

深層学習による路面ひび割れ状況の把握に向けた基礎検討

20T0217A 西川 三香子
指導教員：丸山 喜久，劉 ウェン

1. 研究背景と目的

我が国では近年、道路の老朽化が深刻化している。現在使用されている道路施設の多くは、高度経済成長期に建設、整備されたもので、2032年には建設後50年を経過する道路施設が全体の60%に達する¹⁾。そのため、物流等の輸送の安全・安定を維持するためには保守作業が必要である。ひび割れ率の詳細な評価には、路面性状測定車での測定が挙げられるが、その費用は高額である。またひび割れ率の評価は目視による確認やスケッチ等の作業が必要であり、これらの作業には、莫大な時間と人手が必要である²⁾。

深層学習は、特に画像認識の部分で利用されており、精度・処理速度ともに従来の機械学習を上回る結果を記録している³⁾。深層学習を用いて画像から路面のひび割れ状況を把握できれば、客観的評価や人員・コストの削減が可能になると考えられる。

そこで本研究では、車載カメラで撮影した路面画像を用いて深層学習を行い、路面のひび割れ状況を把握できる画像判別モデルを構築した。さらに、このモデルを用いて路面のひび割れ率を算出し、それらと実際の路面のひび割れ率の関係性を考察した。

2. 対象地域と使用画像データ

本研究の対象地域は、福岡県直方市道20区間（総距離10.28km）、東京都調布市道32区間（総距離14.31km）であり、撮影総距離は24.59kmである。

鹿島道路株式会社の路面性状測定車によって5m間隔の路面画像の撮影と、10m間隔の路面ひび割れ率の測定を行った。この測定車で撮影された画像は、対向車や沿道の壁などが映り込んでいるため、左右の歩道や前後の写真で重複した部分が映らないように考慮した。素画像の1920px×1080pxのうち、図-1のように990px×440pxの範囲でトリミングをした。その後、画像を110px×110pxの大きさに格子状に分割し正規化を行った（図-2）。



図-1 福岡県直方市下新入
58号線 450m地点




図-2 110px 四方に分割

路面性状測定車で測定されたひび割れ率を参考に、

画像の目視判別を行い、ひび割れの有無で2クラスにラベル付けした。ひび割れ率の算出については、本来は0.5m²メッシュ内にひび割れが1本、または2本以上かで分類し計算を行う⁴⁾が、本研究でのラベル付けでは1本以上でひび割れありと判断した。

本研究では、合計7005枚の分割した路面画像を、ひび割れありとなしを目視判別でラベル付けした。画像は6:2:2の割合で訓練データ、検証データ、テストデータとし、モデルの学習と汎化性能の確認を行った。データセットの内訳は、表-1の通りである。

表-1 データセットの内訳

	ひび割れあり	ひび割れなし
訓練用画像[枚]	1540	2600
検証用画像[枚]	690	690
テスト用画像[枚]	746	739

3. 深層学習手法とネットワークの構造

本研究では、深層学習の中でも画像認識で広く使われているCNN（Convolutional neural network）を用いる。CNNは特徴を抽出する畳み込み層と、出力した特徴マップのサイズを削減し計算量を減らすプーリング層を階層化した構造のネットワークである⁵⁾。本研究では、VGG16⁶⁾をCNNとして使用する（図-3）。また使用したネットワークのハイパーパラメータを表-2に示す。




図-3 本研究で用いたVGG16ネットワーク

表-2 ハイパーパラメータの詳細

活性化関数	RuLU 関数
	sigmoid
最適化アルゴリズム	Adam
学習率	0.0001
ミニバッチサイズ	32
損失関数	Binary_crossentropy
最大エポック数	50
Dropout rate	0.1
Weight decay	0.001

4. 学習結果と評価

(1) 指標による評価

図-3 に示したネットワーク構造と表-2 に示したハイパーパラメータに基づき、学習を行った。なお訓練データを学習させる際、画像の回転処理を行い画像の枚数を4倍に拡張した。

モデルの学習結果として、50 エポックまでの中で検証データの損失関数が最小となった時の正解率と損失関数値を表-3 に示す。また、表-3 に示したエポック数まで学習を行ったモデルの重みを用いてテストデータで評価した結果を混同行列で表-4 に、性能評価指標で表-5 に示す。

表-3 学習結果

エポック数	正解率	損失関数値
14	0.9906	0.0258

表-4 混同行列

		予測結果	
		ひび割れあり	ひび割れなし
実際の結果	ひび割れあり	681	65
	ひび割れなし	4	735

表-5 性能評価指標

正解率	適合率	再現率	F 値
0.9535	0.9941	0.9128	0.9517

(2) 判別結果の一例

判別機器がどのように路面画像を判別したかを図示し、実際のひび割れ率と深層学習を用いたひび割れ率を比較する。なお、深層学習を用いたひび割れ率は、全画像数に対して判別機器がひび割れありと予測した画像の割合で算出する。

図-4 に分類結果の一例を示す。画像内でひび割れがあるグリッドは赤、ひび割れがないグリッドは青で表示されていると、正しく判別できている。誤判別は3か所で、正解率は91.6%と高い数値を示した。実際のひび割れ率は23.1%であるのに対し、深層学習を用いたひび割れ率は33.3%となった。




図-4 判別例1の結果

鹿島道路データ 調布市エリア 01-5 190m 地点

5. ひび割れ率に関する考察

図-5 に、実際のひび割れ率と本研究で推定したひび

割れ率の関係を示す。実際のひび割れ率が40%以下の場合には相関係数が0.663となり、正の相関を示す。このことから、これらの範囲のひび割れ率は、本研究の手法で十分推定可能と考えられる。

一方、実際のひび割れ率が40%以上のとき、ひび割れ率が高いにもかかわらず、深層学習によるひび割れ率が低くなってしまう場合がある。この範囲の結果では、相関係数は0.315となる。本研究の画像分類では、ひび割れの有無しか判別できないため、1つのグリッドにひび割れが集中していると、実際のひび割れ率を過小評価してしまう可能性があることが影響している。




図-5 ひび割れ率と深層学習によって推定されたひび割れ率の関係

6. まとめ

本研究では、CNN を用いて路面ひび割れ状況の把握に向けた基礎検討を行った。今回構築したモデルによって、ひび割れありの画像とひび割れなしの画像を95%の精度で判別することができた。しかし、実際のひび割れ率と深層学習を用いたひび割れ率を比較すると、実際のひび割れ率が40%以上となると、推定されたひび割れ率の精度が低い場合も見られた。今後はグリッドの分割をさらに細かくするなどして、精度の向上を図る必要がある。

REFERENCES

- 1) 国土交通省：老朽化対策の取り組み, <https://www.mlit.go.jp/road/sisaku/yobohozen/torikumi.pdf>
- 2) 国土交通省：車両用ビッグデータを活用した路面性状調査, https://www.mlit.go.jp/road/ir/ir-council/keizai_senryaku/pdf/r3_85.pdf, 2022.
- 3) Francois Chollet：Python と Keras によるディープラーニング, マイナビ出版, 2019.
- 4) 大阪府：道路施設点検要領, https://www.pref.osaka.lg.jp/attach/28101/00000000/070_hosou_honpen.pdf, 2016.
- 5) 谷岡広樹：いちばんやさしい ディープラーニング 入門教室, ソーテック社, 2018.
- 6) Simonyan, K. and Zisserman, A.: Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556, 2014.