

機械学習によるアスファルト舗装のひび割れ分類

日本道路（株） 正会員 ○遠藤 桂
中央大学 フェロー 姫野賢治

1. 研究の背景と目的

舗装に発生している損傷を調査することは、舗装の維持修繕計画の立案に際して重要な役割を果たしている。アスファルト舗装に発生しているひび割れは、路面性状測定車などの測定手段によって得られた結果からひび割れ率にて定量化している。ひび割れ率は、その定義から調査対象の舗装に発生しているひび割れの対舗装面積割合を知るためには便利であるものの、ひび割れの位置情報やひび割れの種類などを表現できないため、補修の要否を判断できても具体的な補修方法を選定するための指標としては使いづらい。

ひび割れを評価する他の方法として、調査員などによる目視判断がある。国土交通省道路局が提供している「総点検実施要領（案）舗装編」や「舗装点検要領」では、原則として目視によってひび割れを評価することになっているものの、評価指標としてひび割れ率を参考にしており、ひび割れの種類は判断しない。人の主観による評価には、一定程度の偏差が生じると考えられる。舗装診断士という資格は、路面の評価結果にある程度の信頼性を付加すると考えられるが、アメリカが LTPP Distress Manual に従った実地を含むトレーニングコースなどを通じて、評価者の質を保つような取り組みをしているような段階までは至っていない。仮に目視によって正確にひび割れの種類を判断できるとしても、全国約 100 万 km の舗装済み道路すべてを目視評価して結果を取りまとめ、維持修繕の判断用資料にするには、莫大な労力と時間そして費用が必要となる。

よって、ひび割れの調査と評価を迅速に行い、舗装の維持修繕方法に関連付けられるひび割れの種類を正確に判定する方法の確立が待たれる。そのためには DX を積極的に活用することが必要である。本報告は、デジタル画像化した路面情報にもとづき、機械学習によってひび割れの種類を正確に分類することを目的に、検討した方法と結果および将来の展望について述べるものである。

2. 既往の研究との違い

コンピュータを用いて舗装路面のひび割れを抽出する研究は盛んに行われているが、ひび割れを正確にトレースすることに着眼しており、ひび割れの種類には言及していないものがほとんどである¹⁾²⁾。ひび割れの種類に係る研究として、フラクタル次元によってひび割れを「線状」「面状」「亀甲状」に区分する研究がある³⁾。しかし、線状ひび割れであっても縦ひび割れと横ひび割れでは発生原因が異なるため、個別に評価することが望ましいが、ほぼ同一のフラクタル次元を得るため両者を区別することができない。

以上を鑑みて、本研究では、アスファルト舗装に生じているひび割れを、機械学習によって縦ひび割れ、横ひび割れ、亀甲状ひび割れに分類するものである。

3. 機械学習によるひび割れの種類の評価方法

(1) 路面情報のデジタル化

今回は、スマートフォンに付属しているカメラを用いて路面を撮影し、画像の短辺長さからなる正方形に切り抜く。機械学習によってひび割れを認識しやすいように、画像を白黒 2 値化する。

(2) ひび割れ画像の分類

本研究では、機械学習の手段として、教師データありのディープラーニングを活用する。そこで、デジタル化した画像から、ひび割れなし(NR)、縦ひび割れ(LC)、横ひび割れ(TC)、亀甲状ひび割れ(AC)の 4 区分（以下、キーワード 機械学習、アスファルト舗装、ひび割れの種類、維持修繕工法の選定、DX

連絡先 〒146-0095 東京都大田区多摩川 2-11-20 TEL 03-3759-4872

4 区分) に該当するものを抜き出して教師データとする。

(3) 機械学習環境

機械学習にあたっては、インタプリタ型プログラミング言語 Python でデータ処理手順を記述して、TensorFlow や NumPy など既存のライブラリや拡張モジュールを活用する。これにより、インターネットに接続されていれば、使用する PC の性能に依存することなく、効率的かつ高速に機械学習が行える。

(4) ひび割れ分類の確認

上記のように機械学習させたあと、別の画像ファイルを用いてひび割れの分類を行う。機械学習による分類の結果を人によるひび割れの分類結果と一致するかどうか照合する。

4. 機械学習による舗装のひび割れの分類結果

学習データとして 4 区分それぞれ 156 枚、学習結果の検証データとしてそれぞれ 20 枚の合計 704 枚の画像を用いて 30 回学習させたところ 7 時間弱で学習を終えた。各学習で正しくひび割れの分類ができたものを「正解」とし、 $\text{正解率} = \text{正解数} / \text{全数} \times 100(\%)$ にて正解率を求めたところ、図-1 のようになった。数回の学習で比較的良好な結果を示し、5 回程度を超えると正解率が 90%を超えることがわかった。

この学習結果をもとに、ひび割れを分類するためのデータとして 4 区分 19 枚ずつ合計 76 枚の画像を用いてひび割れを分類させた。表-1 には、4 区分に対する詳細な分類結果を示している。ひび割れの種類を正しく分類できたのは、76 データ中 66 データであった。亀甲状ひび割れは 100%正しく分類できたのに対して、ひび割れなしの正解率は最も低かった。

ひび割れなしの路面画像には、一部骨材が飛散するなどの別の損傷が見られるものが含まれており、影響を受けた可能性が高い。また、縦ひび割れと横ひび割れの画像には、単にひび割れが 1 本だけ発生している画像に加えて、短いひび割れが付随しているものもあり、その程度によって一部亀甲状ひび割れとして分類されたものと考えている。ひび割れの種類や損傷をさらに細分化したり、表層種別ごとに教師データを用意したりすることで、さらに学習精度が向上すると考えている。

5. まとめ

機械学習によって舗装路面に生じているひび割れの種類を高い精度で分類できることがわかった。今回は、ひび割れを認識しやすいように路面画像を白黒 2 値化したが、精度は若干落ちるものの元のカラー画像を用いても同様の分類ができることを確認している。適切な教師データを用意して学習させて、元画像でのひび割れ分類の精度を向上させることができれば、カメラを搭載した車両で対象道路を走行することで、ひび割れの自動分類ができるようになると考えている。画像の評価単位を 50cm×50cm にすれば、既存のひび割れ率を容易に計算できる。結果として、発生しているひび割れの種類と程度に応じた維持修繕の必要性和、維持修繕の具体的な方法を提案できるシステムを構築できるものと考えている。

参考文献

- 1) 例えば、全ら：アスファルト舗装撮影画像からのひび割れ半自動検出システムの開発，土木学会論文集 E1 (舗装工学) Vol.71, No.3, I_31-I_38, 2015 年 12 月
- 2) 例えば、滝ら：AI を活用した舗装のひび割れ抽出に関する取り組み，第 3 回 JAAM 研究発表会論文集，pp.56-59, 2019 年 10 月
- 3) 阿部ら：舗装ひび割れのフラクタル解析，土木学会論文集 No.442/V-16, pp.119-226, 1992 年 2 月




図-1 学習回数と正解率の関係

表-1 ひび割れの分類結果

		分類結果				正解率
		LC	TC	AC	NC	
ひび割れの種類	LC	17	0	2	0	89%
	TC	0	17	2	0	89%
	AC	0	0	19	0	100%
	NC	0	2	4	13	68%