

深層学習を用いた道路区画線の剥離率推定手法の開発

Development of estimation method of the stripping ratio of road markings using deep learning

室蘭工業大学建築社会基盤系学科
室蘭工業大学大学院工学研究科

○学生員 岡部里音 (Rion Okabe)
正会員 浅田拓海 (Takumi Asada)

1. はじめに

道路区画線は、交通の安全・円滑に資するために、路面上にペイントで描かれた記号や文字による標示を指し、道路法では、「道路の構造を保全し、又は交通の安全と円滑を図るため、必要な場所に区画線を設けなければならない」とされている。区画線の主な種類としては、車道中央線、車道外側線、路側帯等の種類がある。区画線は車両通行、冬季の融雪、除雪作業によって汚損、摩耗、剥離などの損傷が生じることがあり、視認効果が大きく低下するため、定期的な点検と塗り直しが必要となる。

近年、公共事業費の削減、土木技術者の減少が問題視され作業の効率化、経費の削減が土木事業全体の課題であり、区画線補修業務も例外ではない。そこで、著者らは、過去の研究において、デジタルカメラで撮影した路面画像から画像特徴量を算出し、それらを用いて区画線の剥離率を推定する重回帰モデルを開発した。しかしながら、このモデルでは、誤差が大きくなるケースがあり、画像特徴量の再設定や教師データの追加には、大きな手間と時間を要する。

そこで、本研究では、最適な特徴量を抽出でき、高い精度が期待できる深層学習の代表モデルである CNN (Convolutional Neural Network: 畳み込みニューラルネットワーク) を導入し、道路区画線の剥離率を推定する手法を構築する。

2. データと方法

2.1 路面画像の撮影

本研究では、著者らがこれまでの研究で開発した簡易カメラ搭載型の路面調査システムを用いて、路面画像を撮影する。本システムでは、市販の小型アクションカメラを車両ボンネットに設置し、走行しながら前方路面を撮影する。カメラには、GoPro Hero6 を採用し、内蔵の GPS で走行中の位置情報を取得した。画像サイズは 1920×1080 ピクセル、動画のフレームレートは 60fps、画角は「広角モード」とした。位置情報を基に、動画から 5m 間隔で静止画（路面画像）を抽出した。以下のモデル学習とテストのために、著者らがこれまでに撮影した道内一般国道における画像から 910 枚を選出した。

2.2 評価領域の抽出

本研究では、先行研究と同じように、路面画像にある区画線の局所的な箇所（評価領域）から剥離率を推定する。評価領域の抽出手順を図-1 に示す。まず、ヒストグラム平坦化によって、画像のコントラストを調整する。次に、路面画像から解析領域（ 900×480 ピクセル）をトリミングする。その解析領域にテンプレートマッチング法（以下、TM 法）を適用して、テンプレート画像（以下、T 画像）と相関が高い箇所から評価領域（ 80×80 ピ




図-1 評価領域の抽出手順




図-2 2 値化処理による剥離率の算出

クセル) を抽出する。T 画像は剥離が全く生じていない状態を示していることから、TM 法によって、解析領域の中で区画線の損傷が最も小さい領域が抽出される。

2.3 従来の 2 値化処理による剥離率

従来の方法では、濃度画像を用いた 2 値化処理によって、区画線の剥離部と残留部を分離し、塗布領域に占める剥離部の割合から剥離率が算出される。そこで、本研究では、テストに使用する正解値のために、図-2 に示す手順で 2 値化処理を行った。まず、評価領域の区画線に直線（図中赤）を引き、塗料の塗布領域を設定する。その塗布領域内で、区画線の剥離部と残存部を分離し、剥離率を求める。なお、閾値は、元画像を見ながら、剥離部と残存部を適切に分離できるように調節した。

2.4 CNN モデルの概要

先行研究では、図-2 に示した 2 値化処理によって剥離率を算出し、教師データに用いていた。しかし、2 値化の閾値の調整は目視で行うため、大きな時間と手間を要する。そこで、より簡易な方法として、目視により、剥離率 10% 刻み（階級値 $c=0,10,\dots,90$ ）で仕分けする方法を考えた。すなわち、剥離率 0~100% の回帰モデルではなく、「例外 (TM で検出された区間線以外の画像)」を含めた 11 クラスの判別モデルを構築する。

モデルの層構成として、畳み込み層とプーリング層にそれぞれ4層を設定した。また、畳込み後には、過学習抑制のため、Batch Normalization を行い、中間層の活性化関数には Relu, 出力層には softmax 関数を採用した。学習では、バッチ数を 100, エポック数を 100 とした。学習には、800 枚の路面画像から抽出した評価領域画像を用いる。

このモデルでは 11 クラスの判別結果が得られる。しかし、実務の面から考えると、出力としては剥離率 0~100%の連続値が望ましい。そこで、softmax 関数により出力された各クラスの確率値 p と階級値 c の内積を算出することで、剥離率を連続値で出力することとした。なお、「例外」クラスは、上記の計算から除外している。

3. 本モデルの精度と有効性

3.1 精度検証

本手法による剥離率の推定精度について検証する。テストには、学習に用いた画像以外の 110 枚を使用した。図-2 に示したように、2 値化処理による剥離率を正解値に用いる。本手法による推定値と 2 値化処理による正解値の関係を図-3 に示す。誤差の大きい値がいくつか見受けられるものの R^2 は 0.97 で、両者はほぼ 1 対 1 の関係となった。また、平均 2 乗誤差 $RMSE$ は 4.63% となった。以上から、本手法の精度は高く、実用化も検討できる段階であると言える。

3.2 一般国道への適用

本手法を一般国道へ適用した例を紹介する。本手法では、まず、車載カメラを一般車両に設置し、走行しながら動画撮影して、5m 間隔で抽出した静止画から剥離率を推定する。位置情報が対応していることから、図-4 に示すように、結果をマップ上に可視化できる。なお、「例外」と判別された箇所は除外している。各プロット点には、路面画像へのリンクも貼っており、目視で確認も可能である。本手法を用いることで、道路区画線の剥離率評価を迅速かつ精度良く実施できる。網羅的なデータを揃えることができれば、補修（塗り直し）の優先順位付けなどに有効である。

4. まとめ

本研究では、市販の車載カメラで撮影された路面画像に深層学習（CNN）を適用し、道路区画線の剥離率を推定する方法を開発した。学習データセットの構築を簡素化するために、CNN は判別モデルとし、目視により剥離率 10%刻みでクラスラベルを付ける方法を取り入れた。さらに、各クラスの出力量（確率）と階級値の内積から剥離率を連続値として出力した。その結果、予測値と正解値の R^2 は 0.97, $RMSE$ は 4.67% となった。

今後は、判別クラスを剥離率 20%刻みの 5 段階にして学習データセットの構築をさらに簡素化する予定である。本手法は、道路区画線の昼間視認性を考慮したものであるため、反射材による夜間視認性の評価は難しい。夜間における撮影を試み、路面照度を考慮した夜間視認性評価手法についても検討したい。




図-3 予測値と正解値の関係




図-4 一般国道への本手法の適用例

参考文献

- 1) 浅田拓海・本多誠司・亀山修一：画像特徴量を用いた道路区画線剥離率推定法の開発，土木学会論文集 E1（舗装工学），Vol.67, No.1, pp.10-21, 2011.
- 2) 浅田拓海・亀山修一：走行車両から撮影した画像を用いた道路区画線診断方法の開発，土木学会論文集 D3（土木計画学），Vol. 68, No. 4, pp.358-368, 2012.