

Deep-learning モデルによる床版ひび割れの検出精度の検討

金沢工業大学 学生会員 岡 直哉
金沢工業大学 正会員 田中 泰司

1. 研究背景

本研究では RC 床板の点検合理化を実現するために、高解像度写真からひび割れ判定が可能な AI モデルを作成した。判定精度を向上するために、教師データの作成において工夫を行い、その効果を検証した。

2. 研究概要

本研究では、画像分類の事前学習済みモデルの一つである VGG16 を用いて転移学習を行い、コンクリートのひび割れを判定できる Deep-learning モデルを3種類作成した。これらをそれぞれ model1、model2、model3 とする。本研究では RC 床板下面を対象とし、全国の各地方から選出された劣化が特徴的な RC 床板の画像を使用した(表-2)。各画像の解像度は 0.2~0.3mm/ピクセルである。

各モデルの違いは表-1 に示すようにアノテーション範囲である。model1 の場合は 256×256 ピクセルの全体が範囲である。アノテーション範囲の中にひび割れが含まれているか否かでひび割れの有無を判定した。この際、範囲内に僅かでもひび割れがあるとひび割れ有り判定したが、ひび割れが画像端部に位置している場合には、その存在を目視でも判別することが難しいことがわかった。そこで model2,model3 では入力画像は 256×256 ピクセルのままであるが、アノテーション範囲を画像の中央部分の 128×128 ピクセルとした。この場合、周辺画像は参考情報として与えられていることになる。周辺

の画像を含めることでアノテーション範囲内のわずかなひび割れも識別しやすくなると考えた。

また、各モデルは教師データ作成方法にも違いを持たせ、それら検証精度に差異があるか比較した。model1,2 は床板画像中のひび割れを人間の目でトレースした元画像をひび割れの有無の判定に使用した。model3 は床板画像を格子上に分割し、人の目でひび割れのあるマス目をクリックすることでラベリングできる専用アノテーションソフトを使用した。どのモデルも「ひび割れ有り」「ひび割れ無し」をアノテーションしたものを教師データおよび検証データとして使用した。

表-1 各 model の定義

モデル	アノテーション範囲	教師データ
model1	256pixel×256 pixel	トレース画像
model2	128 pixel×128 pixel	トレース画像
model3	128 pixel×128 pixel	専用アノテーションソフト




図-1 各 model のアノテーション範囲

表-2 各地域における床板画像の劣化の特徴

地域	ひび割れ	エフロレッセンス	スケーリング	汚れ	濡れ	剥離	チョーク	備考
中部	中	中大	中大	なし	小	小	なし	凍害によるスケーリングが顕著
北海道	大	中	中大	なし	中	なし	なし	凍害によるスケーリングが顕著、濡れ
北陸1	中	中大	小	なし	大	なし	あり	ASR単独
北陸2	中	小	なし	なし	なし	なし	あり	ASRと凍害の複合劣化
北陸3	小	小	なし	中	なし	なし	あり	蜘蛛の巣がかなりある。ひび割れとの判別が難しい
近畿	小	なし	なし	なし	なし	なし	あり	疲労ひび割れ初期、スペーサーの跡が見える
東北	中大	中	なし	なし	大	なし	あり	疲労によるひび割れ進行、濡れ・変色が顕著

3. 検証結果

各モデルの汎化性能を評価するため k-分割交差検証を行った。北海道、北陸-1、北陸-2、北陸-3、近畿、東北、中部の地域ごとにデータを7つに分割し、1つの橋梁を検証データにし、残りの6つの橋梁を学習データに用いて、計7回の検証を行った。検証結果を表-3~5に示す。転移学習モデルによる判別とアノテーション結果が一致した場合に正解とした。転移学習モデルがひび割れ有りと判別したもののアノテーションではひび割れ無しの場合を過検出、転移学習モデルがひび割れ無しだと判別したもののアノテーションではひび割れ有りの場合を見落としとした。

交差検証の結果、model1,2は80%に満たない正解であったが、model2では約90%の正解率となった。画像端部にひび割れがある場合の問題を回避することや、教師データ作成方法の違いにより判別精度を向上できることが示された。また、model2のアノテーション範囲も学習データから自動的に学習していると考えられる。地域ごとに着目するとmodel1,3においては北海道、北陸-3の過検出率や東北の見落とし率が顕著に高かった。特にmodel1の東北の床板画像は計4枚検証したが、2枚は正解率が50%を切り、残りは80%を超える結果となった。正解率の低い2枚の画像は、正解データのひび割れ有り判別が多く密集していることから、model1は密なひび割れを見落としやすい傾向にあると考えられる。またmodel3の北陸-3では微細な傷やクモの巣に反応して過検出率が非常に高くなる傾向が見られた。

4. まとめ

画像の中央部分でひび割れの有無をアノテートした学習データを作成することによって、アノテーション範囲の境界部分にひび割れがある場合の問題を解決でき、その結果、判別精度が向上できることが示された。また、教師データの作成方法も判別精度に影響があることが分かった。交差検証の結果、劣化機構の異なる場合においてもひび割れ判定精度が確保できることが示された。

5. 参考文献

- [1]道路の老朽化の現状 国土交通省：
<https://www.kkr.mlit.go.jp/road/maintenance/roukyu/genjyou.html>(2022/6/9)
- [2]道路橋定期点検要領 国土交通省：
https://www.mlit.go.jp/road/sisaku/yobohozen/tenken/yobo4_1.pdf(2022/6/9)
- [3]西尾真由子・栗栖雄一、橋梁点検部材損傷度判定CNNの可視化による判断根拠の理解と活用
AIデータサイエンス論文集、2020年1巻J1号

表-3 model1の交差検証結果

検証データ	正解率(%)	過検出(%)	見落とし(%)
北海道	66.97	26.22	6.78
北陸1	83.96	13.61	2.43
北陸2	85.59	6.76	7.65
北陸3	72.01	19.79	8.19
近畿	92.82	0.12	7.07
東北	65.46	3.77	30.77
中部	77.52	9.38	13.10
平均	77.76	24.45	10.86

表-4 model2の交差検証結果

検証データ	正解率(%)	過検出(%)	見落とし(%)
北海道	90.76	5.57	3.67
北陸1	95.53	3.42	1.05
北陸2	90.85	6.30	2.85
北陸3	83.94	12.36	3.69
近畿	96.55	0.30	3.16
東北	83.13	9.69	7.19
中部	87.30	8.98	3.72
平均	89.72	22.06	3.62

表-5 model3の交差検証結果

検証データ	正解率(%)	過検出(%)	見落とし(%)
北海道	75.83	22.08	2.08
北陸1	72.90	11.69	15.41
北陸2	72.76	23.91	3.33
北陸3	43.43	54.15	2.42
近畿	91.52	6.71	1.78
東北	63.25	16.32	20.43
中部	68.36	25.28	6.37
平均	69.72	26.06	7.40