

説明可能な AI とテクスチャ解析を用いたポットホール損傷評価手法の構築

A simple evaluation method for pothole damage by using explainable AI and texture analysis

室蘭工業大学創造工学科 ○学生員 石井啓介(Keisuke Ishii)
 室蘭工業大学大学院工学研究科 学生員 日原弘貴(Hirotaka Hihara)
 室蘭工業大学大学院工学研究科 正会員 浅田拓海(Takumi Asada)

1. はじめに

積雪寒冷地では、3、4月の融雪期にポットホール（以下、PH）が多発する¹⁾。車両通行部に発生し、損傷が大きくなった場合には、快適性に加えて安全性の面から迅速な補修が求められる。そのため、融雪期には巡回パトロールを高頻度を実施する必要がある。しかし、現状の巡回業務では、車内からの発見、路上での確認と補修、写真撮影、記録などの作業が繰り返し行われている。このように、PHの補修のための巡回業務には、安全面、コスト面、効率面において課題がある。このような背景から、昨今、ICTを用いたPH検知技術に関する研究が活発化している。例えば、スマホを活用した市民参加型の報告システムが開発されており、主に、生活道路におけるPHの発生状況の把握のために導入されている²⁾。幹線系道路では、一般市民による路面調査は難しいことから、車両に設置した加速度センサー等によるデータからPHを検知する技術が提案されている³⁾⁴⁾。ただし、これらの技術は、車輪通行部以外の検知は難しい。その解決として、画像を用いる方法があり、例えば、車載カメラで撮影した路面画像と深層学習を用いてPHの検知が行われている⁵⁾⁶⁾。深層学習手法としては、CNN（Convolutional Neural Network）やYOLO（You Only Look Once）が採用される場合が多い。

以上のように、幹線系道路においては、車載カメラと深層学習を組み合わせたPH検知技術の有効性が示されている。しかしながら、PHの迅速な点検、補修が必要となる融雪期の道路では、降雪、積雪、路面湿潤、日常的な補修など様々なノイズや状態変化が想定されるが、それらを考慮した検知技術はほとんどない。また、PH部の大きさや路盤材の露出のような損傷の度合いを把握することで、効果的な補修計画の策定が可能となるが、そのようなアプローチは検討されていない。一方、著者らは、市販のアクションカメラを用いた簡易型舗装診断技術の開発を進めており、現在、説明可能なAI（以下、XAI）を用いたひび割れ損傷判別手法⁷⁾を実装済みである。このXAIでは、CNNによる判別結果の根拠となる箇所を画像上に可視化できるCAM（Class Activation Mapping）が採用されている。これによりPH部を画像から抽出できれば、画像特徴量などからその損傷度を評価できると考えられる。

そこで、本研究では、車載カメラで撮影した路面画像にXAIとテクスチャ解析を適用することで、PH部の抽出および損傷評価を行う手法を構築する。また、本手法を実路線に適用して、その有効性を示す。



写真-1 本技術で撮影した画像と評価領域（13箇所）



写真-2 路上で撮影された画像と評価領域（3箇所）

2. 方法

2.1 データ

著者らが開発した簡易型舗装点検技術では、市販のアクションカメラ GoPro Hero6 を採用しており、走行しながら前方路面を動画撮影し、同時に取得したGPSデータから5m間隔で静止画（1920×1080px）を抽出する。また、著者らは、これまでに、本技術を用いて北海道内の一般国道、道道、市町村道の広範囲に渡って撮影を行ってきた。本研究では、これらの画像を用いて、CNNによる路面画像の判別モデルやPH部の損傷評価手法を構築する。CNNを適用する範囲として、写真-1に示すように、400×400pxの評価領域を13箇所設定し、これらを抽出してモデルの構築に使用する。

上記の撮影はほとんど夏季に行っているため、冬期における降雪、積雪、路面湿潤、日常的な補修など様々なノイズや状態変化が見られる画像はない。そこで、道路管理者のフィールド提供により、融雪期に路上で近接撮影されたPH補修前後の画像（508×360px）を入手した。写真-2に示すように、GoPro画像と路面範囲が同程度となるように評価領域（224×224px）を3箇所設定し、これらの画像をモデル構築に用いる。

2.2 CNNによる路面画像の判別

本手法では、まず、評価領域画像に CNN を適用して、「PH 有」「PH 無」「PH 補修後」の3クラスの判別を行う。CNNには、代表的なアーキテクチャである VGG16 を採用した。画像に教師ラベルを付けるため、目視でクラス分けをした。なお、この作業は、学生2名がクロスチェックしながら行った。その結果、「PH 有」が5,064枚、「PH 無」が3,750枚、「PH 補修後」が3,697枚、合計12,511枚の画像が得られた。次に、それぞれ7:3にランダムに分けて、前者を学習データ（「PH 有」3,545枚、「PH 無」2,625枚、「PH 補修後」2,588枚）、後者をテストデータ（「PH 有」1,519枚、「PH 無」1,125枚、「PH 補修後」1,109枚）とした。学習時には、ファインチューニングを適用し、全結合層のみで学習を行った。

2.3 CAMとGLCMによるPH部の損傷度評価

CAMは、CNNの判別根拠箇所に値を与えて可視化する手法であり、土木分野でも説明可能なAIとして導入ケースが増えている。本研究では、VGG16により「PH有」と判別された画像にCAMを適用することで、PH部を抽出できると考えた。PH部の発生位置や損傷度は、より詳細な補修計画の策定につながる。例えば、路盤材が見えるまでに損傷が進むと、車両だけではなく、歩行者や自転車の安全性にまで影響を及ぼす。また、損傷度が小さくても、連続的に発生している場合には、近い将来、甚大な損傷が発生する可能性がある。網羅的かつ高頻度で路面状態を把握することで、予防保全の対象区間の選定や優先順位付けに役立つと思われる。

具体的には、CAMにより抽出されるPH部に対して、テクスチャ解析を適用することで損傷評価を行う。代表的なテクスチャ解析手法として、同時生起行列（Gray Level Co-occurrence Matrix : GLCM）がある。GLCMでは、テクスチャの特徴を様々な指標で評価できるが、本研究では、表層剥がれや路盤材の特徴を定量化することを目的に、エントロピー⁸⁾を採用し、以下の手順で損傷評価を行う。

まず、評価領域画像に対して、3×3ピクセルのウィンドウサイズとして、ムービングウィンドウ方式で、GLCMを作成する。次に、各箇所のGLCMに対して、以下の式(1)により、エントロピーを算出する。

$$\text{エントロピー} = -\sum_i \sum_j P(i,j) \log P(i,j) \quad (1)$$

最後に、PH部のみのエントロピーの合計値（以下、 EN_{PH} ）を算出する。この EN_{PH} によりポットホール損傷度を評価できるのかを調べるために、目視評価結果との関係を分析した。この目視評価は、評価領域画像を見ながら、PH部の大きさや路盤材の露出量などを基に、損傷レベルを1~3の3段階で評価する。この損傷レベルの評価は、学生3名が行い、それらの平均値を以下の分析で用いる。



図-1 CNNのテスト結果の混同行列

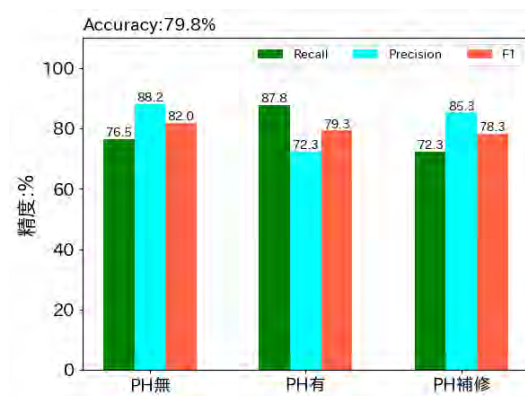


図-2 CNNによる路面画像の判別精度

3. 結果

3.1 路面画像の判別精度


学習済みのCNNモデルのテスト結果を混同行列として図-1に示す。また、この混同行列に基づいて算出した各種精度を図-2に示す。まず、全クラスの正解の割合を表すAccuracyは79.8%となった。次に、「PH有」の画像の見逃しの少なさを意味するRecallは87.8%、誤検知の少なさを示すPrecisionは72.3%を示した。誤検知があった画像を調べたところ、車や路面上の濃い影、湿潤箇所、汚損箇所を誤検知していたが、全体から見るとそのような誤検知は少ない。大部分を占めるのは、PHと補修跡が共に写っている場合であり、精度を下げる原因となっている。現在では、各精度が70%以上を超えているものの、改善の余地があることから、今後、より多くの画像を収集し、モデルの再学習を行う予定である。

3.2 PH部の損傷評価


CNNにより検知された「PH有」画像にCAMを適用した結果を図-3に示す。同図では、目視評価による損傷レベル毎に代表的な結果を示している。まず、全体として、PH部がその大きさや形状に合わせて抽出できていることがわかる。また、No.3, 7, 8のように、ポットホールが複数存在する場合もそれらが一体的に抽出されている。No.9においては、離れているポットホール

目視評価損傷レベル:1



No.1 : 184



No.2 : 110





No.3 : 112





目視評価損傷レベル:2



No.4 : 211



No.5 : 197




No.6 : 202




目視評価損傷レベル:3



No.7 : 551



No.8 : 332



No.9 : 382



左：CMによるPH部抽出判別根拠強度 右：画像特徴量による損傷度評価

図-3 ポットホール損傷評価の例

もそれぞれ抽出されている。

次に、目視評価による損傷レベル毎に EN_{PH} を見ると、損傷レベルが高いほど、 EN_{PH} が大きいことがわかる。目視評価では大きさも考慮しているため、エントロピーの合計値により、損傷レベルと相関する。また、PH部の大きさが同程度である No.3 と No.4 を比較すると、後者の方が表層の剥離が著しい。エントロピーは、多くの濃度値を持つ画素が存在する場合に大きくなることから、剥離の深さや路盤材の露出を評価できると言える。

これらの傾向が他の箇所でも見られるのかを調べるため、全画像の結果を用いて目視損傷レベル毎の EN_{PH} の関係を分析した。損傷レベル別の EN_{PH} のボックスプロットを図-4 に示す。損傷レベルが高くなるほど、 EN_{PH} の中央値が大きくなることがわかる。しかし、各損傷レベルでは、 EN_{PH} のばらつきが大きく、損傷レベルを精度よく推定することは難しい。今後は、多様な画像を収集し、CNN モデルの判別精度を向上されるとともに、様々な画像特徴量を導入して、PH 損傷度の推定精度を向上させる予定である。

3.3 実路線への適用

GoPro カメラで撮影した画像に本手法を適用し、その有効性を示す。撮影は、2022年3月に室蘭市内の一般国道で行った。まず、カメラ内蔵の GPS で取得した位置




図-4 推定値と目視評価の比較

情報を基に、撮影動画から 5m 毎に静止画を抽出した。次に、写真-1 に示したように、評価領域をスライドさせながら本手法を適用して、計 16 各レーンの EN_{PH} を算出した。ここでは、OWP と IWP の位置に注目するため、各位置に相当するレーンの EN_{PH} を分析に用いた。

対象区間における OWP と IWP における EN_{PH} のプロファイルを図-5 に示す。ここでは、撮影対象路線のうち、ポットホールが多く、損傷度が大きい区間を選出し




図-5 本技術の適用例

ている。対象の画像と図を見比べたところ、正しくポットホールを捉えられているものもあったが、落ち葉や影などを誤検知しているものもあった。実路線に適用するにあたって、主に誤検知に対しての精度を追求していく必要がある。

4. まとめ

本研究では、車載カメラで撮影した路面画像に説明可能な AI とテキスト解析を適用して、ポットホール部の抽出および損傷評価を行う手法を構築した。得られた結果を以下に示す。

- 融雪期に撮影した PH 補修前後の路面画像および本技術のカメラで撮影した多様な画像を用いて、「PH 有」「PH 無」「PH 補修後」の 3 クラスを判別する CNN モデルを構築した。テストの結果、正答率は 79.8% となり、「PH 有」の Recall は 87.8%、Precision は 72.3% を示した。
- 「PH 有」と判別された画像に CAM を適用して、PH 部を抽出し、さらに、同時生起行列特徴量に基づく平均エントロピー EN_{PH} を算出し、目視評価による損傷レベルとおおよそ相関することがわかった。
- 本手法を実路線に適用し、OWP と IWP における EN_{PH} のプロファイルを描いた。その結果、対象区間では、PH を正しく検知できたが、誤検知もあった。

今後は、ポットホール部のサイズ計測や路盤材露出度について定量的な検証を行う。課題は多いが、本手法を著者らが開発した簡易カメラ搭載型舗装点検技術に統合することで、融雪期の道路巡回の効率性、安全性の向上に寄与できる。また、日常的な測定データを集約し、都市、交通、道路、気象等の各種データと結合して時空間的な統計分析を行うことで、補修計画やライフサイクルコスト分析などを高度化できると考える。

参考文献

- 1) 丸山記美雄, 安倍隆二, 熊谷政行: 融雪期の舗装損傷発生条件に関する一検討, 平成 25 年度土木学会北海道支部論文報告集, No.70, 2017.
- 2) Kontokosta, C. and Hong, B.: Bias in smart city governance: How socio-spatial disparities in 311 complaint behavior impact the fairness of data-driven decisions, Sustainable Cities and Society, Vol.64, 2021.
- 3) 毅力果奇, 阿栄, 村上茂之, 佐々木博: スマートフォンによる路面性状の平坦性の簡易診断における SVM の適用可能性, 交通工学論文集, Vol.4, No.4, pp.1-10, 2018.
- 4) 窪田諭, 木下広翼, 丸山明, 村岡正, 中川均: 集配車両のセンシングデータを用いた舗装維持管理の提案, 土木学会論文集 E1, Vol.76, No.2, pp.I_133-141, 2020.
- 5) 佐藤公紀, 紺野康二, 高野淳, 長田隆信: 首都高におけるカメラ点検システムと AI 損傷自動検出を活用した巡回点検の高度化, AI・データサイエンス論文集, Vol.2, No.J2, pp.539-544, 2021.
- 6) 前田紘弥, 関本義秀, 瀬戸寿一, 檜山武浩, 小俣博司: 機械学習とスマートフォンを用いた道路の損傷画像のリアルタイム検出と修繕対応基準における各特徴量の重要度比較, 交通工学論文集, Vol.4, No.3, pp.A1-A9, 2018.
- 7) 長屋弘司, 浅田拓海, 亀山修一: 説明可能な AI を用いた舗装のひび割れ発生原因判別システムの開発, 土木学会論文集 E1, Vol.77, No.1, pp.28-38, 2021.
- 8) 三浦弘之, 翠川三郎, Soh Hui Chen: 2010 年ハイチ地震における被害地域検出のための高分解能衛星画像のテキスト解析, 日本地震工学会論文集, Vol.12, No.6, pp.6_2-6_20, 2012.