# 道路画像の深層学習に基づく路面ひび割れ状況の把握に向けた検討

## DETECTION OF ROAD CRACKS BASED ON DEEP LEARNING OF IMAGES CAPTURED FROM A VEHICLE

19WM1301 古市 直也 Naoya Furuichi 指導教員 丸山 喜久

## SYNOPSIS

Currently, visual discrimination and handwritten records are used to evaluate road cracks. In order to reduce the cost of road maintenance and the burden of inspectors, it is required to develop an easy method for evaluation of road surface condition. In this study, we developed an image classification model to detect road cracks based on deep learning of images captured by a vehicle-mounted camera. We used Caffe, a proven framework in the field of image recognition, as the framework for deep learning, and CNN (Convolutional Neural Network) as the network structure. We tested the accuracy of the image classification model using test set which were not used for training and validation of the model, and achieved an accuracy of over 70%. Furthermore, a pseudo-road-crack rate was calculated, and visualized to evaluate road surface condition by displaying it on a map using GIS.

1. はじめに

我が国で現存する社会基盤施設は主に高度経済成長期に 整備されており、2033年には建設から50年を経過する道路 施設が全体の半数に達する<sup>1)</sup>.しかし、路面性状測定車での 測定は費用が高額であり<sup>2)</sup>,保守作業の質が道路管理者の 予算に依存している.さらに、ひび割れ率の評価には目視 による判断やスケッチ等の膨大な作業が課せられており、 これらの方法は客観的な判断が困難である上に、多くの時 間を費やしている.

近年,人工知能が注目されるなど,深層学習の研究が盛 んである.画像,動画認識の分野で利用されている深層学 習<sup>3)</sup>を用いて画像から路面状況を評価することで,客観的 な路面性状評価を実現するだけでなく,道路維持管理のコ スト削減や検査員の負担を軽減することができると考えら れる.

そこで、本研究では車載カメラが撮影した路面画像を用 いて、ディープラーニングによる画像判別モデルを構築し た.さらに、この画像判別モデルを用いて、学習に使用し なかった未知の画像を判別させて精度の検証を行った.

#### 2. 対象路線と使用画像データ

本研究の対象路線は神奈川県横浜市内の神奈川県道2号線の一部区間(9.14km),神奈川県道109号線(7.34km), 横浜市道85号線の一部区間(7.12km),東京都調布市道33 区間(総距離14.31km),福岡県直方市道20区間(総距離10.28km)であり,総撮影距離は48.19kmとなっている.

鹿島道路株式会社の多機能路面測定車によって 5m 間隔 での道路画像の撮影と 10m 間隔でのひび割れ率の測定を 行った.この測定車で撮影されたそのままの画像は対向車 や沿道の建物などが写り込んでいるため,左右の歩道や建 物等の障害物や前後の写真で重複した範囲が映らないよう に考慮して元の画像の 1920px×1080px のうち,図-1 のよ うに 880px×440px の範囲でトリミングを行った.その後, 画像を 110px×110px の範囲で格子状に分割してから,図-1 の赤く塗られた画像のような障害物が写る画像を取り除 いて正規化を行った.

多機能路面測定車で測定されたひび割れ率 P(%)<sup>4)</sup>を参考 に各エリア 30 箇所程度の画像に目視判読を行い,ひび割 れの有無で 2 クラスに分類した.これらを約 4:1 の比率で 訓練用画像と検証用画像に分けた.また,これらの画像に 加えて,画像を分割した際に全体の 1/8 以上をマンホール が占めるものをマンホール A,全体の 1/4 以上もしくはマ ンホールの 1/2 以上が写るものをマンホール B としてクラ ス分けした.目視判読に利用していない画像は全てテスト 用画像で用いることとし,表-1 のように合計 310544 枚を 用意した.



図-1 画像のトリミング範囲

表-1 使用した画像の内訳

ひび	あ	な	マンホール	マンホール		
割れ	り	l	Α	В		
訓練用	1418	2678	27	100		
画像[枚]						
検証用	423	702	5	7		
画像[枚]						
テスト用	305184					
画像[枚]	(うち 2004 枚は目視判読済)					
合計[枚]			310544			

3. 深層学習のアルゴリズム

本研究では深層学習に Caffe<sup>5)</sup>を使用した. Caffe はオー プンソースで開発されているディープラーニングのフレー ムワークであり,画像認識の分野に向いている.また,GPU を利用した計算処理速度が高速であること,コード設計が 容易であることが特徴として挙げられる<sup>6)</sup>.

Caffe を利用することによって CNN(畳み込みニューラ ルネットワーク: Convolutional neural network)による画像 判別モデルを作成した. CNN は画像や動画認識に広く使わ れているモデルである<sup>7)</sup>. この判別モデルを用いて,入力 した路面画像のひび割れの有無を評価する.

#### 4. 最適化手法

ニューラルネットワークの重みの最適化には勾配法を用いた.勾配法は数値計算で関数の最小値を算出する際に利用される方法で,式(1)のように計算される<sup>3)</sup>.

$$x_{i+1} = x_i - \varepsilon \, \frac{\partial f}{\partial x} \tag{1}$$

ここで, xiはある時点での重みの値, fは損失関数, ∂f/∂x は 勾配, εは学習率である.本研究の最適化においては,出力 層と学習データの値の差分の二乗の総和を小さくするよう に勾配法が用いられている.さらに,勾配法の中でも訓練 用の画像から少数の画像をランダムで選んで更新処理を行 うミニバッチ法を使った.

学習率 ε の変動のポリシーは式(2)で表される"step"と式 (3)で表される"poly"の 2 通りを採用した<sup>4)</sup>.

$$Lr_{iter} = base \ lr \times gamma \ \left\lfloor \frac{iter}{stepsize} \right\rfloor$$
(2)  
$$Lr_{iter} = base \ lr \times \left(\frac{1 - iter}{\max \ iter}\right)^{power}$$
(3)

ここで,*iter* はある時点での学習回数,*Lriter* は前述の学習 回数での学習率,*base\_lr* は学習開始時の学習率の値, *max\_iter* は設定した学習回数である.また,*gamma,stepsize*, *power* は計算に用いる定数である.

5. ネットワークパラメータ

ネットワークパラメータはリファレンスモデルの AlexNetを参考とし,一部改変して用いた.本研究で用いた ネットワークは5つの畳み込み層,3つのプーリング層,3つ の全結合層で構成される. 現在はより多層のネットワークが主流となっているが、 使用する画像の大きさや、以前行っていた路面全体画像で のひび割れ検出の検証の際<sup>8)</sup>にAlexNetが他のGoogLeNet等 のネットワークと精度に差がなかったこと、計算時間の短 さなどを鑑みて、このAlexNetを採用するに至った.

また,活性化関数はAlexNetと同様にReLU (Rectified Linear Unit)関数を使用した.活性化関数とは,前の層のノードとエッジの重みの積の和に対して施す関数のことである.ReLU関数は学習の速度が速く,学習が止まることが少ないことが特徴である<sup>3)</sup>.

## 6. 学習結果

(1) 各指標による比較

本研究では、学習時は100回毎に損失関数(loss)と正解率 (accuracy)を表示させ、1000回の学習毎にテストを行った. 本研究では比較のために12のモデルを作成した.モデル1~ 5が2クラス分類、モデル6~12がマンホール画像を加えた3 クラス分類である.モデル1と6の2つのモデルを除き、学習 に用いる訓練用画像と検証用画像のうち路面画像は左右反 転させ、マンホールの画像はさらに90度ずつ回転させ、画 像のかさ増しを行っている.各モデルの設定と学習結果は 表-2、表-3の通りである.

全てのモデルにおいて,検証用画像を用いた正解率が9割 近い数値となっているため,学習が成功していると判断で きる.2クラス分類と3クラス分類における数値の差はほと んど確認できなかった.損失関数の値が最も低いのは,訓 練データに対する過学習を防ぐことができる仕組みである Dropout層<sup>9)</sup>を除去したモデルであったが,テスト時の正解 率は他のモデルの方が高かった.したがって,Dropout層が 有効であることが示された.

テスト時の正解率とF値に注目すると、画像のかさ増し を行っていないモデル1と6の数値が低くなった.これは左 右反転を行った鏡像の画像を加えることで、元の画像が同 じものであっても学習に用いるデータとしては有用である ことを示している.2クラス分類と3クラス分類で共通して テスト時の正解率が高かったのはAlexNetのデフォルトの パラメータ設定に近いモデル2と7、Stepsizeを20000から 2000へと変更し、学習率の変化を細かくしたモデル3と8で あった.これらのモデルについては、マンホールか判別し にくい画像を学習用の画像から除去した上で更に学習を行 った.この結果がモデル11と12であり、モデル11のみ精度 が向上した.

表-2	谷ヨ	モデ	ル	の設定	Ē
	Net.			-	-

モデル名	クラス数	マンホール画像	画像数	ポリシー	base_lr	gamma	stepsize	power	Dropout
モデル1	2	-	1 倍	Step-1	0.001	0.1	20000	-	有
モデル2	2	-	2 倍	Step-1	0.001	0.1	20000	-	有
モデル3	2	-	2 倍	Step-2	0.001	0.1	2000	-	有
モデル4	2	-	2 倍	Poly	0.001	-	-	50	有
モデル5	2	-	2 倍	Step-1	0.001	0.1	20000	-	無
モデル6	3	A+B	1倍	Step-1	0.001	0.1	20000	-	有
モデル7	3	A+B	2 倍	Step-1	0.001	0.1	20000	-	有
モデル8	3	A+B	2 倍	Step-2	0.001	0.1	2000	-	有
モデル9	3	A+B	2 倍	Poly	0.001	-	-	50	有
モデル 10	3	A+B	2 倍	Step-1	0.001	0.1	20000	-	無
モデル 11	3	В	2 倍	Step-1	0.001	0.1	20000	-	有
モデル 12	3	В	2 倍	Step-2	0.001	0.1	2000	-	有

モデル名	損失関数値	検証時正解率	学習回数	テスト時正解率	再現率	適合率	F值
モデル1	1.0607	85.14%	6000	72.26%	0.5643	0.4541	0.5032
モデル2	0.9906	87.52%	6000	74.17%	0.5898	0.5426	0.5652
モデル3	0.5924	87.31%	4000	75.31%	0.6127	0.5492	0.5792
モデル4	0.4241	87.56%	5000	74.69%	0.5922	0.5843	0.5882
モデル5	0.3681	88.62%	2000	75.00%	0.5957	0.5977	0.5967
モデル6	1.6743	83.18%	16000	70.56%	0.5148	0.5450	0.5294
モデル7	0.4742	86.86%	3000	73.00%	0.5608	0.5683	0.5645
モデル8	0.6309	85.78%	6000	73.30%	0.5516	0.5900	0.5701
モデル9	0.5964	81.70%	5000	68.86%	0.4446	0.4984	0.4700
モデル 10	0.4327	86.29%	2000	68.86%	0.5419	0.5366	0.5392
モデル 11	0.4449	87.05%	2000	74.02%	0.5658	0.6056	0.5850
モデル 12	0.4422	86.36%	2000	72.50%	0.4848	0.5769	0.5269

表-3 学習結果

(2) 混同行列による比較

次にそれぞれのモデルにおいて目視判読済の2004枚の画 像の判別結果に対する混同行列を比較する.

今回は3クラス分類で最も精度が高かったモデル11と,同 じパラメータ設定で2クラス分類のモデル2を比較する.2ク ラス分類の混同行列における4つの数字は表-4のようにTP, FP, FN, TNと表記する.

2つのモデルともTP及びTNに相当する画像が多く,ひび 割れが正しく判別できていると考えられる.2つの混同行列 において"ひび割れあり"の画像を"なし/マンホール"と判 別した数が減少している.また,表-5で示した2クラス分類 のモデル2においては再現率が0.59と高いが,表-6で示した

		予測		
		ひびあり	ひびなし	
実	ひびあり	TP	FP	
際		(True Positive)	(False Positive)	
	ひびなし	FN	TN	
		(False Negative)	(True Negative)	

表-4 混同行列と精度指標の定義

表-5	モデル	2 の判	別結果
-----	-----	------	-----

		2 · · · · · · · · · · · · · · · · · · ·	8217		
		予測			
		ひびあり	ひびなし		
実際	ひびあり	325	274		
121	ひびなし	226	1111		

## 表-6 モデル 11 の判別結果

		予測				
		ひび あり	ひび なし	マンホール		
実際	ひびあり	386	209	4		
	ひびなし	264	1064	9		
	マンホール	21	5	9		

3クラス分類では適合率の方が0.61と高くなっている.これ は、3クラス分類の方がひび割れありと判別した数が多く、 ひび割れの見逃しが減少していると推測される.その一方 で、マンホールの画像についてはひび割れありと判別する ケースが多く、正常な路面とは区別出来ているものの亀甲 状のひび割れなどと混同していると思われる結果となった.

## (3) 判別結果の一例

作成した判別器がどのように路面画像を判別したかを図示する.今回は前節でも取り上げたモデル11のうち上手く 判別出来た例と上手く判別できなかった例を表-8のように それぞれ1箇所取り上げる.

表-8 判別結果の例

	<b>F1</b> - 117	••••••	
	実際の	擬似的な	的中率
	ひび割れ率	ひび割れ率	
例 1	26.40%	24.14%	96.55%
例 2	0.40%	71.43%	57.14%

なお,擬似的なひび割れ率は全画像数に対して判別器が ひび割れありと予測した画像数の割合,的中率は正しく予 測した画像数の割合として算出している.



図-2 判別例1の結果 神奈川県道2号線 始点より8205mの地点

まず,良好に判別できた例から示す.図-2で示した例1の 画像では右側の赤色の領域などでひび割れのあるグリッド に沿って正しく判別が行えている.桃色で示したひび割れ の見逃しは1箇所のみであり,見逃しの少ないモデルである ことが確認できる.また,ひび割れのない路面についても 正しくひび割れなしと判別しており,擬似的なひび割れ率 とひび割れ率との差も小さく,的中率は95%を超えるなど 良好な結果となった.



図-3 判別例2の結果 調布市道エリア 00-00 始点より25mの地点

次に判別精度が低かった例を示す.図-3で示した例2の画 像では車両の進行方向に対して垂直な向きのひび割れを正 しく判別しているのに対し,上部と下部に紫色で示すひび 割れのない路面をひび割れありと判別しているのが分かる. 実際よりもやや過剰にひび割れを抽出する傾向が確認でき た.また,マンホール部分についてはひび割れありと判別 していた.マンホールとひび割れの両方が写り込む画像も 存在したため,ひび割れが優先されたと推測される.

#### 7. 疑似ひび割れ率と実際のひび割れ率の比較

最後にテスト画像のうち,目視判読を行わなかった画像 についても擬似的なひび割れ率を算出し,GISによって地 図上に表示させた.なお,この画像については枚数が多い ため,側溝などの障害物は取り除いていない.今回はひび 割れ率の数値が多様な直方エリアについて説明する.



図-4 直方エリアのひび割れ率分布



図-5 直方エリアの疑似ひび割れ率分布

2つの分布図を比較すると,擬似ひび割れ率の数値が高い ことが確認できる.北東部においてはひび割れのない箇所 で疑似ひび割れ率が高い数値を示しているなどやや過剰に ひび割れを抽出する傾向が確認できるが、実際のひび割れ 率において赤系統の色で示される箇所は疑似ひび割れ率で も高い数値となっており、実際の保守作業で重要になる見 逃しが少ないことがこの図からも確認できる.

#### 8. 結論

本研究では路面画像を使って深層学習に基づく学習を行い、ひび割れを抽出する画像判別モデルを構築した.かさ 増しによるデータの増加、パラメータ調整により、少ない 路面画像を使いながらも約74%の正解率で判別が出来るモ デルの構築を実現した.また、擬似的なひび割れ率を算出 することで、GIS によって路面性状の見える化を図った. 分布図ではひび割れ率の高い箇所の見逃しが少なく、深層 学習による路面性状評価が可能であることを示した.

しかし、判別結果からはひび割れを過剰に抽出するケースも見受けられた.これは学習に用いた一部の路面画像においてひび割れが90%を超える極端な亀甲状のひび割れを含む事やマンホールの画像が他クラスに比べて不足するなどデータの偏りに原因があると推測される.

深層学習による路面性状評価は、学習に用いる訓練デー タと検証データが精度に非常に大きな影響を及ぼしている と推察される.舗装やひび割れの種類や形状など多様な路 面画像をデータに加えることで、さらなる精度の向上や汎 用性の高いモデルの構築が可能と考えられる.また、今後 はひび割れの検出を複数の判別器を用いて、形状により段 階分けをするなどさらに精度と実用性の向上を検討してい る.

参考文献

- 国土交通省近畿地方整備局:1.道路老朽化の現状 老 朽化の現状, https://www.kkr.mlit.go.jp/road/maintenance/ roukyu/genjyou.html
- 福島県郡山市:郡山市道路施設修繕計画, https://www. city.koriyama.lg.jp/material/files/group/19/shuuzenkeikaku .pdf
- 3) 武井宏将:初めてのディープラーニング,リックテレ コム, 2016.
- 4) Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R., Guadarrama, S. and Darrell, T.: Caffe: Convolutional architecture for fast feature embedding, Proceedings of the 22nd ACM International Conference on Multimedia, pp. 675-678, 2014.
- 5) 大阪府:大阪府舗装点検要領,http://www.pref.osaka. lg.jp/attach/28101/0000000/070\_hosou\_honpen.pdf
- 橘理恵: Caffe によるディープラーニング、日本医用画 像工学会 Medical Imaging Technology, Vol. 36, No.2, pp. 52-57, 2018.
- 中山英樹:深層畳み込みニューラルネットによる画像 特徴抽出と転移学習,電子情報通信学会技術研究報
  告, Vol. 115, No.146, SP2015-45, pp. 55-59, 2015.
- 8) 古市直也,丸山喜久:道路画像の深層学習に基づく路 面ひび割れ状況の把握に向けた基礎検討,土木学会年 次学術講演会講演概要集,Vol.74,Paper No. V-435,2019.
- 9) 藤田一弥, 高原歩:実装ディープラーニング, オーム 社, pp.110-119, 2016.
- 10) 国土交通省 道路局:舗装点検要領, https://www.mlit. go.jp/road/sisaku/yobohozen/tenken/yobo28\_10.pdf