

深層学習を用いた道路舗装種別の画像判定技術に関する基礎的研究

(株) 建設技術研究所 (元東京都市大学) 正 会 員 ○宇都宮 優喬
 法政大学 正 会 員 今井 龍一
 大阪経済大学 正 会 員 中村 健二
 摂南大学 正 会 員 塚田 義典
 日本工営 (株) 正 会 員 秋山 成央
 東芝インフラシステムズ (株) 正 会 員 熊倉 信行

1. はじめに

我が国では、専用機器または目視により道路の舗装種別毎の構造特性を踏まえた舗装点検¹⁾が実施されており、多くの費用や時間を要している。その対策として、近年、車両に取り付けた市販カメラで撮影した路面画像(以下、「車載カメラ画像」とする。)に深層学習を適用したひび割れ検出²⁾や加速度計を用いた平坦性を評価するIRI計測³⁾等の簡易的な道路維持管理の研究が進められている。しかし、これらの技術は舗装種別を考慮せずに、排水性舗装と密粒舗装との場所に対して同様のアルゴリズムを適用するため、誤判定や誤検出につながる可能性がある。解決策として、道路舗装種別の自動判定技術が挙げられるが、先行研究は見当たらない。

本研究の目的は、深層学習を用いた道路舗装種別の画像判定技術の開発とした。まず、深層学習を適用した画像処理技術を選定する。次に、車載カメラ画像から教師データを作成する。最後に、道路舗装種別を判定する学習モデルを構築し、その有用性を検証する。

2. 道路舗装種別判定の学習モデルの構築方法の選定

本章では、車載カメラ画像を用いて道路舗装種別を判定するための深層学習の手法を選定する(図-1参照)。

(1) 道路舗装種別判定の処理フロー

図-1は、車載カメラ画像を用いた道路舗装種別判定の全体像を示している。舗装種別情報および車載カメラ画像から教師データを作成し、道路舗装種別を自動で判定する学習モデルを構築する。そして、新たに撮影した画像を学習済モデルに入力すると、舗装種別の推定結果が出力される。本研究で推定する舗装種別は、排水性、密粒およびその他の3種別とした(図-2参照)。本稿は、排水性および密粒舗装の検証結果を報告する。

(2) 深層学習を用いた画像処理技術の選定

深層学習を用いた画像処理技術は、主に表-1に示し

た3手法に分類される。Classificationは、路面の画像を舗装種別毎にラベル付けして分類できる。Detectionは、対象物を矩形で検出するが、舗装面以外の物体を学習する恐れがある。Semantic Segmentationは、画像内の舗装面の領域を画素単位で判定できる。以上より、本研究では、道路舗装面を対象に判定できるClassificationおよびSemantic Segmentationを採用した。

3. 道路舗装種別判定の有用性の検証

本章では、作成した教師データに対してClassificationおよびSemantic Segmentationを適用し、道路舗装種別判定の有用性を検証した。

(1) 教師データの作成条件

車両後方部に取り付けた車載カメラ(ビデオカメラ・アクションカメラ)で撮影した動画を教師データとした。教師データは、晴れの日東北地方や関東地方の国道および県道の一部区間で撮影した動画から作成した。

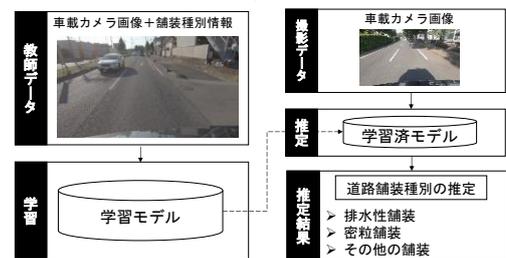


図-1 道路舗装種別判定の全体像

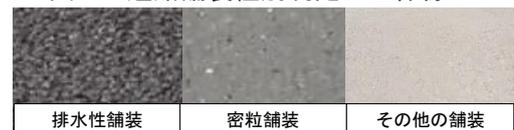


図-2 道路舗装種別のイメージ

表-1 深層学習を用いた画像処理技術

手法	Classification (画像分類)	Detection (物体検出)	Semantic Segmentation (画像領域分割)
	路面状態を分類	車両と人々を検出	道路上の対象物を領域指定
イメージ			
説明	指定されたクラスに対して画像が何かを識別する手法	画像内のどこに何の対象物があるのかを識別する手法	画像内の物体を画素単位で識別する手法
ネットワーク	CNN	R-CNN, SSD, YOLO	FCN, SegNet, UNET

キーワード 深層学習, 道路舗装種別, 画像処理技術, Classification, Semantic Segmentation

連絡先 〒103-8430 東京都中央区日本橋浜町 3-21-1 日本橋浜町Fタワー 株式会社建設技術研究所 TEL.03-3668-0451

Classification では、排水性舗装の画像および密粒舗装の画像をフォルダで分類した。Semantic Segmentation では、領域指定プログラムを開発し、画像の道路路面領域を手作業で舗装種別毎に指定した。この際に、領域指定する対象物は、排水性舗装、密粒舗装およびその他の舗装の3クラスとし、特定部分を色付けて抽出するマスク画像で出力した。

(2) 学習モデル

本研究で適用した Classification のネットワークは、特徴を抽出する畳み込み層を16層、全結合層を3層持った畳み込みニューラルネットワーク (CNN) である VGG19 を模倣して構築した。Semantic Segmentation のネットワークでは、VGG19 より畳み込み層が3層少ない VGG16 のモデルの一部を特徴情報の抽出に利用した SegNet を模倣して構築した。

入力チャンネル数は、識別する特徴を多く認識させるため、3チャンネル (RGB) に設定した。学習回数は、最大 2,000 回とし、学習モデルの出力結果と正解との誤差を算出した数値である損失関数が一定となり、識別精度が高い時点の学習回数を用いた。

(3) 検証方法

Classification では、画像サイズおよび画像変換の精度を検証した。画像サイズは、撮影した 1,920×1,080pix の画像を異なるサイズに変換した。画像変換は、左右反転のケースおよびコントラスト変換のケースである。

Semantic Segmentation では、出力したマスク画像の中で、画素の割合が最大となる舗装種別を判定した。

評価方法は、適合率、再現率および F 値を用いた。適合率は、学習モデルが予測したデータのうち実際に正解であるデータの割合である。再現率は、正解であるデータのうち学習モデルでも正解と予測した割合である。F 値は、適合率および再現率の調和平均の算出結果であり、1.00 に近いほど高い識別精度であると評価する。

(4) 検証結果

Classification における画像サイズの検証は、フル HD の画像を 512pix 四方および 1,080pix 四方に変換した画像のケースが高精度に識別できた (表-2 参照)。左右反転は、識別精度に影響を与えないと確認できた。また、コントラスト変換は、学習に失敗して損失関数が大きくなり、識別精度が収束せずに発散した。そのため、画像変換では、教師データを必要以上に変換してしまうと、学習結果に悪影響を及ぼす可能性があることを確認した。Semantic Segmentation では、排水性舗装および

密粒舗装の検証データに対する F 値が 0.98 以上と高精度に識別できた (表-3 参照)。

以上より、両手法で識別精度を示す F 値が 0.90 以上であるため、道路舗装種別判定モデルの有用性の一端を確認できた。両手法を比較した結果を表-4 に示す。

表-4 より、同精度かつ低コストで教師データを作成できる Classification が道路舗装種別の判定に適していると考えられる。また、Semantic Segmentation では、舗装に加えて、道路標示やひび割れ等の対象物を抽出するため舗装種別毎の劣化検出等の活用が期待できる。

4. おわりに

本稿は、深層学習を用いて車載カメラ画像から道路舗装種別を判定する学習モデルの有用性を検証した。

今後の課題として、様々な撮影条件の影響度等を踏まえた精度検証や劣化検出手法の確立が挙げられる。

謝辞: 本研究を遂行するにあたり、文教大学の櫻井淳氏、関西大学大学院の中原匡哉氏には貴重なご意見を賜った。ここに記して感謝の意を表する。

参考文献

- 1) 国土交通省：舗装点検要領，2018。
- 2) 熊倉他：舗装ひび割れ簡易可視化ツールの開発，第73回年次学術講演会，土木学会，No.CS9-035，2018。
- 3) 藤田他：簡易平坦性測定および GIS に基づく市街地道路の路面モニタリング，土木学会論文集 F3(土木情報学)，土木学会，Vol.69，No.2，pp.I_90-I_97，2013。

表-2 学習結果 (Classification)

検証項目	ケース	学習回数	損失関数 (%)	舗装種別	教師データ			検証データ		
					適合率	再現率	F値	適合率	再現率	F値
画像サイズ	96pix 四方	250	0.38	排水性	0.96	0.85	0.90	0.93	0.86	0.90
				密粒	0.87	0.97	0.92	0.87	0.94	0.90
	256pix 四方	150	0.16	排水性	0.99	0.97	0.98	0.92	0.93	0.93
				密粒	0.97	0.99	0.98	0.93	0.92	0.93
	512pix 四方	330	0.06	排水性	0.99	1.00	0.99	0.94	0.96	0.95
				密粒	1.00	0.99	0.99	0.96	0.94	0.95
768pix 四方	230	0.04	排水性	0.97	1.00	0.98	0.89	0.97	0.93	
			密粒	1.00	0.97	0.98	0.96	0.88	0.93	
1,080pix 四方	200	0.07	排水性	0.99	1.00	0.99	0.93	0.97	0.95	
			密粒	1.00	0.99	0.99	0.96	0.93	0.95	
画像変換	変換なし	140	0.14	排水性	0.98	1.00	0.99	0.94	0.96	0.95
	左右反転	140	0.21	排水性	1.00	0.98	0.99	0.96	0.94	0.95
				密粒	0.97	0.99	0.98	0.92	0.96	0.94
	左右反転+コントラスト変換	発散			排水性					なし
				密粒						

表-3 学習結果 (Semantic Segmentation)

舗装種別	学習回数	損失関数	教師データ			検証データ		
			適合率	再現率	F値	適合率	再現率	F値
排水性	36	0.12	0.99	1.00	0.99	0.96	1.00	0.98
密粒			1.00	0.99	0.99	1.00	0.95	0.98

表-4 手法の比較

分類	項目	Classification	Semantic Segmentation
コスト面	教師データ作成時間 (1枚当たりの作成時間)	5秒未満	約10分
	学習時間 (学習回数1回当たりの時間)	0.52秒	14.2秒
	判定時間 (1枚当たりの時間)	※教師データ4,400枚	※教師データ600枚
	マシンスペック	低～中	中～高
利活用面	舗装種別 (排水性、密粒)	判別可	判別可
	その他地物 (ひび割れ、白線および車両等)	適用不可	適用可
	その他の舗装種別	適用可	適用可
	手法の拡張性	一部有	有