

深層学習を用いた排水性舗装のひび割れ検出に関する基礎的検討

朝日航洋株式会社 正会員 ○鈴木 清

朝日航洋株式会社 非会員 杉山 史典

非会員 松山 満昭

非会員 山本 和朋

株式会社北海道朝日航洋 非会員 石井 将史

1. はじめに

舗装道路の維持管理には、その健全度を評価するために、路面に生じたひび割れなどの検出による面的な状態把握が必要となる。これまで路面の状態把握は、目視点検により行われていたが、近年ではレーザ測距儀やビデオカメラなどのセンサを搭載した計測車両を用いた効率化が進められている¹⁾。

ラインセンサカメラは、計測車両に搭載可能なセンサの一つであり、カメラを車両に搭載して等速運動させることにより、道路に沿って連続的に路面の画像が取得され、今後の利活用が期待される。

一方、路面の画像からひび割れ箇所を検出するためには、多様な環境要因(太陽高度・方向等)、路面材質を考慮する必要があることから、昨今話題となっている機械学習の適用性が高いと考えられる。

しかしながら、本検討で対象とする排水性アスファルトにおけるひび割れは、取得した画像において、大局的に見た場合には線形を成し、且つそれが周囲と比較して輝度値が低くなるものの、詳細に見た場合には必ずしもそれが当てはまらない。よって、排水性アスファルトにおけるひび割れを検出するためには、通常の機械学習では困難であり、多様なスケールを考慮した深層学習の導入が必要であると推測される。

そこで、本検討では、ラインセンサカメラを車両に搭載して、道路に沿った画像を取得し、続いて深層学習を用いて、路面上のひび割れを検出する技術の開発を目的として、学習手法の検討から検証までの一連のプロセスを蓄積し、汎化性を獲得するための基礎的な検討を行った。

2. 使用機材及び深層学習環境の概要

舗装試験法便覧²⁾によれば、舗装路面に形成された1mmのひび割れの検出が要求されており、ラインセンサカメラによって取得された画像は1画素あたり0.5mm程度の分解能が必要であると考えられる。したがって、本検討では、図1に示すように、地上から約




図1. ラインセンサカメラの設置状態

2mの位置にラインセンサカメラを鉛直(道路向き)で設置し、画像解像度を縦方向0.52mm、横方向0.44mmとした。

本検討で使用したラインセンサカメラは、日本エレクトロセンサリバイスのXCM404OSAT2を用いた。

深層学習処理環境は、Continuum Analytics社から提供されているPythonパッケージAnaconda3をベースに、学習フレームワークとしてGoogle社が開発しオープンソースとして公開されているTensorFlowにpix2pixを実装した³⁾⁴⁾。

3. 深層学習の概要と路面評価への適用性

路面健全性評価の1指標であるひび割れは、目視により比較的容易に検出できる損傷であり、このような検出対象は2012年に開催されたILSVRC(大規模画像認識協議会)において、CNN(畳み込みニューラルネット




図2.CNNの概念図

トワーク)を用いた機械学習により誤検出率の低い結果が得られることが報告されている⁵⁾。

CNNは、図2に示すように入力画像の畳み込み(統計量画像の作成)とプーリング(複数の統計量画像間の演算処理)を繰り返す、演算を繰り返すごとに画像のエッジ、肌理、及びその構成要素を特徴量として捉え、理解する仕組みを持つ。その汎用性の高さから、従来の画像解析手法では検出が困難とされてきたスケールを変えた場合に見え方が異なる検出対象についても、その形状や輝度値など多様な側面を認識し、検出することを可能とする。そのため、環境要因制御が難しい屋外環境下での検出精度の向上、自動化による点検の効率化及び客観的指標による評価技術として期待される。

4. 深層学習の適用及び結果

(1)入力画像の準備

入力画像は、舗装の劣化が進んでいる一般道路のラインセンサカメラ画像を用いた。画像中には、ひび割れやパッチング跡などの局所劣化が多数存在し、且つ多様なひび割れが確認されることから本検討の精度評価に適している。検証領域は、図3に示す幅約2.1m、長さ約228mの区間a～cである。




図3.入力画像

(2)教師画像の準備

深層学習は、画像中に含まれる検出対象領域を教師画像として入力し、学習することで、特定の対象物を検出可能とする(図4)。




図4. 教師画像例

したがって、教師画像の判読精度が学習モデルの検出精度及び汎化性に大きく影響する。教師画像は、

分割した入力画像から無作為に約900ヶ所選択し、目視判読画像と入力画像を左右に並べた256x512pixelサイズの教師画像を生成した。

(3)教師画像による学習

本検討では、教師画像から無作為に選択した約600ヶ所で学習モデルを構築し、約300ヶ所を検証画像とするクロスバリデーションを採用した。学習モデルは、学習回数を決定するエポック数と、教師画像から無作為に選択するバッチサイズにより決定される。本検討では、バッチサイズをpix2pixの推奨値である4とし、エポック数は400とした。

(4)検出結果及びその検証

目視点検と本検討によるひび割れ検出結果を比較し、処理モデルの検出精度及び汎化性を評価した。

検出精度の評価に関して、表1に目視点検によるクラック率²⁾と、本検討によるクラック率²⁾の比較を示す。

表1.クラック率²⁾の比較

区間	目視点検によるクラック率 ²⁾ (%)	本検討によるクラック率 ²⁾ (%)
a	47.6	50.0
b	31.3	43.0
c	33.9	32.7


区間a,cにおいては目視点検と本検討によりほぼ同等のクラック率²⁾が得られたが、区間bにおいては本検

討により約10ポイント高いクラック率となっており、一部の箇所においてひび割れ検出精度の低下が生じていることが理解できる。

一方、汎化性の評価に関して、一般的に画像精度評価指標として用いられるκ係数及び全体精度を算出したところ、κ係数で0.91、全体精度で95%以上と高い値を示した。このことから、多様なひび割れを含む入力画像に対して、高い汎化性を示していると判断できる。

5. 考察

ひび割れ検出精度の低下要因として、図5に示すとおり、大局的に見るとひび割れは検出されているものの、画素単位で評価した場合、①1mm幅程度の細いひび割れの検出漏れ、②連続性の欠如、③日向部における過剰な検出幅、④検出形状の不一致があり、ひび割れと



して検出された画素の割合が、舗装試験法便覧²⁾のひび割れ本数と整合するよう精度評価手法を検討する必要がある。

図5. 検出精度の低下箇所

また、深層学習においても、与える教師画像の量及び変状箇所と非変状箇所の教師画像の比率など人為的に指定する設定値があり、それが結果にどのように左右するのか確認しながら進める必要がある。

深層学習は、今後予定されている膨大なインフラ管理において必要不可欠な技術であり継続的な基礎研究の蓄積が必要であると考える。

謝辞：本稿の作成に際し、首都高速道路株式会社、首都高技術株式会社の各位には排水性アスファルトの知見に基づく助言をいただいた。ここに感謝の意を表す。

参考文献

- 1) 森石一志, 中村博康, 渡邊一弘, 三次元点群データを用いた新たな路面評価手法の検討, 木学会論文集 E1 (舗装工学) 69(3), I_9-I_16, 2013
- 2) 公益社団法人日本道路協会, 舗装試験法便覧, 2007
- 3) 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-, 2016
- 4) Phillip, Isora, et al. "Image-to-Image Translation with Conditional Adversarial Networks" arXiv:1611.07004v2, 2017
- 5) ケータイ用語の基礎知識 第714回:ディープラーニングとは, 2015
<https://k-tai.watch.impress.co.jp/docs/column/keyword/709416.htm>