

道路舗装ひび割れ判読工程での機械学習技術適用検討

国際航業株式会社 学生会員 ○福士 直子
 国際航業株式会社 非会員 田島 朋樹
 株式会社ザクティ 非会員 松尾 義裕
 株式会社ザクティ 非会員 岡本 圭介
 国際航業株式会社 正会員 伊東 広敏

1. はじめに

道路舗装のひび割れは舗装の健全性に大きく影響を与えることからひび割れの点検は重要であり、さらに、予算・技術者ともに恒常的に不足している中での管理延長 120 万 km 超の道路舗装のマネジメントにおいては AI による効率化は喫緊の課題として取り組みが進められている^{1),2)}。機械学習技術による効率化は 1) 学習データの準備, 2) 学習モデルの構築, 3) 活用成果の品質維持の 3 つのコストを低減させることが重要である。全国の地方自治体を対象とした道路舗装点検の実務では、ある特定の条件下で取得されたデータでモデルを構築し、別の条件下で取得したデータを既存の学習済みモデルに適用して得た結果が点検成果に使用可能な品質であることが理想的な AI 利用形態である。しかしながら、学習データと取得条件が異なるデータを適用した学習モデルの出力結果は使用できるかどうか分からない。そのため、「外挿は不得手である」³⁾という点に留意した上で、技術者が「取得条件が類似するので適用可能である」と判断したデータを学習済みモデルに適用することになる。適用不可ならば前述の 1)-3) のコストが発生し、適用可ならば 3) だけで済むため、適用可能なデータなのかどうかの判断は点検コストの増減に直接影響する。そこで本検討では、学習データと適用データの取得条件が異なるデータセットを用意し、AI の予測精度の変化から適用可能なデータの考え方と AI を有効に活用するための方向性について検討を行った。本稿ではその検討の一部を紹介する。

2. 検討手順

従来型の道路舗装点検のひび割れ率算出工程で機械学習技術を使用することを想定して予測モデルを構築した。使用データは、道路舗装表面の撮影画像を舗装面がセンターラインに対して直角に 50cm 四方に区切られるように分割して作成した。解くべき課題は、各画像に写っているひび割れの本数が「0 本」、「1 本」、「2 本以上」のどれに該当するか、画像の 3 クラス分類予測とした。アルゴリズムは ImageNet のコンテストで好成績を収めたものを中心に複数検討し、一番成績の良かった VGG19 を採用した。また、予測モデルはひび割れありなし判定後にひび割れ本数を判定する 2 段階で 3 クラス分類を行う方法を採用した。さらに、50cm 画像の分類予測の結果得られる正解率(Accuracy)*、適合率(Precision)*、再現率(Recall)*と、路面性状評価業務で用いられる方法で 20m 区間のひび割れ率を算出し、目視判読の結果を正として国土交通省の診断区分判定の能力評価指標として得られる検出率と的中率⁴⁾から、実務への適用可能性について考察する。

3. データの概要

使用したデータを表 1 に整理した。全てのデータセットの撮影機材および撮影時間帯、撮影方向などの撮影

表 1 使用データ一覧

| ID | データセット | 撮影条件 | 地域特性 | 道路種別 | 平均ひび割れ率 | 調査年度 | 画像枚数 | | | |
|------|--------|------------------|-------------|-------------|---------|------|----------|------------------------|------------|------------------------|
| No.0 | 教師データ | ラインセンサ, 夜間, 垂直撮影 | 日本海側の積雪寒冷地域 | 一般国道, 主要地方道 | - | H26 | 0本 1本 | 15,025枚 11,377枚 | 2本以上 合計 | 10,886枚 37,288枚 |
| No.1 | 適用データ1 | ラインセンサ, 夜間, 垂直撮影 | 日本海側の積雪寒冷地域 | 一般国道, 主要地方道 | 12.6% | H26 | 0本 1本 | 2,047,221枚 115,306枚 | 2本以上 合計 | 217,741枚 2,380,268枚 |
| No.2 | 適用データ2 | ラインセンサ, 夜間, 垂直撮影 | 日本海側の積雪寒冷地域 | 一般県道 | 14.1% | H26 | 0本 1本 | 2,023,608枚 153,812枚 | 2本以上 合計 | 249,489枚 2,426,909枚 |
| No.3 | 適用データ5 | ラインセンサ, 夜間, 垂直撮影 | 太平洋側の沿岸平野部 | 主要市道, 一般市道 | 4.7% | H29 | 0本 1本 | 116,910枚 4,388枚 | 2本以上 合計 | 3,180枚 124,478枚 |

キーワード Road Pavement Maintenance, Crack Detection, Machine Learning, VGG19

連絡先 〒183-0057 東京都府中市晴見町 2-24-1 国際航業株式会社 e-mail: naoko_fukushi@kk-grp.jp

条件は同じである。学習データ (No. 0) は適用データ 1 (No. 1) から抽出して作成したデータセットであり、No. 0 と No. 1 はひび割れ画像のクラス構成比率以外は同等である。No. 1 は学習済みモデルの予測精度の検証データという位置づけである。No. 1 と No. 2 は同一地区のデータで、道路種別が異なる。No. 1 と No. 2 の平均ひび割れ率は同程度であった。No. 2 は適用可能と想定されるデータの位置づけである。また、No. 3 は地区、道路種別、平均ひび割れ率が異なるデータで、No. 1-3 の中では取得条件が一番異なるデータという位置づけとなる。

4. 適用結果と考察

第一段階のひび割れ有り予測精度と、第一段階と第二段階の予測結果を統合したひび割れ3分類予測精度、国土交通省の診断区分判定性能評価指標を表2に整理した。まず、No. 1 の予測精度でモデルの特徴を見る。ひび割れ0本の適合率と再現率が両方とも非常に高く、十分信頼できる。また、ひび割れ有り予測の再現率が高いので、ひび割れ有りと判定された画像を抽出するスクリーニングとして使用できるレベルである。次に、No. 2 の予測精度を見ると全体傾向はNo. 1 と同じであったため、道路種別が異なる程度であれば、適用可能と判断して良いと考えられる。次に、No. 3 の予測精度を見ると、ひび割れ有り予測の正解率がNo. 1, 2 と較べて高い。これは、もともとひび割れ無し画像がNo. 1, 2 より多いデータセットで、ひび割れ0本の再現率および適合率が高いためと考えられる。また、ひび割れ有り予測の再現率が1割以上下がっており、これはひび割れの見落としが多くなることを指している。従って、地区が異なる場合には、3クラス分類が適切に行えず、本来のスクリーニング性能も発揮できない可能性が高い事になり、適用不可と考える。

次に、国土交通省の指標を見る。これは3分類予測の結果を基に算出したひび割れ率の診断区分判定結果を評価したもので、路面性状調査技術の健全性診断区分を正しく判別する性能を評価する指標である⁴⁾。診断区分は、Ⅰ：健全（ひび割れ率20%未満）、Ⅱ：表層機能保持段階（ひび割れ率20-40%）、Ⅲ：修繕段階（40%以上）となっている。No. 1, 2 のⅡ以上およびⅢのみの検出率がA（80-100%）で、的中率はB（60-80%）またはC（40-60%）であった。仮にAであることが実務利用における合格ラインと考えると、本検討で構築したモデルは、修繕段階にある区間の見落としが少なく合格ラインであると言える。前述のスクリーニングとしても実務で使用可能レベルであると言える。その一方で、No. 3 のⅢのみの検出率はE（0-20%）であり、修繕段階にある区間の検出に問題がある。維持管理においては、修繕段階の区間の見落としは望ましくないため、診断区分判定でも他地区の学習済みモデルにはデータ適用不可と考える。

5. おわりに

本検討では、道路舗装画像のひび割れ3クラス分類予測の学習済みモデルへのデータの適用可否の判断において、学習データと適用データの道路種別が異なる程度であれば十分適用可能であり、地区が異なれば適用不可であるという結果であった。今後は、本モデルをスクリーニングに使用した際の実用性の検討を行い、品質維持にかかるコストの低減について取り組んでいく。

表2 適用データ別の予測精度*

| ID | ひび割れ有り予測 | | | ひび割れ3分類予測 | | | | | | 国土交通省評価 ⁴⁾ | | | | |
|------|----------|-------|-------|-----------|-------|-------|-------|-------|-------|-----------------------|------|-----|------|-----|
| | | | | 正解率 | 0本 | | 1本 | | 2本以上 | | 検出率* | | 的中率* | |
| | 正解率 | 適合率 | 再現率 | | 適合率 | 再現率 | 適合率 | 再現率 | 適合率 | 再現率 | Ⅱ以上 | Ⅲのみ | Ⅱ以上 | Ⅲのみ |
| No.1 | 0.892 | 0.582 | 0.816 | 0.866 | 0.968 | 0.905 | 0.277 | 0.561 | 0.623 | 0.668 | A | A | C | B |
| No.2 | 0.878 | 0.592 | 0.852 | 0.846 | 0.968 | 0.883 | 0.291 | 0.606 | 0.669 | 0.700 | A | A | C | B |
| No.3 | 0.953 | 0.600 | 0.693 | 0.941 | 0.980 | 0.970 | 0.391 | 0.542 | 0.519 | 0.432 | B | E | A | - |

*正解率：全体の正答率，適合率：予測した中での正答の割合，再現率：実数の中での正答の割合。検出率：目的損傷レベルの判定区間数について、正答区間数を存在する区間数で割った値，的中率：目的損傷レベルの判定区間数について、正答区間数を検出区間数で割った値。

参考文献

1. 土木学会 SIP インフラ連携委員会. SIP インフラ連携委員会報告書 インフラ維持管理への AI 技術適用のための調査研究報告書. 2019.
2. 富士 直子, 小林 大志郎, 岩男 誠二, 笠原 亮介, 矢吹 信喜. 機械学習技術を活用した路面性状調査の効率化. 土木学会論文集F 3 (土木情報学). 2017;73(2):I_409-I_415.
3. 樋口 知之. 視点 人工知能はみよみまねマシンの究極形. 情報管理. 2016;59(5):331-335.
4. 国土交通省. 『路面性状を簡易に把握可能な技術』の試験結果等を公表します ～新技術の活用に向けて～. 2018.