

深層学習を用いた舗装ひび割れ種類の判別と 判別根拠の可視化に関する研究

A detection and visualization model of pavement crack by using Deep Learning and Grad-CAM

室蘭工業大学建築社会基盤系学科 ○学生会員 内藤雅之(Masayuki Naito)
室蘭工業大学大学院工学研究科 正会員 浅田拓海(Takumi Asada)

1. はじめに

現在、我が国では、簡易舗装を含めると100万kmを超える舗装済み道路が供用されている。舗装は気象条件や交通量により性能が低下することを前提に建設し、必要な管理行為を適切に実施すべき施設である。維持管理が必要とされる膨大なストック量に対し、地方部を中心とした多くの箇所での舗装の劣化が進んでいる。このような状況から、その場限りの維持管理ではなく、ライフサイクルコストの低減や持続可能な予防保全型維持管理に向けたメンテナンスサイクルの構築が喫緊の課題となっている。これは、路面状態の点検で確認された診断結果を基に、適切な措置を行い、施工履歴や気象条件、劣化原因等をデータベース化することであり、効果的な修繕計画の策定、遂行に必要な不可欠とされている。特に、現場での調査を伴う点検や診断に関しては、関連予算や人員の制限などもあり、効率化が求められている。

点検に関しては、ひび割れ、わだち掘れ、縦断凹凸などの計測について、低コストで簡易的な手法が近年の研究により開発されている。特に、ひび割れは、多くの道路において重要な点検項目とされており、AI技術（深層学習）の導入による効率化が着目されている。例えば、CNN（畳み込みニューラルネットワーク）を用いたひび割れ箇所の検出手法を開発した全らの研究など、多数の研究¹⁾や技術開発²⁾が報告されている。また、著者らは、より低コスト化、簡易化、精度向上を目指し、Unet（深層学習による2値化処理）によるひび割れスケッチを導入した簡易カメラ（市販カメラ）搭載型点検システムを開発した³⁾。これらのように、ひび割れの度合いを評価する点検技術については研究、開発が活発化している一方で、路面状況や施工履歴、気象条件などからひび割れの種類や発生原因を判定する「診断」に関する検討は少ない。点検と同様にAI技術の導入が有効であると考えられるが、AIによる結果の出力は根拠が明確ではなく、ブラックボックスになりがちである。しかし、AIが路面のどの箇所を見て、判別を行なったのかという情報は、データベースの構築や納税者への説明責任、舗装診断士の育成ツールなどに役立つと思われる。

以上から、本研究では、著者らが開発した簡易カメラ搭載型点検システムで撮影した路面画像に深層学習（CNN および Vgg16）を適用し、舗装におけるひび割れ種類の判別手法を開発する。さらに、Grad-CAMを導入し、上記の判別結果の根拠箇所を路面画像に可視化し、その有効性について考察する。

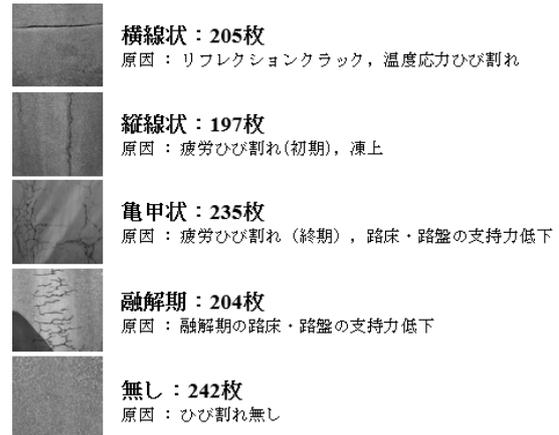


図-1 ひび割れ種類と発生原因および使用画像の枚数

2. 方法

2.1 画像データとひび割れ種類

著者らが開発した簡易カメラ搭載型点検システムでは、市販のアクションカメラ（GoPro Hero5）を車両ボンネットに設置し、走行しながら前方路面を動画撮影する。画像サイズは1920ピクセル×1080ピクセル、動画のフレームレートは60fps、画角は広角モードとした。

本研究では、ひび割れの形状からその発生原因を判別するモデルを開発する。そのデータとして、2020年の3月から6月にかけて北海道の一般国道で撮影した画像から選んだ1083枚を用いる。今回、対象とするひび割れの発生原因の分類については、図-1に示す5種類とした。この分類は、舗装点検必携⁴⁾を参考に著者が行い、明らかな違いのある路面のみを対象とした。なお、現在、舗装診断士を対象としたWEB診断試験を実施中であり、データが揃い次第、分析に反映する予定である。

2.2 深層学習を用いたひび割れ種類の判別モデル

路面画像の解析手順を図-2に示す。まず、深層学習への適用の前処理として、ヒストグラム平坦化と解析領域の抽出を行う。深層学習モデルは、色差成分よりも輝度成分に対して強い感度を持つことから、ヒストグラム平坦化により濃淡を強調させることで、ひび割れを鮮明にし、ノイズを減少させる。次に、白線や背景等を取り除いた解析領域を射影変換し、路面画像として保存する。モデルに正方形の画像として入力するため、224ピクセル四方にリサイズしている。現在、解析領域の範囲指定は目視で行っているが、今後は、白線を検知する処理を導入して、自動化する予定である。

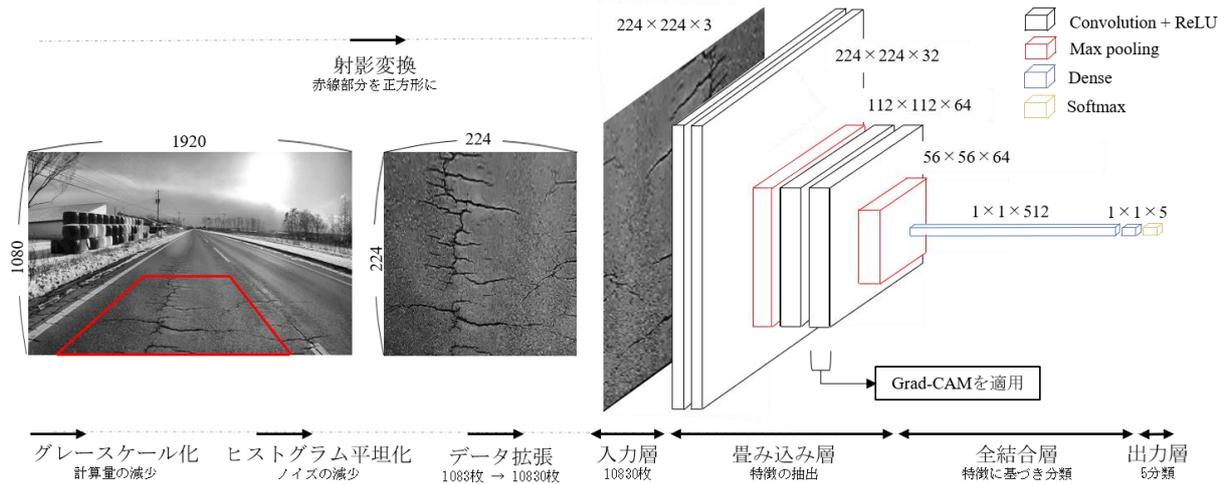


図-2 画像の前処理およびCNN4モデルの概要

本研究では、ひび割れ種類の判別モデルとして、畳み込み層 (Convolution) 4層のCNN (以下、CNN4) と、既存モデルである Vgg16⁵⁾を採用し、比較を行った。図-2には、本研究で構築したCNN4の概要を示している。両モデルの構築環境としては、OS: Windows10 Pro, CPU: Core i9-9900K, メモリ: 64GB であり、モデル構築に用いた言語、学習ライブラリは python3.6, keras2.24 である。

まず、CNN4モデルについて説明する。このモデルでは、畳み込み層を4層とし、max poolingを2回設定した。max poolingは、2×2のメッシュ毎に最大値を求め、圧縮することで、特徴量を維持しながらも、計算負荷を軽減する方法である。全結合層 (Dense) では、56×56ピクセルに圧縮する過程で抽出した64枚の特徴マップをベクトルデータとして処理する。畳み込み層の活性化関数にはCNNによる画像判別において最善であると言われている「ReLU」、出力層には「ソフトマックス数」、誤差を定義するロス関数には「交差エントロピー誤差」を採用した。判別クラス数は、図-1に示すひび割れ種類に対応するため、5クラスとした。

次に、Vgg16について概説する。深層学習は、CNNをベースに、層や活性化関数の組み合わせから様々なモデルが提案されている。判別精度を重視するなら、既存のモデルを利用する方法もある。その中で、Vgg16は、CNNのオープンアーキテクチャの一つであり、すでに100万枚を超えるイメージを学習させたモデルである。本研究ではこのVgg16を採用し、CNN4との精度比較を行う。Vgg16モデルでは、転移学習を適用し、全結合層のみでひび割れ種類の判別を学習させた。転移学習とは、ある領域の知識 (100万枚の多種多様な画像の特徴) を異なる領域の学習 (本研究ではひび割れ画像) に適用させる技術である。CNNの浅い層 (畳み込み層やプーリング層) では縦線・横線などのおおよその特徴を抽出し、深い層 (全結合層) で特徴に基づいた分類を行うことが知られている。100万枚の学習済みデータから特徴量を抽出する一方で、畳み込み層では学習を行わないため、短時間での学習が可能である。

最後に、上記2つのモデルにおける学習について説明する。本研究では、判別精度の向上のために、学習データの拡張を行った。これは、基の路面画像に対して、最大12度とした回転、水平・鉛直方向の反転や平行移動をランダムで行い、アングルの異なる画像を生成し、学習データを水増しする方法である。10倍の水増しを行い、計10,830枚の画像を得た。この内、8割の8,664枚をモデル学習データ、2割の2,166枚をテストデータに使い、バッチ数128、エポック数350で学習を行った。CNN4モデルにおける学習過程をみると、100エポック周辺で学習データでの正当率が70%、200エポック周辺で90%を超え、学習の収束が確認された。なお、Vgg16モデルでは、特徴量を1から抽出する必要が無いため、学習データは拡張前の1083枚の8割に当たる867枚を使用し、テストデータには2割にあたる216枚を用いる。

判別精度については、予測値と正解値の混合行列を作成し、正当率から両モデルの精度を評価、比較する。

2.3 Grad-CAMを用いた判別根拠の可視化方法

本研究では、深層学習によるひび割れ種類の判別だけでなく、その結果の根拠箇所を可視化する方法についても検討する。可視化するためのアルゴリズムとしては、Grad-CAMを採用した。Grad-CAMは、図-2に示した最後の畳み込み層において、判別結果に基づいた逆伝播を行い、勾配の重みを計算する手法である。判別結果に対する勾配が大きいピクセルは、予測値に大きな影響を与えるという発想の下で開発されたアルゴリズムであり、重要と判断されたピクセルに色付けすることで判別の根拠箇所をヒートマップとして可視化できる。なお、Vgg16では、最後の畳み込み層で路面画像を学習していないため、逆伝播による勾配を検出できずGrad-CAMを適用できない。CNN4モデルのみGrad-CAMを適用する。

可視化の精度については、ひび割れの種類ごとに判別根拠となる箇所を的確に抽出できているのかを、目視により5段階で評価する (評価1: 大きな抽出漏れ, 評価2: 一部抽出漏れ, 評価3: 的確に評価, 評価4: 一部過剰に抽出, 評価5: 過剰な抽出)。目視での評価は、本学学生3名で行い、その中央値を分析に用いる。

表-1 CNN4 モデルのテスト結果

正当率 93.3 n=2166枚		CNN4による予測値 単位：%				
		横線状	縦線状	亀甲状	融解期	無し
正解値	横線状	89.0	3.1	1.4	1.2	5.3
	縦線状	1.1	93.1	3.4	0.0	2.4
	亀甲状	1.5	5.4	91.3	1.1	0.7
	融解期	0.5	0.7	0.5	96.2	2.1
	無し	0.8	1.6	0.8	0.4	96.4

表-2 Vgg16 モデルのテスト結果

正当率 96.8 n=2166枚		Vgg16による予測値 単位：%				
		横線状	縦線状	亀甲状	融解期	無し
正解値	横線状	91.2	0.0	0.0	0.0	8.8
	縦線状	0.0	98.1	1.9	0.0	0.0
	亀甲状	0.0	0.0	100.0	0.0	0.0
	融解期	4.4	0.0	0.0	95.6	0.0
	無し	1.8	0.0	0.0	0.0	98.2

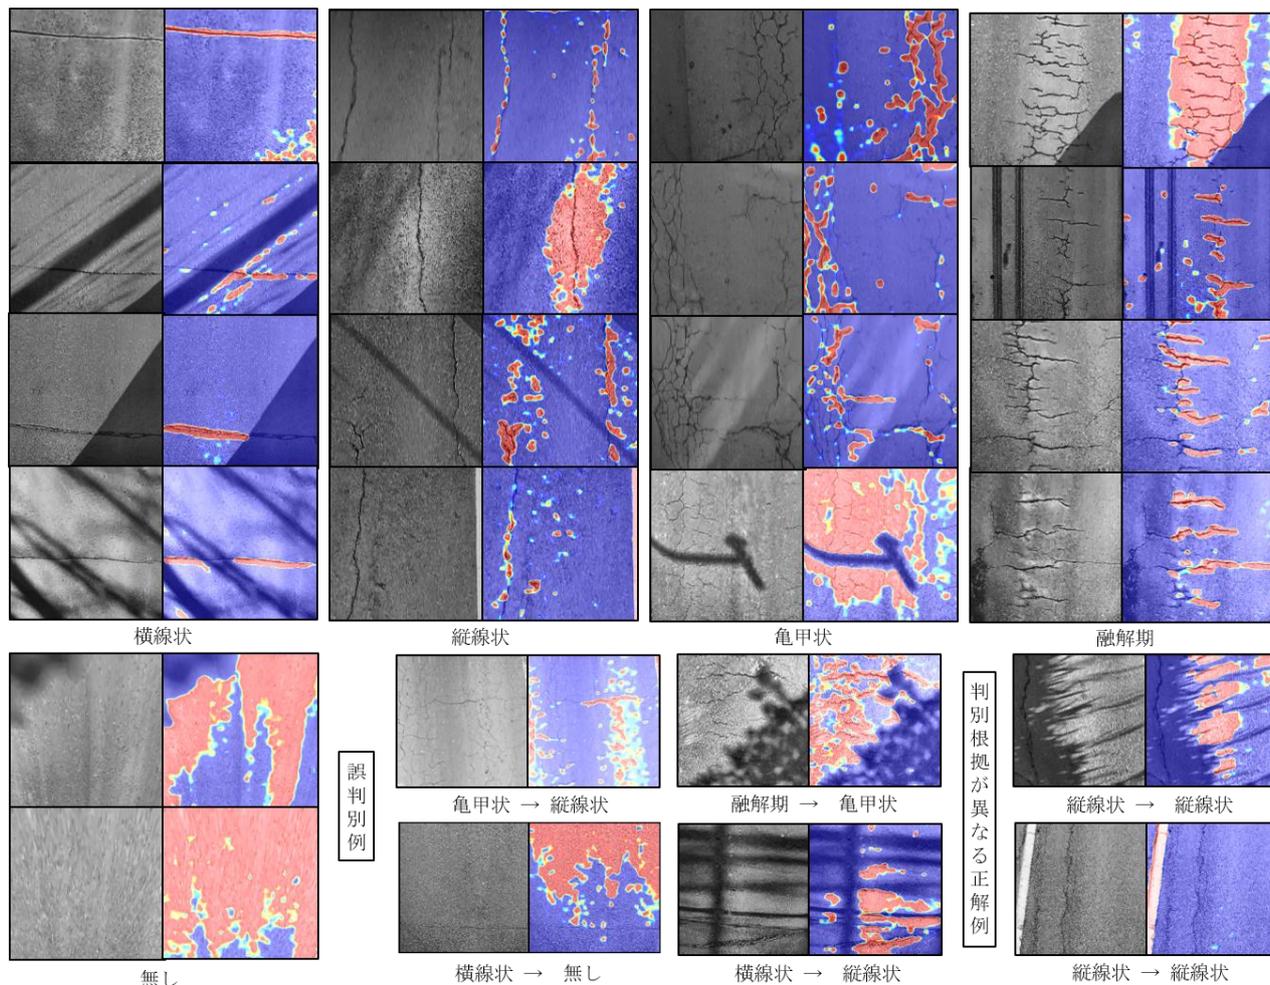


図-3 Grad-CAMによるひび割れ種類判別の根拠箇所の可視化(一例)

3. 結果と考察

3.1 深層学習によるひび割れ種類の判別精度

CNN4 モデルおよび VGG16 モデルのテスト結果を混合行列として、表-1および表-2に示す。CNN4モデルでは、表-1に示すように、正答率は93.3%となった。Vgg16では、表-2に示すように、正答率は96.8%となり、上記のCNN4モデルよりも精度が若干高くなった。したがって、単に、ひび割れ種類の判別を行う場合には、Vgg16を用いた方が良い結果が得られると言える。また、深層学習が画像のどのような箇所を重視して判別したのかわかれば、原因の解明や再学習による精度向上がしやすい。そこで、次節で示す判別根拠の可視化結果を基に、誤判別の原因についても考察を行う。

3.2 判別根拠の可視化の精度

上記のCNN4モデルにGrad-CAMを適用し、ヒートマップで可視化した画像の例を図-3に示す。赤く示された部分、特に色が濃いほど、逆伝播の勾配が大きく、判別への影響が大きかった箇所(以下、判別根拠箇所)を意味する。同図には、誤判別例および、正当しているものの判別根拠箇所が異なる例も示している。

まず、判別根拠箇所の傾向について分析する。図-3に示したように、「横線状」や「縦線状」と判別された画像では、1本毎にひび割れが判別根拠箇所として抽出されていることがわかる。また、「亀甲状」や「融解期」では、1本毎の場合やまとめて抽出される場合の2パ

ターンがある。これは、ひび割れの間隔や長さが関係していると考えられ、他の画像に適用した場合においても同様の傾向が確認された。また、いずれのひび割れ画像においても、電柱や車の影となる部分を判別根拠箇所として認識しないことが分かった。一方で、影に隠れたひび割れ部分も判断に含まれないことが分かった。全体的に暗い画像においては、ひび割れ部分のみを判断根拠にしていることから、1枚毎のコントラストの強弱が結果に大きく関与していると思われる。以上から、影が部分的であれば、CNNの判別に影響がないことが示されたが、影が全体に映り込む場合や、影の濃い部分にひび割れが隠れる場合、誤判別になる傾向が見受けられた。

以上は、代表的な結果であるため、種類ごとにテストデータから各25枚を抽出し、定量的な可視化精度について検証した。本学学生3名による目視評価の結果を図-4に示す。全体として、大きな抽出漏れや過剰な抽出は少なく、「横線状」「融解期」「縦線状」においては、約3~5割が的確に抽出されていた。「亀甲状」は、的確に可視化されていた割合は1割程度であるが、面的なひび割れであるため、部分的な抽出漏れや過剰な抽出が多いことがわかる。

上記の「亀甲状」については、「縦線状」と誤判別される場合が多い(表-1,2)。これらの判別根拠箇所から、CNNがどのように判別したのかを調べる。図-3に示した可視化結果の例から、原因は2つ挙げられる。1つ目に、亀甲状と判断されるべき、疲労ひび割れ(終局)等のコントラストが薄く、一部のみが判断された結果、縦線状の疲労ひび割れ(初期)と誤判断された場合である。2つ目に、本研究では射影変換部分を著者が決定しているため、該当部分が狭まり、ひび割れが減少したことによる誤判断である。また、「横線状」を「無し」と判別した場合も多く確認された。これは、ひび割れのコントラストが薄く、CNNが判断できなかったことが原因である。出勤時間帯や走行速度などの撮影条件をより厳密に管理することで、精度の改善が期待できる。

3.3 本手法の有効性

最後に、本研究で検討した深層学習による舗装ひび割れ種類の判別と、判別根拠箇所の可視化に関する有効性について考察する。

まず、深層学習を導入することにより、判別が自動されるため、舗装診断の効率化が期待できる。現在、舗装診断士が目視による路面の点検を行っているが、有資格者の数は少なく、膨大な路面延長を診断するには、自動化によるスクリーニングが支援ツールとして有効である。

ただし、深層学習などのようなAIモデルでは、判別の根拠を説明することは難しいとされている。そこで、本研究では、ひび割れ種類の判別とともに、その根拠となる箇所の可視化を行った。これにより、誤判別の原因を調べることが容易となり、モデルの精度向上や撮影条件の検討に利用できる。また、舗装診断士のような熟練者による教師データからAIが学習できれば、多くの路面画像から、判別結果と可視化画像が得られ、舗装診断士や点検従事者などの教育ツールとして利用できると思われる。さらに、このような「説明可能なAI」により、

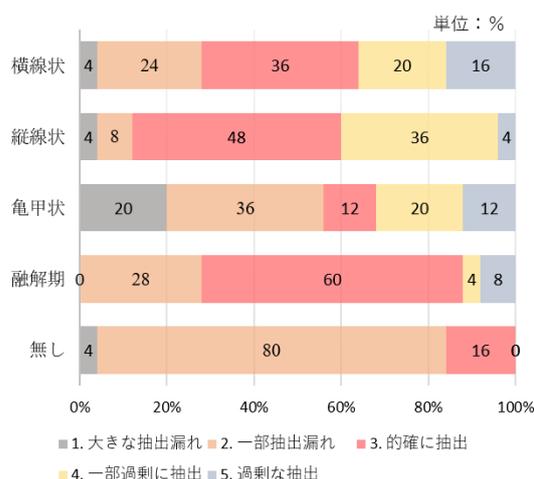


図-4 判別根拠箇所の可視化の精度

診断業務の効率化が期待できるだけでなく、信頼性の高い点検・診断データベースの構築や道路利用者・納税者への説明責任にも役立つと考えられる。

4. まとめ

本研究では、路面画像に深層学習(中間層4層のCNN4およびVgg16に転移学習させたCNN)を適用し、舗装ひび割れの種類を判別するモデルについて、精度検証を行った。いずれのモデルでもテストにおける正当率は約95%と高く、精度良く判別できることがわかった。さらに、上記のCNN4にGrad-CAMを適用して、判別根拠箇所の可視化を行ったところ、Grad-CAMは、舗装ひび割れにも適用が可能であることが示された。

今後は、舗装診断士によるWEB診断試験結果を用いて、ひび割れ種類の判別および判別根拠箇所の可視化について精査を行う。さらに、ひび割れの種類は他にもあることから、画像だけではなく、気象条件や供用年数といった情報をモデルに入力するなど、マルチモーダル型の深層学習モデルを構築し、精度向上を図りたい。

参考文献

- 1) 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ブ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, 1_97-1_105, 2017.
- 2) 国土交通省: 「路面性状を簡易に把握可能な技術」の試験結果を公表します~新技術の活用に向けて~, 試験結果等比較表(別紙-2), 2018.
- 3) 浅田拓海, 居駒薫樹, 長屋弘司, 亀山修一: U-netによるひび割れスケッチを導入した簡易カメラ搭載型舗装点検の精度検証, 土木学会論文集 E1 (舗装工学), Vol.76, No.2, pp.1_123-1_131, 2020.
- 4) 舗装点検必携平成29年版: 公益社団法人日本道路協会, 丸善出版株式会社, 2018.
- 5) Ramprasaath R. Selvaraju, Michael Cogswell, Abhishek Das, Ramakrishna Vedantam, Devi Parikh, Dhruv Batra: Grad-CAM: Visual Explanations from Deep Network Via Gradient-based Localization, 2016.