## ※層学習を用いた2段階路面ひび割れ抽出手法

奥田 知之<sup>1</sup>•窪田 智則<sup>2</sup>•篠原 崇之<sup>3</sup>

<sup>1</sup>正会員 株式会社パスコ 中央事業部 (〒153-0043 東京都目黒区東山 1-1-2 東山ビル 5F) E-mail: taodmk3852@pasco.co.jp

<sup>2</sup>株式会社パスコ 中央事業部(〒153-0043 東京都目黒区東山 1-1-2 東山ビル 5F)
E-mail: yiokja2380@pasco.co.jp
<sup>3</sup>株式会社パスコ 経営戦略本部(〒153-0042 東京都目黒区青葉台 4-9-6 日本地図センタービル 5F)
E-mail: taarkh6651@pasco.co.jp

路面の画像を切り出したパッチ画像に対する深層学習を用いた自動ひび割れ抽出は,排水性,コンクリート舗装,シーリング部等の一般的な密粒舗装以外について抽出漏れ又は過抽出する課題があった.そこで、本研究は深層学習モデルにより車道幅員内の路面画像を6クラスの路面種別に分類し、その結果と路面パッチ画像を用いてひび割れを抽出する2段階路面ひび割れ抽出手法の提案と検証を行った. 前段の路面種別分類モデルの予測精度は96%以上を達成した.後段のひび割れ抽出モデルでは、路面種別分類結果を用いる事により、6クラス中5クラスの路面種別では最大0.3%程度精度向上した一方で、残りシーリングクラスについては0.7%の精度低下とひび割れ抽出に最適なクラス分類検討の課題が残った.

# *Key Words:* convolution neural network, deep learning, pavement condition survey, crack detection, pavament maintenance and management

## 1. はじめに

少子高齢化やそれに伴う予算規模縮減,老朽化により, 公共インフラの維持管理を効率化していく事が求められ てる.公共インフラの中でも舗装は路面画像の取得が容 易であるため,従来より路面性状測定車等を用いた定期 点検が行われてきた<sup>1)</sup>.しかし,それらの装置により得 られた路面画像からひび割れを評価する解析作業は,舗 装調査・試験法便覧に基づき目視で行われている.従っ て目視によるひび割れ解析作業を一部でも自動化できれ ば,人的コストを削減し,効率化に寄与できる.

既報<sup>2</sup>では CNN(Convolutional Neural Network)を用い て、密粒舗装のひび割れを抽出した結果、精度高くひび 割れを抽出する事が出来た.しかし実際の路面には、密 粒舗装とは異なる排水性舗装やカラー舗装等が混在して いる.その様な路面については、密粒舗装とはひび割れ の見え方が異なるため、密粒舗装と同じモデルを用いて 同等精度でひび割れを抽出する事は難しいと考えられる.

本研究では、そのような多様な路面種別に対して対応 するため、ひび割れ抽出を行う深層学習モデルの前段に、 別の深層学習モデルにより路面種別の分類を行う.その 結果と路面パッチ画像をひび割れ抽出モデルに入力とし て与えることで、密粒舗装以外の路面に対するひび割れ 抽出精度の向上を目的とする.

## 2. 深層学習によるひび割れ抽出

深層学習を用いたひび割れ自動抽出手法は、モデルが 抽出するひび割れのスケールに応じて、表-1に示す4種 類に整理できる.

[1]から[4]になるほど,抽出結果のスケールは細かく なり,より詳細なひび割れの情報が得られる一方で,デ ータ取得,教師データ作成及び,計算コストが増加する.

路面性状調査等の舗装のひび割れ点検では[4]の様な ピクセルスケールの詳細な抽出結果が必要とされる事は 稀である.また,[2]の手法ではひび1本又は2本のクラ ス分類のみを行うため,その中にどの程度ひび割れが密

表-1	衆層学習による舗装ひび割れ自動抽出方法の分類

No	自動抽出対象	ひび割れ抽出 スケール例	ひび割れ抽出 スケール	コスト
[1]	前方映像の路面	2m × 3m	大	<i>/</i> ]/
[2]	試験法便覧	0.5m × 0.5m		
[3]	パッチ	32pix × 32pix		
[4]	ピクセル	1pix × 1pix	1/	大



図-1 深層学習による2段階路面パッチ画像ひび割れ抽出手法

集しているのか、横断又は縦断方向か、亀甲状かなどより詳細な情報が得られない<sup>3</sup>. そのため、本研究では[2] と[4]の中間的なスケールである[3]のパッチ画像スケー ルのひび割れ抽出を対象とする.

しかし、車道路面の表面に使われる舗装には、一般的 な密粒舗装以外に、排水性舗装、コンクリート舗装等が ある.また、橋梁の繋ぎ目にはジョイントがあり、周辺 環境への配慮のためのカラー舗装や、ひび割れをシーリ ング材により補修した跡がある.これらの舗装をカメラ により撮影した路面画像上のひび割れは、それぞれ異な る特徴があるため、同じモデルでひび割れを抽出すると、 例えばジョイント部や、カラー舗装の塗料はく離部をひ び割れとして過抽出したり、排水性舗装のひび割れを抽 出漏れする事がある.

先行研究としてその様な課題に対して, ひび割れ過抽 出の要因となるマンホールや白線等が含まれるひび割れ と,含まれないひび割れのパッチ画像を別クラスとして 分類し,ひび割れ抽出を行った事例 <sup>4</sup>がある.本研究で 分類する路面種別は,路面全体の一部だけ切り出すため 限られた範囲の情報のみが含まれるパッチ画像よりも, 広域的な情報により決定されると考えられる.そこで本 研究では,図-1に示すように前段として先にパッチ画像 より広範囲の路面画像から路面種別を分類し,その情報 を元に後段のひび割れ抽出を行う,2段階路面パッチ画 像ひび割れ抽出手法を提案,検証する.

## 3. 深層学習による2段階ひび割れ抽出手法

本章では、提案する2段階ひび割れ抽出手法を説明する.

#### (1)深層学習モデル

本研究では画像分類タスクの精度を競う ILSVRC 2016 で優勝した ResNeXt<sup>9</sup>を用いる.最初に,画像認識 に用いられる深層学習モデルの基本的な構成要素である CNN 層を説明する.

#### a) CNN 層

CNN 層は、まずl層目の CNN に対する入力特徴量マ



図-2 ResNeXtの構成ブロック

ップ $z_{ijk}^{(l-1)}$ に対し、フィルタの重み $h_{pqkm}$  (p = 0, ...H - 1, q = 0, ...H - 1)との畳み込み計算を行い、入力チャ ネル数k(= 0, ...K - 1)にわたって積算する.

$$z_{ijm}^{(l)} = f\left(\sum_{k=0}^{K-1} \sum_{p=0}^{H-1} \sum_{q=0}^{H-1} z_{i+p,j+q,k}^{(l-1)} h_{pqkm} + b_{ijm}\right) (1)$$

ここでmは出力チャネル数,  $f(\cdot)$ は活性化関数である. 従って,各 CNN 層ごとに設定するmの値により出力チャネル数が決定される.

## b) FC 層

深層学習モデルの最終層には CNN 層の出力を 1 次元 に変換した $x_i$ (i = 1, ..., I)を入力とした, FC(Fully Connected)層を用いた. FC 層は以下の式で表される.

$$u_j = f\left(\sum_{i=1}^{l} w_{ji} x_i + b_j\right) \tag{2}$$

ここで $w_{ji}$ は結合荷重パラメータで、 $b_j$ はバイアス項 である. j(=1,...,J)は出力の要素数で、出力層ではJを クラス分類数と同じに、活性化関数にソフトマックス関 数を用いてクラス分類確率を求め、最も確率が高いクラ スを分類結果とした.

#### c) ResNeXt

ResNeXt は、Inception<sup>®</sup>や GroupedConvolution<sup>®</sup>等の 並列に CNN を計算する手法を参考にして提案され、図 -2に示すように、並列に複数の CNN 層を1つの構成ブ ロックにまとめた構造となっている.ブロック内では 3 層の CNN を 32(カーディナリティ)並列に計算し、最後 にチャンネル間で積算する.また、構成ブロック内 2 層 目の入出力チャネル数(ボトルネック幅)は、ブロック全 体の入出力チャネル数と比較し大幅に縮減する.また、

No.	分類	クラス名							
0	密粒舗装	asphalt							
1	コンクリート舗装	concrete							
2	排水性舗装	polas							
3	カラー舗装	color							
4	シーリング	seal							
5	ジョイント	joint							

**表-2** 路面種別分類

ResNeXt は ReNet<sup>®</sup>により提案された, ブロックへの入 力をそのまま出力に加算する Residual Connection を持 つ. なお 図-2 の各矩形は CNN 層を表し, 左の数値が入 力チャネル数(k), 中央がフィルタのサイズ(H), 右の 数値が出力チャネル数(m)である.

本研究では、この ResNeXt の構成ブロックを 8 個積 層、カーディナリティ 32、ボトルネック幅 4 の ReNeXt26\_32x4d を用いる.

#### (2) 入力画像

入力データとして,路面性状測定車に備えられたラインセンサより得られた路面画像を用いた.ラインセンサは横断方向 4.5m×縦断方向 1.1m の領域を 4096pix×909pixの画像サイズで照明を用いながら記録しており,およそ 1pix 辺り 1.1mmに相当する高精細な画像が得られる.なお,本研究では日光の影響を受けない夜間に撮影した路面画像を用いた.

#### (3) 路面種別分類

#### a) 路面種別の分類

路面種別を目視により表-2 に示す 6 クラスに分類した. 例えば密粒舗装上に現れるシーリング又はジョイントは,密粒舗装ではなくシーリング又はジョイントとして分類した. シーリングとジョイントがあった場合には,ジョイントを優先した.

なお、ひび割れ率は一般的に車道外側線(白線)の内 側のみを対象として求めるため、白線は上記分類に用い なかった.優先的にそれらのクラスに分類した.また、 路面が濡れている場合や、マンホール等も路面種別に追 加する事が考えられるが、今回用いたデータではそれら の路面が多くは確認できなかったため、上記6分類のみ とした.

#### b) 路面種別分類モデル

路面種別分類モデルを ResNeXt26\_32x4d を用いて構築した.路面種別はひび割れ抽出モデルで用いるパッチスケールの画像と比較し,ある区間の路面全体的に分布する,より広域の特徴を捉える必要があると考えられる. そのため,路面性状測定車により得られた車道幅員全体を撮影した路面画像4096pix×909pixから左右798pixずつ切り落として2500pix×909pixとし,これを更に1/2

表-3 路面種別分類モデルの混同行列

Prediction	asphalt	concrete	polas	color	seal	joint	precision
asphalt	297	0	0	8	6	1	95.2%
concrete	0	181	1	1	0	1	98.4%
polas	4	0	261	4	1	0	96.7%
color	1	0	1	114	0	0	98.3%
seal	5	0	0	0	234	0	97.9%
joint	3	0	0	1	0	59	93.7%
recall	95.8%	100.0%	99.2%	89.1%	97.1%	96.7%	
accuracy	96.8%						-

に縮小した 1250pix×454pix を入力画像として用いた. なお、元の 4096pix×909pix の画像を用いて次項の検証 を行ったが、殆ど精度の向上は見られなかった事から、 計算量削減のため縮小した画像を用いた. 学習画像、検 証画像数はそれぞれおよそ5千枚、1千枚である. 深層 学習ではデータ量の水増しをするデータ拡張により、精 度及び凡化性能が向上する事が知られている. データ拡 張は水平方向の反転、上下50pix、左右 125pix までの平 行移動、±5%までの拡大・縮小を行った.

#### c) 精度検証

精度検証結果として、検証画像に対する混同行列を表 -3に示す.表の列が教師ラベル、行がモデルによる予測 結果を表している.各クラスの precision, recall 共に 89%以上で、全体の精度(accuracy)は 96%以上と高い精 度を達成しており、路面種別分類単体でも用いることも 可能な、ひび割れ抽出の前段として路面種別を精度高く 分類できるモデルが構築できたといえる.

#### (4) ひび割れ抽出

#### a) 入力画像および教師ラベルの作成

路面性状測定車により得られた路面画像およそ 10km(約1万枚)分に対し,技術者が目視でひび割れ上に ラインを引き,教師データの元となるひび割れマスク画 像を作成した.このひび割れマスク画像を上下左右に 32pix の重複を持たせて 96pix ごとに切り出したパッチ 画像を作成し,その中心 32pix にスケッチしたラインが あった場合,ひび割れありの教師ラベルを付与した.デ ータ拡張は水平方向の反転,±20度までの回転,上下 左右 14pix までの平行移動,±10%までの拡大・縮小を 行った.パッチ画像の80%を学習用,残りの10%ずつを それぞれ検証,評価用とした.

#### b) ひび割れ抽出モデル

ひび割れ抽出モデルは路面種別分類モデルと同様に ResNeXt26\_32x4d を用いて構築した.路面種別分類モ デルにより得られた路面種別は,分類結果の種別のみ 1, 残りの種別を0で表した1次元ベクトルとしてFC層の 入力x<sub>i</sub>に結合して与えた.

学習用のパッチ画像をすべて用いると、ひび割れあり 画像数 1,027,562 に対し、ひび割れ無しが 35,513,334 と

		asphalt		concrete		polas		color		seal		joint	
		ひび無し	ひび有り	ひび無し	ひび有り	ひび無し	ひび有り	ひび無し	ひび有り	ひび無し	ひび有り	ひび無し	ひび有り
路面種別 入力なし	precision	99.2%	66.3%	99.3%	64.5%	98.2%	64.8%	98.2%	59.1%	98.5%	63.5%	98.0%	61.2%
	recall	99.5%	58.1%	99.5%	57.0%	98.6%	57.7%	98.3%	56.6%	98.8%	57.5%	98.2%	58.3%
	accuracy	98.7%		98.8%		96.9%		96.6%		97.4%		96.4%	
路面種別 入力あり	precision	99.3%	68.9%	99.3%	63.9%	98.2%	68.4%	98.2%	65.4%	98.0%	66.2%	98.0%	66.2%
	recall	99.5%	59.5%	99.5%	59.6%	98.8%	58.8%	98.7%	56.7%	98.5%	59.3%	98.5%	59.3%
	accuracy	98.8%		98.8%		97.2%		97.0%		96.7%		96.7%	

表-4 2段階ひび割れ抽出結果

30 倍ほどの差があり、クラスごとのデータ数を調整す る必要があった.ひび割れ抽出モデルの入力画像は、ひ び割れあり:ひび割れ無しの割合がおよそ 1:5 となるよ うに学習した.

## c) 精度検証

評価データに対して各路面種別ごとに求めた precision, recall, accuracy を表-4に示す. 比較のため FC 層に路面 種別を入力せず、その他の構造は同一のモデルによる結 果も示している.これによると、seal 以外の路面種別は、 路面種別を入力とすることで、最大 0.3%程度であるも のの、精度(accuracy)が向上したもしくは変わらなかっ た.精度向上分が小さい理由の1つは、精度が96%以上 であるため、教師ラベルの作成精度などを考慮すると精 度向上が可能なパッチ画像が少ないためだと考えられる. 一方でsealについては路面種別入力があることにより、 0.7%精度が低下した.シーリングは他の路面種別とし て,路面画像内に占める割合が小さい.そのため,車道 幅員全体からシーリングと分類した画像でも、ひび割れ 抽出を行うパッチ画像に分解した際にはシーリングが入 っていない画像が多いため、精度が低下したと考えられ る.

## 4. まとめ

本研究では、様々な路面種別が混在する事で、ひび割 れを抽出漏れ又は過抽出してしまう路面に対して、前段 として車道幅員全体を撮影した路面画像から、深層学習 モデルにより路面種別を6分類し、後段としてその結果 と路面パッチ画像を入力とする別の深層学習モデルによ り、より細かいパッチスケールのひび割れを抽出した. まず、路面種別分類モデルにおいては、精度96%以上と 高い精度で路面種別が分類できた.この路面種別分類モ デルは、単体で路面種別を自動判定する為に用いること も可能である.その路面種別分類結果と路面パッチ画像 を入力に用いたひび割れ抽出モデルにより、ひび割れあ り、なしの2クラス分類を行った結果、シーリング以外 は最大 0.3%程度の精度向上で、シーリングについては 0.7%精度が低下した.この原因としては、他の舗装種 別,例えば排水性舗装等とは異なり,シーリングは局所 的な変状であるためだと考えられる.それにより,車道 幅員全体の画像に対しシーリングに分類した路面画像を, ひび割れを判定するパッチ画像に分解した際に,シーリ ングが入らない画像が多いためだと考えられる.したが って,よりひび割れ抽出に最適な路面種別のクラス分類 や,その分類を判定するために使う領域等を検討する必 要があると考えられる.

#### 参考文献

- 大浜雅宣:走行写真撮影法による路面性状調査(その 1)~35mmパルス写真による路面の横断凹凸の測定 ~,写真測量とリモートセンシング, Vol.18, No.2, pp.4-12, 1979.
- 2) 奥田知之, 瀧洋二, 篠原崇之: 深層学習を用いた路 面性状測定車によるラインセンサ路面画像のひび割 れ自動抽出, 土木情報学シンポジウム講演論文集, Vol.44, 2019.
- 浅田拓海,川村和将,石田篤徳,亀山修一: Convolutional Neural Network を用いたひび割れ・パッチングの高精度検出手法の開発,土木学会論文集 E1 (舗装工学), Vol.74, No.3, pp.131-139, 2018.
- 4) 全邦釘, 井後敦史, 南免羅裕治, 黒木航汰, 大窪和 明:車載カメラにより撮影された舗装画像からのデ ィープラーニングによるひび割れ率評価, 土木学会 論文集 E1(舗装工学), Vol.73, No.3, pp.97-105, 2017.
- 5) Xie ,S., Girshick ,R., Dollár ,P., Tu ,Z., He ,K. Aggregated residual transformations for deep neural networks : Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, pp.5987-5995, 2017.
- Szegedy ,C., Liu ,W., Jia ,Y., Sermanet ,P., Reed ,S., Anguelov ,D., Erhan ,D., Vanhoucke ,V., Rabinovich ,A. Going deeper with convolutions : Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Vol.07, pp.1-9, 2015.
- Krizhevsky ,A., Sutskever ,I., Hinton ,G.E. ImageNet Classification with Deep Convolutional Neural Networks : Advances In Neural Information Processing Systems, pp.1-9, 2012.
- Wu ,S., Zhong ,S., Liu ,Y. Deep residual learning for image steganalysis : ILSVRC2015, pp.1-17, 2015.