

(49) 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

奥田 知之¹・瀧 洋二²・篠原 崇之³

¹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

²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: yiokja2380@pasco.co.jp

³正会員 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

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いる。そこで、本研究は目視で行われている路面のひび割れ抽出を自動化する事で、舗装維持管理の効率化に資するために、路面パッチ画像に対する深層学習によるひび割れの自動抽出を行った。深層学習モデルの CNN(Convolutional Neural Network) 及び ResNet(Residual Network)によるひび割れあり、なしの 2 クラス分類精度を比較すると、ResNetの方がおよそ 0.5%高く、98.9%であった。しかし、ひび割れありのパッチ画像を抽出する再現率及び適合率は 70%程度であり、目視で作成する教師ラベルの質を揃える必要がある等の課題がある事が解った。

Key Words: convolution neural network, deep learning, pavement condition survey, crack detection, pavement 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る。また近年、深層学習により大量のデータから特徴を学習する事で、高精度な予測や推定が出来る事が解ってきた¹⁾。そこで、インフラ維持管理に深層学習を適用する事で、維持管理を効率化する事が期待されている。

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²⁾。しかし、それらの装置により得られた路面画像から、区間の総舗装面積に対してひび割れている面積を表すひび割れ率を求める解析作業は、舗装試験法便覧³⁾に基づき目視で行われている。従ってその目視によるひび割れ抽出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。

近年、その様な画像認識分野では深層学習の中でも CNN(Convolutional Neural Network)を用いた手法が主流になりつつある¹⁾。深層学習により舗装ひび割れを抽出した研究は幾つかあるものの、次章で論じる通り事前に目視でよく選定された路面画像に対して検討している

事が多く、実際の多様な路面状況を反映していない事や、ひび割れ抽出を行うスケールが異なる。そこで、本研究は路面性状測定車により測定される実際の路面画像から舗装ひび割れの自動抽出を最適なスケールで高精度に行う事を目的とする。

2. 深層学習を用いたひび割れ自動抽出

深層学習モデルが出力する抽出結果のスケールに応じて以下の 4 種類に整理できる。

[1]車両前方画像からのひび割れ抽出⁴⁾

車両前方を撮影した画像から、舗装部分を切り出した画像を入力として用いて、画像中のひび割れを抽出する。任意の車両から前方を撮影した画像に幅広く適用可能である一方、路面性状調査で要求される 1mm 幅のひび割れを認識する事は困難である。

[2]舗装試験法便覧に従ったひび割れ抽出⁵⁾

1mm 幅のひび割れが認識可能なように取得した路面画像から、舗装試験法便覧のひび割れ解析方法に基づき 0.5m×0.5m の路面パッチ画像に対するクラス分

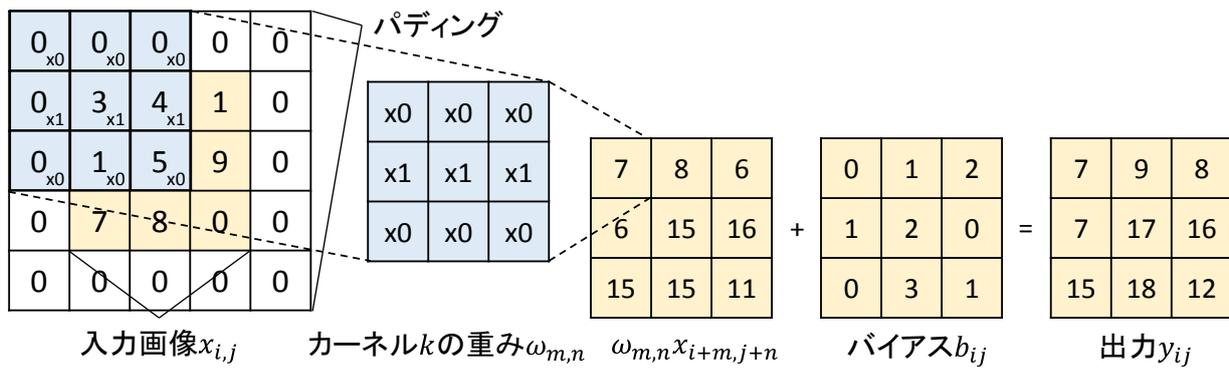


図-1 CNNの計算例

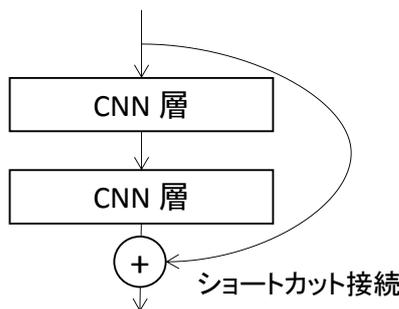


図-2 ResNetの構成ブロック

雑草、路側帯等)を含む。それにより、ネガティブはポジティブよりも多様な特徴を学習する必要があるため、学習が難しいと考えられる。既往研究では、舗装ではない所は除くなど、目視により予め選定されたデータセットを用いている事が多く、路面性状測定車により実際に得られる多様な路面画像とは異なる事が多い。

本研究の特徴は、その様な舗装以外の画像も多量に含まれる、路面性状測定車により取得される実際の路面画像に対して、高精度なパッチスケールのひび割れ自動抽出を行う事である。

類(ひびなし、1本、又は2本)を行う方法である。

[3]パッチ画像スケールのひび割れ抽出^{6,7)}

路面画像をひび割れの方向等詳細な情報を得られるよう[2]より細かいパッチに分解し、そのパッチ画像中にひび割れがある又はない等のクラス分類を行う方法である。

[4]ピクセルスケールのひび割れ抽出⁸⁾

パッチに分解した画像から、1ピクセル単位でひび割れ有り無しのクラス分類を行う方法である。従って、1ピクセル単位で精度の高い教師データが必要になる。

[1]から[4]になるほど、抽出結果のスケールは細くなり、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本へのクラス分類のみを行うため、縦横断のひび割れ方向や亀甲状などより詳細な情報が得られない⁷⁾。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抽出を行う。

ひび割れありの教師ラベル(以下、ポジティブと称す)を持つパッチ画像は、基本的に舗装上しかありえないが、ひび割れなしの教師ラベル(以下、ネガティブと称す)はポジティブではない画像全てになるため、あらゆる多様な路面画像(例えばジョイント、ガードレール、縁石、

3. 使用する深層学習モデルと入力データ

Nhat-Duc^ら⁶⁾や、浅田^ら⁷⁾により用いられた、深層学習の中でも画像認識に適したモデルがCNNである。CNNの層が深くなると勾配が消失する問題を解決するため、CNN層の入力と出力の残差を学習するようにショートカット接続を追加したモデルがResNet(Residual Network)⁸⁾である。

(1)CNN

CNNは入力画像に対し、次式で示すカーネル(フィルタ)との畳み込み計算を繰り返し行う。

$$y_{ij} = \sum_{m,n} \omega_{m,n} x_{i+m,j+n} + b_{ij} \quad (1)$$

ここで、 x と y は入力と出力、 ω と b はカーネルの重みとバイアスである。カーネルのサイズ m と n が3の場合の計算例を図-1に示す。CNNは通常この畳み込み計算の後に、次元を削減するプーリング、活性化関数による変換、及び標準化を行う。本研究ではNhat-Duc^ら⁶⁾と同じCNN層4層の後に全結合層2層のモデルを用いた。

(2)ResNet

ResNetの構成を図-2に示す。ここで、CNN層は(1)

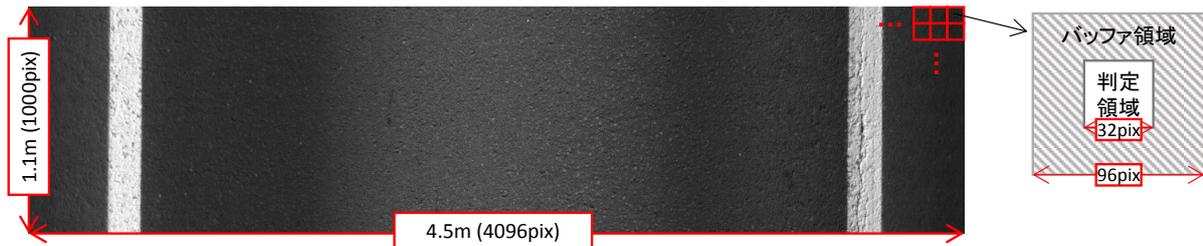


図-3 入力画像例

表-1 CNNの混同行列

教師 \ CNN	Positive	Negative	適合率
Positive	24,188(1.0%)	20,308(0.9%)	54.3%
Negative	14,875(0.7%)	2,227,157(97.4%)	99.3%
再現率	61.9%	99.0%	98.4%

表-2 ResNetの混同行列

教師 \ ResNet	Positive	Negative	適合率
Positive	27,523(1.2%)	13,543(0.6%)	67.0%
Negative	11,540(0.5%)	2,233,922(97.7%)	99.5%
再現率	70.0%	99.3%	98.9%

で述べた畳み込み計算を行う層である。ショートカット接続は入力そのまま出力に加算するため、ResNetのCNN層は入力に対する残差を学習する事に相当する。本研究で用いたResNetは、CNNが34層、即ち図-2の構成ブロックを17層分接続したResNet34である。

本研究ではCNNとResNet両方のモデルを構築し、ひび割れあり、なしのクラス分類精度を比較する。なお、これらのモデルは深層学習フレームワークのTensorflowを用いて構築した。

(3)使用データ

入力データとして用いる路面性状測定車により得られたラインセンサ画像の例を図-3に示す。ラインセンサは横断方向4.5m×縦断方向1.1mの領域を4096pix×1000pixで撮影している。およそ3km分の日光の影響を受けない夜間撮影の路面画像に対し目視でひび割れ上にラインを引き、パッチ分割後の判定領域にラインがある画像にはポジティブの教師ラベルを付与した。入力パッチ画像サイズは、中心の32pix×32pixを判定領域、その外周の32pixをバッファ領域とし、96pix×96pixである。

(4)パッチ画像数

上記により作成した入力パッチ画像数は、ポジティブ

約20万枚、ネガティブ約1000万枚と大幅に偏るため、ポジティブとネガティブデータ数比を調整する必要がある。本研究ではFanら⁸⁾の方針に従い、再現率と適合率のバランスが取れた、ポジティブ：ネガティブ = 1：10 = 20万枚：200万枚を用いた。それらのデータ数の内20%を検証データ、80%を学習データとした。

4. 結果と考察

CNNとResNetの検証データに対するクラス分類精度を表す混同行列をそれぞれ表-1及び表-2に示す。ここで適合率は、モデルが分類したポジティブ又はネガティブそれぞれのクラスが教師ラベルと一致していた割合で、値が大きいほど誤検出が少ない事を示す。再現率は、それぞれの教師ラベルのパッチ画像中でモデルによる分類が教師ラベルと一致していた割合で、値が大きいほど検出漏れが少ない事を示す。適合率と再現率が交差する右下のセルは、全データに対してモデルによる分類が教師ラベルと一致している割合である精度を示す。CNNの精度は98.4%、ResNetの精度は98.9%と何れも高い精度を示しているが、ResNetの方が0.5%高い。

ResNetはCNNと比較しポジティブに対する再現率がおおよそ8%高く、適合率は12.7%高い。再現率と適合率は片方を向上すればもう片方は低下するトレードオフの関係にあるが、ResNetはCNNと比較して再現率と適合率がともに向上した事から、全面的に精度を向上する事が出来たと言える。しかし、ポジティブに対する適合率及び再現率はいずれも70%程度であり、まだ精度向上の余地があると考えられる。

その要因は3.(4)で述べた通りポジティブのパッチ画像数は、ネガティブと比較し大幅に少ないため特徴を十分に学習できない事や、ひび割れを目視抽出する際のばらつきが上げられる。図-4に教師ラベルとResNetによる分類結果の比較例を示す。赤のパッチは教師ラベルがネガティブで、ResNetの分類結果はポジティブである場所を示しているが、左下の黄色破線で囲まれた領域はひび割れがあるように見えるため、本来は教師データが

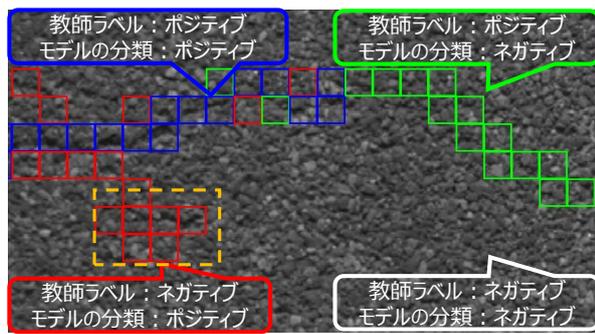


図-4 教師ラベルと ResNet の分類結果比較例

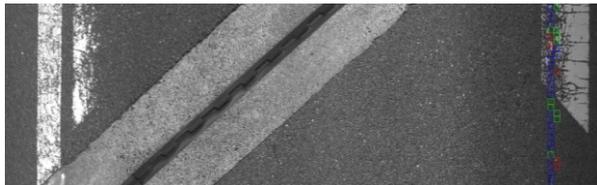


図-5 ResNet のジョイント部分分類結果例

ポジティブであるべきだと考えられる。反対に、画像右側に分布する緑のパッチは教師ラベルがポジティブだが、ResNet の分類結果がネガティブである箇所である。先ほどの黄色破線で囲まれた領域よりひび割れが細く見えるが、教師ラベルはポジティブとなっている。このように、目視抽出の基準が均一ではなく質にばらつきがあるため、ResNet が明確な基準を学習する事が困難になる事が、ポジティブに対する適合率と再現率が 70%程度にとどまる要因の 1 つだと考えられる。この点に関しては、ひび割れ目視抽出の明確な基準を策定する事や、一度 ResNet により自動抽出した結果を元に再度目視で教師ラベルを作り直す事、同じ路面画像に対する教師データ作成作業を複数人でやり平均化する等の対策が考えられる。

また、幅の太いひび割れがあるため明確にひび割れを抽出できる箇所の多くは、図-4 の青パッチで示したように、教師ラベルと ResNet の分類結果はポジティブで一致した。それ以外の色つきパッチが無い場所は、教師ラベル、ResNet による分類結果が共にネガティブであることを示す。

図-5 に実際の路面性状調査で得られる多様な路面画像の一例として、ジョイント部のクラス分類結果を示す。本研究の ResNet は学習データに含まれるジョイントの特徴を学習した事で、このようなジョイント部をポジティブと誤検出することなく、ネガティブと判断できている。この事は、多様な路面を含む実際の路面点検への適用性が高い事を示す。

5. まとめと今後の課題

本研究では、従来用いられていた CNN と、CNN に対してショートカット接続を追加した ResNet により、路面パッチ画像に対するひび割れあり又はなしの 2 クラス分類精度を比較した。クラス分類精度は CNN で 98.4%、ResNet で 98.9%と ResNet の方が高かった。ポジティブに対する再現率と適合率は、CNN よりも ResNet の方がそれぞれ 8%と 12.7%高かった。しかしそれでも ResNet の再現率及び適合率は 70%程度であるため、更なる精度向上の余地があり、そのためには目視による教師ラベルデータのばらつき改善等の課題がある。また、今後本研究で提案したパッチスケールのひび割れクラス分類を用いる事で、路面画像のひび割れ目視抽出をどの程度効率化する事が出来るか定量的に測定する必要がある。

その結果自動抽出による低コスト化が実現すれば、従来コスト制約により車上目視によるランク評価等のより簡易な点検を行っていた舗装についても、ひび割れ自動抽出を用いた均質で詳細な解析ができる可能性がある。

6. 参考文献

- 1) 松尾豊：人工知能の未来とデータ共有の新しい可能性, 情報管理, Vol. 58, No. 8, pp. 597-605, 2015.
- 2) 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.
- 3) 日本道路協会編：舗装調査・試験法便覧第 II 章, pp. 147-176, 2007.
- 4) 前田紘弥, 関本義秀, 瀬戸寿一, 榎山武浩, 小俣博司：機械学習とスマートフォンを用いた道路の損傷画像のリアルタイム検出と修繕対応基準における各特徴量の重要度比較, 交通工学論文集, Vol. 4, No. 3, 2018.
- 5) 福士直子, 小林大志郎, 岩男誠二, 笠原亮介, 矢吹信喜：機械学習技術を活用した路面性状調査の効率化, 土木学会論文集 F3 (土木情報学), Vol. 73, No. 2, pp. 409-415, 2017.
- 6) Nhat-Duc, H., Nguyen, Q. L., and Tran, V. D. : Automatic recognition of asphalt pavement cracks using metaheuristic optimized edge detection algorithms and convolution neural network, *Automation in Construction*, Vol. 94, pp. 203-213, 2018.
- 7) 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.
- 8) Fan, Z., Wu, Y., Lu, J., and Li, W. : Automatic Pavement Crack Detection Based on Structured Prediction with the Convolutional Neural Network, *arXiv*, 2018.
- 9) He, K., Zhang, X., Ren, S., and Sun, J. : Deep Residual Learning for Image Recognition, *arXiv*, 2015.