

畳み込みニューラルネットワークによる 道路舗装ひび割れの高解像度トレース手法の開発

Development of high resolution tracing method for road pavement crack by using convolutional neural network

室蘭工業大学工学部建築社会基盤系学科 ○学生員 平沢 一騎 (Kazuki Hirasawa)
室蘭工業大学大学院工学研究科 正員 浅田 拓海 (Takumi Asada)

1. はじめに

近年、インフラの老朽化、維持管理への関心が高まっております。道路舗装においては、地方部においても持続可能なメンテナンスサイクルの構築が喫緊の課題となっている。特に、維持管理の基本である点検業務は、その頻度増加とともに、低コスト化・簡易化が求められている。

高速道路における舗装点検では、路面性状測定車によりひび割れ、平坦性、わだち掘れの3つの路面性状が計測され、その総合指標（MCI：Maintenance Control Index：舗装の維持管理指数）から維持修繕の要否が判断している。このうち、ひび割れに関しては、撮影画像から手作業によるトレースを行っており、膨大な手間と時間を要することから、効率化、自動化が望まれている。また、一般道路に関しては、低コスト・簡易化を目的に車載カメラ画像からひび割れを解析する手法¹⁾が幾つか報告されているが、影やタイヤ痕などによるノイズの発生が指摘されている。

一方、昨今、画像認識技術において Deep Learning が着目されており、道路舗装のひび割れ診断においても一般道路（主に密粒度アスファルト舗装）の画像に適用した試みも幾つか報告されている。しかしながら、ひび割れの位置を 50cm メッシュほどの低解像度で把握する程度に留まっており、さらに、上記のようなノイズを解決した研究事例は見受けられない。また、詳細なひび割れトレースが必要となる高速道路舗装（排水性アスファルト舗装）への適用事例はほとんど見られない。

本研究では、路面性状測定車による高速道路路面画像と車載カメラによる一般道路路面画像を対象とした、Deep Learningによる高解像度なひび割れトレース手法を開発する。具体的には、画像認識に強いと言われている CNN（Convolutional Neural Network：畳み込みニューラルネットワーク）によるひび割れ認識を行い、入出力領域の大きさ（解析サイズ）や路面画像上の可視化方法について検討し、本手法の有用性や課題について整理する。

2. 路面画像データの概要

本研究では、路面性状測定車の電子ストリークカメラにより撮影された高速道路の路面画像（以下、ストリーク画像）と車載カメラによって撮影された一般国道の路面画像（以下、車載カメラ画像）を用いる。

ストリーク画像は、20m 区間/車線を 1 枚（18000×4096 ピクセル）とし、本研究では、ひび割れのある区間の画像 4 枚を分析に用いる。元の路面画像に加え、従事者によるひび割れトレース画像（元画像にペン入れを重ねた画像）があることからこれを教師データに用いる。

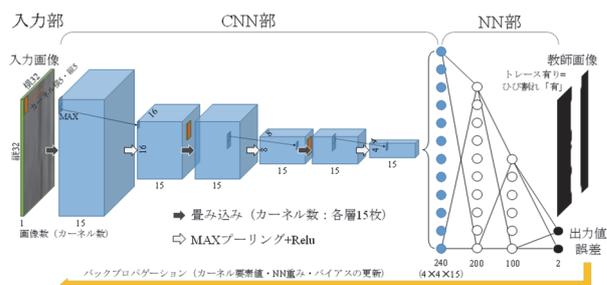


図-1 モデル構成（解析サイズ 32 の場合）

車載カメラ画像については、車両後部に設置した市販の 4K アクションカメラによって走行しながら撮影した動画を用いる。なお、解析のために、動画から 10m 間隔で静止画を切り抜き、さらに、アフィン変換²⁾により真上から捉えた画像（3750×6262 ピクセル）を 100 枚作成した。教師データに関しては、従事者の指示の下で、学生がひび割れをトレースした画像を用いる。

3. CNNによるひび割れトレース手法

(1) CNNの概要

本研究では、高解像度のひび割れトレースを行うことを目的とし、CNNにより路面画像における小片領域毎にひび割れ有・無の判別を行う。CNNは、通常のニューラルネットワーク（NN）の前に、画像への2次元フィルタ（畳み込み）と画像圧縮（プーリング）を行う層を複数設定する。この畳み込み層とプーリング層により、画像の特徴を抽出するパラメータを学習し、その特徴ベクトルをNN層に渡して多クラス判別が行われる。

通常のNNでは、画像をベクトル化することで適用が可能となるが、例えば、認識すべき視対象（例えば文字）が1ピクセルでも移動すると、同じ視対象でも全く違うものとして処理される。CNNでは、畳み込みとプーリングによって視対象の位置関係を曖昧化することで、上記のような位置ズレによる影響が低減される。すなわち、人間の視覚と同様に曖昧さを考慮して視対象の認識、判別が実現できるため、高精度となることが知られている。

(2) モデルの学習および精度検証

本研究で検討するモデルの構成を図-1に示す。CNN部は、畳み込み→MAXプーリングを3回繰り返す層構成とした。畳み込みのカーネル（2次元フィルタ）は、全ての層で5×5ピクセルを15枚設定した。MAXプーリングは、4画素の最大値を1画素に圧縮する方法である。したがって、最終的には入力画像からサイズ（一辺

のピクセル数)が $1/2^3$ にまで圧縮される。なお、活性化関数は全て Relu である。NN 部は 2 層、それぞれ 200, 100 ユニットで構成し、出力値 (Softmax 関数適用値) はひび割れ有・無の 2 ユニットとなる。パラメータ更新の最適化手法には Adam を採用する。ミニバッチ学習を採用し、バッチ数は 100, エポック数は 2000 とした。

本研究では、入力画像サイズ (解析サイズ) を 32×32 , 64×64 ピクセルの 2 段階でそれぞれ学習を行い、精度比較に加え、路面画像上での高解像度なひび割れトレースに適したサイズを検討する。画像種類、解析サイズ毎の学習、テスト用のデータセットを以下の方法で構築した。まず、ひび割れトレース後の路面画像により、ひび割れを含む、含まない小片領域をランダムにそれぞれ 12,000 箇所抽出する。元画像、トレース画像から抽出したものをそれぞれ入力用、教師用 (ひび割れ有・無の 2 値に変換) に分け、それらの中でひび割れ有・無の枚数はそれぞれ 3000 枚とした。

各モデルの学習過程を図-2 に示す。車載カメラ画像では、解析サイズ 32, 64 で約 90% まで精度が増加し、学習の収束が見られる。しかし、ストリーク画像では、精度増加は見られるが、学習回数 2000 回では不足であった。学習後モデルによるテスト結果を図-3 に示す。車載カメラ画像では全解析サイズにおいて判定精度が約 90% となった。ストリーク画像では 70% 程度と低く、ひび割れの見逃し (観測有・予測無) が 20% 程度見られた。排水性舗装では、目地が荒く、目視でもひび割れ判定が難しいことから、別のアプローチが必要と考えられる。

(3) 路面画像上でのひび割れ高解像度トレース

車載カメラ画像のモデルでは高い精度が得られた。そこで、このモデルを路面画像上にスライドさせながら適用し、ひび割れを高解像度、高精度で抽出する手法を提案する。スライド量は解析サイズの $1/4$ ピクセルとし、ひび割れ有の場合に出力値の $1/16$ を当該領域に加算していく。本手法の適用結果を図-4 に示す。赤部は本手法、黒線は目視トレースの結果である。サイズ 32 で細かく拾い過ぎるためノイズが目立つが、サイズ 64 では精度良く描画された。また、街路樹等の影に影響されず、目視トレースで見逃した部分も抽出されている。

以上のように、解析サイズやスライド量が適切であれば高い精度が得られることが分かった。今後は、上記を踏まえて各種パラメータを見直し、トレース精度を向上させるとともに、解析コスト低減などの改善を加える。

4. まとめ

本研究では、2 種類の路面画像を対象に、CNN によるひび割れの高解像度なトレース手法について検討した。車載カメラ画像 (密粒度舗装) では、ノイズを含む低品質な画像であるが、路面画像上に高解像度、高精度でひび割れを描画できることを示した。一方、路面性状測定車によるストリーク画像では、排水性舗装の目地が荒いことなどが原因となり、精度が得られず、見逃しが多くなる。これについては、今後、トレース結果に頼らない教師無し学習モデル、例えば Auto Encoder と CNN の組み合わせモデルによる特徴量抽出を行い、画像類型化のアプローチについて研究を進める予定である。

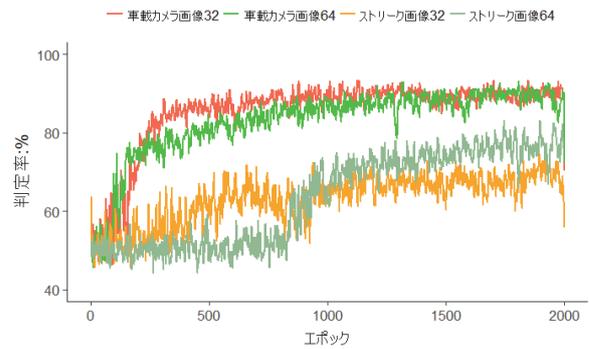


図-2 各画像、解析サイズにおけるモデル学習過程

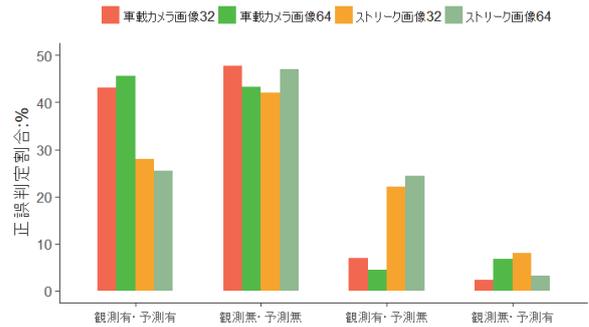


図-3 各画像、解析サイズにおけるモデルテスト結果

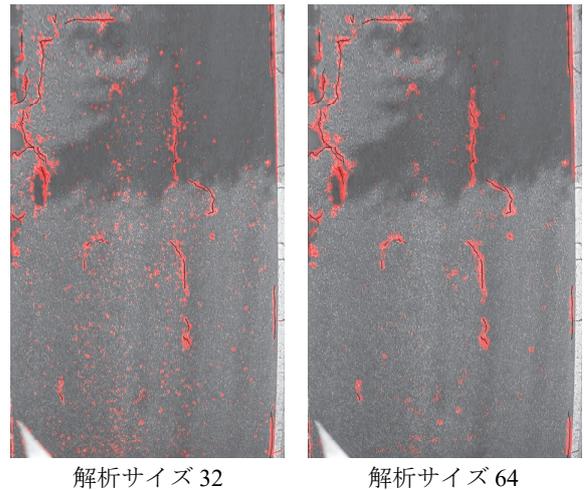


図-4 ひび割れの高解像度抽出 (車載カメラ画像)

謝辞：路面性状測定車による路面画像は、中日本高速道路株式会社から提供いただいた。車載カメラ画像は、株式会社サントップテクノから提供いただいた。ここに記して感謝の意を表する。

参考文献

- 1) 浅田拓海, 亀山修一, 川端伸一郎, 佐々木克典: 走行車両から撮影した路面画像を用いた舗装のひび割れ評価手法の開発, 土木学会論文集 E1 (舗装工学), Vol.70, No.3 (舗装工学論文集第 19 卷), I_9-I_16, 201411.