

ICT と商用車プローブデータを活用した AI による道路維持管理システムの開発

長崎大学 学生会員 友原 慎太郎

長崎大学 正会員 松田 浩 山口 浩平 出水 享

長崎大学 非会員 古賀 掲維

1. はじめに

現在、道路管理者は膨大なインフラストックを抱えており、道路舗装の損傷は徐々に進行することが問題に挙げられる。したがって、劣化具合を適宜把握しつつ、適切な維持管理を実施していく必要がある。

現在は、舗装の維持管理指数である MCI (Maintenance Control Index) を用いた路面性状評価が行なわれている。MCI は、路面性状を高精度で評価できるものの、測定には専用の測定車両が必要であり、MCI の算出にコストがかかるため、使用頻度は 5 年に 1 度程度である。そのため、目視点検が日常的に実施されている。しかしながら目視点検は、点検漏れなどのミスが発生する可能性や取得データが定量的でないなどの問題がある。そのため、高コストである MCI や業務生産性の低い目視点検等よりも、効率の良い経済的な手法の確立が急務と考える^{1) 2)}。

本研究では、スマートフォン、ドライブレコーダーなどの ICT 機器と大型交通量情報（商用車プローブデータ（以降、商プロ））を活用し、道路管理業務を簡単かつ効率的に実施するための AI を活用した道路維持管理システムの構築を目的としている。今回、システム構築に必要な画像分類 AI、道路損傷検出 AI、商プロと各データ比較の検討を行った。

2. 画像分類 AI

MCI は、平坦性、ひび割れ率、わだち掘れの 3 指標を用いて算出される。ここでは、画像分類 AI によってひび割れ率を求めることを目的とする。実施方法は、ドライブレコーダーを用いて、路面を撮影した連続画像に $0.5\text{m} \times 0.5\text{m}$ のマス目を重ね合わせ、このマス目内の画像に深層学習による画像分類 AI を組み合わせることにした。

また、ひび割れ画像のデータ取得のために、国土交通省九州地方整備局長崎河川国道事務所および福岡国道事務所に協力いただき道路パトロール車にドライブレ

コーダーを取り付けた（図 1）。

2. 1. 教師データの準備と作成

ドライブレコーダーで撮影した画像はレンズによるゆがみがあるため、チェスボード（写真 1）を用いてレンズ補正を行う。レンズ補正された画像は、ドライブレコーダー画面上において路面が台形状に記録される。この画像を射影変換（写真 2）し、さらに MCI に準じて 0.5m 四方角に道路幅員に合わせて分割を行った（写真 3）。得た画像を、損傷や道路構造物等の要素ごとに分類した（表 1）。

2. 2. 画像分類 AI の学習結果

分類の見直しや改善を繰り返し、最終結果を表 2 に示す。改善を繰り返すごとに精度は向上したが、線状ひび割れおよびパッチングの正答率は、他と比較して低いままであった。これは、パッチングの教師データの画像が他のカテゴリーより少ないことから、AI の評価にばらつきが生じたためと考えられる。




図 1 機器の設置イメージ



写真 1 チェスボード




写真 3 画像分割



写真 2 射影変換の様子

連絡先 〒852-8521 長崎県長崎市文教町 1-14 TEL095-819-2591

キーワード 道路維持管理 AI ICT ひび割れ率 深層学習 舗装道路

3. 機械学習による道路損傷検出

本章では入力した画像内において、機械学習を用いた一般物体検知アルゴリズム SSD (Single Shot MultiBox Detector) による路面損傷の検出を行う³⁾。その中でも、今回は pixel 数が多いため、高精度の検出ができるように SSD512 を用いた。なお、教師データの作成、モデルの学習、保存、検証の実行はすべてプログラミング言語 Python を用いて実行し、labellmg というツールを使用しタグ付けを行った。

機械学習の学習結果を写真 4、5 に示す。学習曲線のグラフ (図 2) より、横軸の iteration (繰り返し回数) が大きくなるほど縦軸の loss (損失) が 0 に近づいているため、AI 学習ができていると考えられるが、loss の値が高い数値となっている。これは分類する損傷の数が多いのに対して教師データの量が少なかったためと考えられる。

4. 商プロを用いた比較検討

(株) 富士通交通・道路データサービスが蓄積している商プロ (走行経路、出発・目的地、急ブレーキ、渋滞状況など) と各種データ (道路巡回日誌、道路支援パトロール支援差サービス) を比較し補修が必要な箇所を推測できないか検討を行う。ここでは、商プロのうち急ブレーキ発生イベントデータを用いた。

今回対象としたのは長崎県の主要国道である。そのデータの中から急ブレーキデータを抽出し、地図上にヒートマップで可視化した (図 3)。さらに、長崎河川国道事務所から提供していただいた巡回日誌の中から道路損傷の情報を取り出し、そのデータを地図上に可視化した (図 4)。そして両図を同じ地図上で表したものを図 5 に示す。同図の赤枠で囲まれた箇所を見ると、ポットホールの発生している箇所がオレンジ色になっており、これはこの場所でブレーキをした車両が多いことを示している。

5. まとめ

画像分類 AI、道路損傷検出 AI とともに教師データの分類が曖昧であることと、分類する損傷の数に対して教師データの量が少ないと AI の精度低下につながるということがわかった。また、商プロの急ブレーキデータと道路損傷箇所には相互関係が存在することがわかった。しかしながら、今回は長崎県内の国道だけであり規模が小さいため、より多くのデータの収集を行い信憑性

表 1 画像分類の内訳

class	カテゴリー		枚数
p0	ひび割れ	なし	2690
h1		1 本のみ	2279
h2		2 本以上	1741
p2	ハッチング	25%以上	647
p5		25%～75%	783
p7		75%以上	613
manhole	マンホール		1750
joint	ジョイント		1141
line	白線		1897
speed	道路標示		1668
shadow	影		1266

表 2 正答率比較

4 回目	
class	正答率 (%)
p0	88.3
h1	85.0
h2	65.0
p2	70.0
p5	61.6
p7	71.6
manhole	90.0
joint	91.6
line	96.7
speed	88.3
shadow	88.3




写真 4 学習結果




写真 5 学習結果




図 2 学習曲線



図 3 急ブレーキデータ (ヒートマップ)




図 4 道路損傷箇所




図 5 図 3 と図 4 の照合

の確保が必要である。

参考文献

1) 古賀, 友原, 市川, 他: 深層学習を用いた舗装面のひび割れ率算定に関する研究, 土木構造・材料論文集, pp.1-2, 2022
2) 公益社団法人 日本道路協会: 舗装点検必携, 2017
3) Wei Liu, et al: "SSD: Single Shot MultiBox Detector", European conference on computer vision, pp.21-37 (2016).