像内の物体をピクセル単位で判定した。図 3 のように 28 例のジョイント部からラベル付けした学習用データを 662 枚、検証用データを 50 枚作成した。ニューラルネットワークは既往のネットワークである SegNet²⁾の構造を用いた。用いた学習条件を表 3 に示す。学習の結果、全ての検証用データのジョイント部をほぼ正確に検出した。ジョイント検出の結果画像例を図 4 に示す。

4. 高速道路路面の健全度評価システムの構築

2 節で述べたクラック分類と 3 節で述べたジョイント検出を組み合わせ、高速道路路面のジョイント部を判定から除外し、クラックを自動分類する健全度評価システムを構築した。クラックとジョイント部は判定後に路面画像上に表示される。このシステムを用いた判定例を図 5,6 に示す。

5. まとめ

- 本研究での成果を以下に示す。
- (1) 深層学習を用いた高速道路舗装路面のクラック分類を行い、分類精度 96.30%を得た。
 - (2) 深層学習を用いた高速道路路面のジョイント部の検出を行い、ジョイント部を正確に検出した。
 - (3) ジョイント部をクラック分類から除外した上でクラックを自動分類し、クラックとジョイント部を路面画像上に表示する健全度評価システムを構築した。
- 本研究を実際の路面点検の用いることで手間・費用を大幅に削減することが期待できる。

参考文献

1) K.Simonyan and A.Zisserman : Very deep convolutional networks for large-scale image recognition, arXiv:1409.1556, 2014.

2) Vijay Badrinarayanan, Alex Kendall and Roberto Cipolla : SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, arXiv:1511.0056, 2016.

3) 東日本高速道路株式会社, 中日本高速道路株式会社, 西日本高速道路株式会社 : 設計要領 第一集 舗装保全編・舗装建設辺 平成 29 年 7 月版, 株式会社高速道路総合研究所, 2017



図 3 ラベル付けした学習用データの例

表 3 ジョイント検出の学習条件

学習条件	
学習法	sgdm
ミニバッチサイズ	9
最大エポック	40
初期学習率	0.01
学習中の学習率の低下	$\times 0.9/4\text{epoc}$
L2 正則化の係数	0.01




(a) 原画像




(b) ジョイント部の検出画像

図 4 ジョイント検出の結果例




(a) 原画像




(b) 健全度評価システムの判定画像

図 5 健全度評価システムの判定例 1



(a) 原画像



(b) 健全度評価システムの判定画像

図 6 健全度評価システムの判定例 2