

# 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

浅田 拓海<sup>1</sup>・川村 和将<sup>2</sup>・石田 篤徳<sup>2</sup>・亀山 修一<sup>3</sup>

<sup>1</sup>正会員 室蘭工業大学助教 大学院工学研究科 (〒050-8585 室蘭市水元町27-1)

E-mail: asada@mmm.muroran-it.ac.jp

<sup>2</sup>正会員 中日本高速道路株式会社 東京支社 (〒105-6011 東京都港区虎ノ門4-3-1)

<sup>3</sup>正会員 北海道科学大学教授 工学部都市環境学科 (〒006-8585 札幌市手稲区前田7条15丁目4-1)

本研究では、路面性状測定車による高速道路の路面画像にConvolutional Neural Network (CNN) を適用し、ひび割れとパッチングを高精度で検出し、ひび割れ率を自動算出する手法を開発した。まず、目視スケッチ画像を基にひび割れ部等の小片領域を抽出し、CNNモデルの学習用データセットを自動生成した。小片領域サイズを複数設定し、モデルの精度比較を行ったところ、サイズ150以上では過学習となる可能性があり、90~120などの中間サイズではひび割れやパッチングの見逃し、誤検知が比較的少なくなることが分かった。モデルを路面画像に適用してひび割れ率を算出し、従来のスケッチ法と比較した。その結果、サイズ90 (実寸3cm×3cm) で最も精度が良く、ひび割れ形状を細かく可視化できることを示した。

**Key Words :** pavement, crack, tracing, convolutional neural network, high resolution

## 1. はじめに

近年、インフラの老朽化、維持管理への関心が高まっており、道路舗装においては、地方部においても持続可能なメンテナンスサイクルを構築し、予防保全型の維持管理体制を整えることが喫緊の課題となっている。特に、維持管理の基本である点検業務は、その頻度増加とともに、低コスト化・簡易化が求められている。

このような背景の下、平成 28 年 10 月には、国土交通省道路局により舗装点検要領が策定され、目視や体感などの低コスト・簡易な点検が加えられた<sup>1)</sup>。また、道路を A~D の 4 つに分類し、それらの特性に応じた点検、診断、措置、記録のメンテナンスサイクルを構築することが定められている<sup>2)</sup>。その中で、分類 A に対応する高速道路については、高速走行によって目視等の点検が難しいため、路面性状測定車などの機器を用いた点検を基本とする、と明記されている。この路面性状測定車では、ひび割れ、平坦性、わだち掘れの 3 つの路面性状が計測され、それらのデータから詳細な点検・診断が可能である。しかしながら、ひび割れに関しては、撮影された路面画像を用いて、目視によるスケッチ、評価メッシュ内の本数判定を行ってひび割れ率が算出されている。橋梁やトンネル等を合わせた道路全体のメンテナンスサイ

クル構築を考えると、舗装点検における上記のような作業コストの低減は必要不可欠となろう。

道路舗装のひび割れ評価では、舗装点検要領の策定以降、車載カメラ撮影による低コスト・簡易な調査手法や画像解析によるひび割れ解析などの研究<sup>3,4)</sup>、開発が活発化しているが、既存手法との整合性や実際のデータに基づく信頼性の高い手法は少なく、また、高速道路舗装を対象とした手法はほとんど報告されていない。既往の研究としては、例えば、著者らの動的 2 値化法を用いたひび割れ解析手法<sup>5)</sup>や塙らによるメディアンフィルタを用いた手法<sup>6)</sup>などがある。これらの手法では、車載カメラ方式のため点検の低コスト化が期待できるものの、低解像度な画像および簡易な画像解析のため、影や汚損などのノイズの影響や不明瞭なひび割れの見逃しなどの課題が残っている。また、上記のような古典的な画像認識では、分析者が画像特徴量や各種解析パラメータを設定し、それらを各種モデルに入力してひび割れ等を検出するため、モデルの汎用性が低く、見直しや改善が困難となることが指摘される。一方、昨今、画像認識技術において、Autoencoder や Convolutional Neural Network (CNN: 畳み込みニューラルネットワーク) などの Deep learning の導入が着目されており、画像特徴量等の設定が不要な自己学習モデルにより、ひび割れ検出を試みた研究事例も幾つ

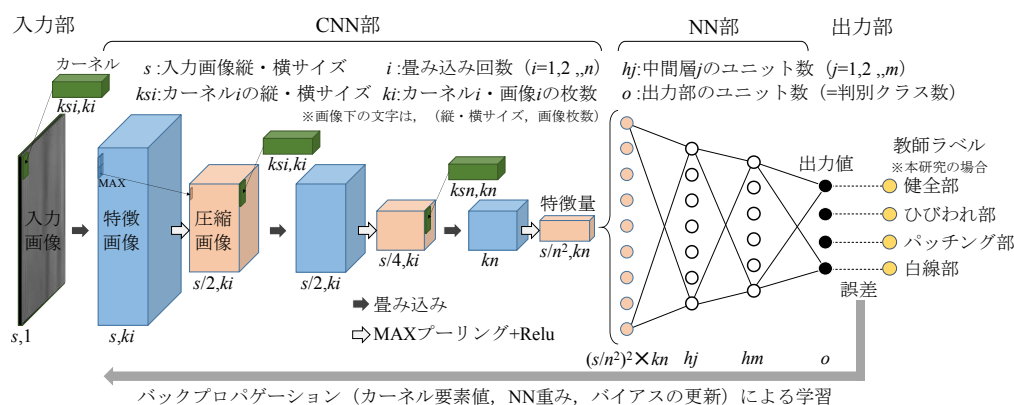


図-1 CNNモデルの概要

か報告されている。全らは、その代表的なアルゴリズムである CNN を用いて、車載カメラから撮影した路面画像からひび割れ箇所を検出し、その面積率からひび割れ状態を3段階評価する手法を開発している<sup>7)</sup>。しかしながら、上記のような Deep learning 等を用いた舗装ひび割れ研究では、パッチングの検出対象となっていないことなどから従来のひび割れ率との整合性が検証されていない場合が多い。また、一般道路を対象に簡易・迅速な路面点検を目的とした手法が多い一方、ひび割れの形状を細かく検出するようなアプローチやテクスチャの異なる高速道路舗装への適用を試みた事例は少ない。

舗装の予防保全型維持管理を考える上では、管理路線を網羅的に点検した上で、各所の劣化原因とその後の進行を推察・予測<sup>8)9)10)</sup>し、補修・修繕のタイミングや工法を適切に判断することが重要となる。ひび割れにおいては、ひび割れの縦横の方向、亀甲状などの形状パターンからその発生原因が類型化されており、重要な診断材料として扱われる。膨大な画像枚数を相手に、上記のような診断を効率的に行うためには、Deep learning 等の画像解析によりひび割れ線の検出やひび割れ率算出を自動化するだけでなく、ひび割れやパッチングの形状が把握できるような細かい検出（以下、高精度検出）が有効と考えられる。

本研究では、路面性状測定車によって撮影された高速道路舗装の路面画像に CNN を適用し、ひび割れとパッチングを高精度で検出する手法を開発する。さらに、検出後の画像から従来手法に基づいてひび割れ率を自動算出し、その精度や検出結果の視認性から本手法の妥当性および有効性を示す。以下は、本稿の章構成である。まず、第2章では、CNNについて解説し、その導入理由について述べる。第3章では、CNNによるひび割れやパッチングの判別対象となる画像のサイズ（判別画像サイズ）の設定やひび割れ評価の流れについて説明した後、モデルの学習・テストの結果を示す。第4章では、学習済みモデルを路面画像に適用してひび割れとパッチングを検出して従来手法に基づくひび割れ率を算出し、その精度

と視認性から最適な判別画像サイズについて検討する。第5章では、本研究の結論を述べる。

## 2. CNNの概要

本研究では、ひび割れとパッチングを検出し、自動的にひび割れ率を算出する手法を開発する。入力データが画像となることから、昨今、画像認識の強力なアルゴリズムとして注目されている CNN を導入する。

従来の画像認識では、対象画像から SIFT（Scale-Invariant Feature Transform）や各種統計量などの人為的な画像特徴量（Hand-crafted 特徴）を設定、算出し、それらをニューラルネットワーク（以下、NN）などの判別器に入力し、その出力値と教師ラベル（入力画像に対する判別の答えとなる情報）の関係から誤差最小化による学習モデルが一般的である。しかし、画像特徴量の設定は、分析者の経験や主観、試行錯誤に頼ったものであり、また、分析対象が変わると都度見直しが必要であるなど、運用上の欠点がある。一方、CNN は、学習の中から自動的に画像特徴量を生成する手法である。そのため、モデルの精度向上が必要になる場合、最初に設定したモデル構成はそのままに、追加の学習データを与えるだけで、改善を行うことができる。舗装路面は、材料や工法など区間毎にそのテクスチャが異なるため、対象区間が広がり、新たなパターンが現れる度にモデルの再学習、追加学習が必要と予想される。このような対象には CNN が有効と考えられる。

CNN モデルの概要を図-1 に示す。このモデルは、画像特徴量を抽出する CNN 部と通常の NN（ニューラルネットワーク）部が一体となった層構成を有する。CNN 部では、画像への2次元フィルタ（カーネルによる畳み込み）と画像圧縮（プーリング）を行う層を複数設定し、これらの繰り返しにより、画像情報を圧縮して特徴量を算出する。その特徴量をベクトル化して NN 部に入力し、多クラス判別が行われる。学習時は、入力画像と教師ラ

ベルを与え、その誤差をバックプロパゲーションにより処理することで、各層のパラメータ、すなわち NN 部の重みとバイアス、CNN 部のカーネル要素値が更新される。多様なパターンを入力画像と教師ラベルの組み合わせで構成したデータセットを与えることで、誤差が最小となるように最適化される。学習後は、対象画像をモデルに入力し、出力値として各クラスの判別率が得られ、それが最大となるクラスを判別結果とする。

通常の NN では、入力画像をベクトル化して入力することで多クラス判別が可能となる。しかしながら、例えば、判別すべき対象（例えば文字）が 1 ピクセルでも移動すると、ベクトルデータ上では大きく構成が変わり、同じ視対象でも全く違うものとして処理される。これに対し、CNN では、畳み込みとプーリングによって対象の位置関係を曖昧化した後に NN に入力することで、上記のような位置ズレや回転による影響が低減される。すなわち、人間の視覚と同様に曖昧さを考慮して対象の判別が実現できるため、高精度となることが知られている。

より詳しい解説は、文献 12)、13)などを参照されたい。また、本研究におけるモデルの構成および各種の設定については、第 3 章で説明する。

### 3. CNNモデルの学習

本研究で用いるデータは、路面性状測定車によって撮影された路面画像および舗装調査・試験法便覧の路面性状測定車によるアスファルト舗装を対象とした目視によるスケッチ手法<sup>11)</sup>（以下、従来目視法）によるひび割れ評価の結果であり、これらを中日本高速道路株式会社（以下、NEXCO 中日本）から取得した。本研究における CNN モデルによるひび割れ評価手法（以下、CNN 法）の概要を図-2に示す。

まず、路面画像（元画像）に加えて、モデルの学習および精度検証のための目視スケッチ画像を用意する。図中 a に示すように、路面画像を PC 上でスケッチし、ひび割れ線、パッチング、白線、解析から除外する箇所を異なる色でトレースまたはマスキングする。このトレース・マスキング箇所の画素値（RGB 値）を基に、元画像から「ひび割れ部」、「パッチング部」、「白線部」、それ以外の「健全部」の 4 種類の路面状態を示す小片領域を元画像から自動的に複数枚抽出し、入力画像として保存する。図中 b に示すように、入力画像とそれら画像に対応する教師ラベル（「健全部」「ひび割れ部」「パッチング部」「白線部」）から成るデータセットが生成される。本研究では、CNN による検出の細かさを検討するため、判別対象となる小片領域のサイズ（判別画像サイズ）を 8 つのパターンで設定し、それぞれデータセ

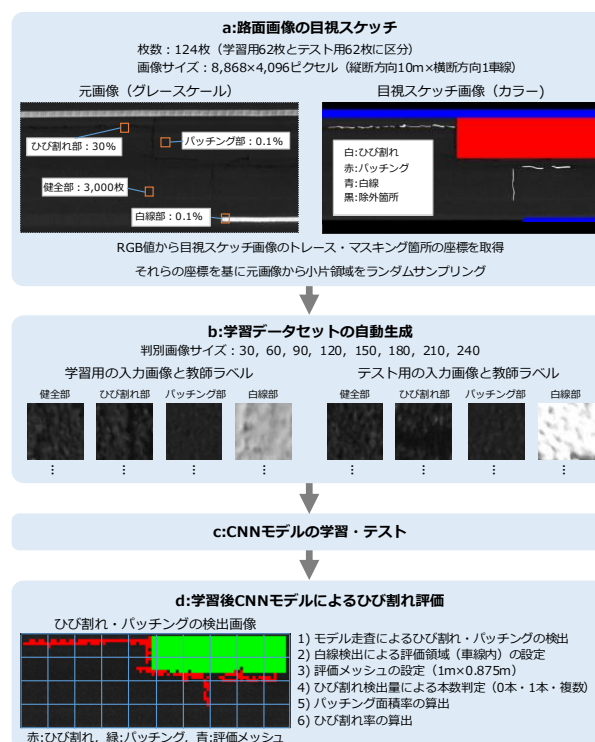


図-2 本手法によるひび割れ評価の流れ

ットを作成した（図中 b）。これらのデータセットを用いてモデルの学習およびテストを行い、モデルの精度を確認する（図中 c）。最後に、図中 d に示すように、1) 路面画像にモデルを走査させながら適用して、ひび割れとパッチングの検出画像を生成する。2) ひび割れの評価対象領域を定め、3) メッシュを描いた後、4) ひび割れ本数の判定、5) パッチング面積率の計算を行い、6) 最後に、ひび割れ率を求める。以下では、「a: 路面画像の目視スケッチ」から「c: CNN モデルの学習・テスト」までの手順および分析結果について述べる。

なお、開発言語は Python3 であり、基本的な画像処理には OpenCV、CNN モデルには深層学習ライブラリである Keras (Tensor Flow-gpu) を利用した。使用した PC の CPU は Intel Core i7、GPU は GeForce GTX 1080 Ti である。

#### (1) 目視スケッチ画像と判別クラス

本研究では、図-2a に示したように、路面性状測定車のカメラにより撮影された高速道路の路面画像（グレースケール変換後）を用いる。この画像は、10m 区間毎に分割されており、1 枚のサイズは、縦断方向 8,868×横断方向 4,096 ピクセルである。対象路線は、東名高速道路であり、既存の路面性状データを基に、ひび割れ率およびパッチング面積率のばらつきを考慮して 124 枚の画像を選出した。

路面性状測定車によるひび割れ評価では、その過程で目視によるひび割れとパッチングのスケッチ画像（図-2a）が作成される。本手法では、このスケッチ画像を

利用した学習データセットの自動生成を行うことから、NEXCO 中日本より元画像とスケッチ画像をセットで取得した。さらに、車線内に白線が存在することが稀にあり、ひび割れ部やパッチング部と分離する必要があることから、白線部の判別をモデルに組み込むこととした。図-2a に示したように、区画線などを含む全ての白線部について、マスキングを追加した。また、車線外側は、評価対象外であるため、この部分を分析から除外するためにマスキングを行った。

以上のように、本研究では、「ひび割れ部」、「パッチング部」、「白線部」、それ以外の「健全部」の4つの路面状態と対象とした4クラス判別モデルとした。

## (2) 判別画像サイズ

本研究では、ひび割れとパッチングを小片領域毎に判別する手法について検討する。そこで、小片領域のサイズ、すなわちモデルに入力する画像のサイズ（以下、判別画像サイズ）を複数パターン設定し、モデル自体の精度、ひび割れの形状視認性および評価の精度について比較を行い、最適な判別画像サイズを明らかにする。既往の研究では、実路面の0.3m×0.3m程度の粗いメッシュ毎でひび割れ有無の判定が行われている<sup>7)</sup>。本研究では、図-2b に示したように、判別画像サイズを30×30ピクセル（実路面で約3×3cm）から240×240ピクセル（実路面で約27×27cm）までの8段階のパターンでモデルを構築し、比較する。

## (3) 学習用データセットの自動生成

CNN などのような機械学習モデルでは、モデルの学習と精度検証（テスト）のために、それぞれ路面画像を用意する。本研究では、全124枚の路面画像をランダムサンプリングにより半分に分け、学習用とテスト用とした。

ひび割れやパッチング箇所のテクスチャ、画像のパターンは複雑であることから、未知のデータに対して精度良く判別できるモデルを構築するためには、大規模な学習データセットがあれば望ましい。しかし、特に、教師ラベルは、人の目視判定により設定されることから、データセットの構築には、大きな時間と手間が生じる。そこで、本研究では、図-2a に示した目視スケッチ画像を用いて、学習データセットを自動かつ大量に生成する方法を考えた。デジタル画像では、ピクセル毎にR・G・Bの3原色の要素の値（0～255の整数値）の組み合わせで色が表現される。したがって、このRGB値を基に、「ひび割れ部」、「パッチング部」、「白線部」のトレース・マスキング箇所および、それ以外の「健全部」の画像上の座標（縦・横方向のピクセル）が自動的に取得できる。これらのピクセルを中心点とするように小片領

表-1 学習に用いる画像枚数

●学習用（路面画像番号奇数番：62枚）

画像縦横 ピクセル	実寸 cm	健全	ひび割れ	パッチ ング	白線	合計
30	3.3	186,000	196,868	84,098	149,651	616,617
60	6.7	186,000	168,184	81,425	136,922	572,531
90	10.0	186,000	150,736	78,932	124,486	540,154
120	13.3	186,000	136,210	76,566	111,855	510,631
150	16.7	186,000	123,920	74,114	99,901	483,935
180	20.0	186,000	112,776	71,430	88,369	458,575
210	23.4	186,000	103,059	69,226	76,620	434,905
240	27.7	186,000	94,297	66,912	64,913	412,122

●テスト用（路面画像番号偶数番：62枚）

域を設定し、モデルへの入力画像として保存した。

上記の方法では、各部のスケッチ・マスキング箇所のピクセル量が大きく異なるため、各クラスの抽出画像枚数に偏りが生じ、モデルの学習が適切に行えない可能性がある。また、路面画像内のスケッチ・マスキング箇所の全ピクセルから抽出を行うと、画像枚数が膨大となり、本研究で用いるPCのスペックでは処理が困難となる。そこで、小片領域をスケッチ・マスキング箇所の全ピクセルから抽出するのではなく、図-2a に示したように、クラス毎に抽出率（スケッチ・マスキング箇所の全ピクセル量に対する抽出対象ピクセル量の割合）を設定して、それぞれランダムサンプリングを行った。これを学習用およびテスト用の路面画像でそれぞれ行い、データセットを構築した（図-2b）。抽出した学習用の画像枚数を表-1に示す。一つのモデル当たり、約2時間程度でおよそ50万枚の画像を自動的にかつ迅速に生成することができた。なお、テスト用もほぼ同じ枚数が抽出された。

## (4) CNNモデルの構成

CNNのようなDeep learningでは層を増やすほど精度が得られるが、その分、解析コスト・時間が膨大になる。本手法では、モデルを路面画像の小片領域毎に適用する。図-1に示したように、CNN部の畳み込み→MAXプーリングの繰り返しを3回に設定し、比較的軽量の層構成とした。入力画像の縦・横サイズ（判別画像サイズ）をそれぞれ $s$ ピクセルとする。畳み込みのカーネルサイズ $k_{si}$ と枚数 $k_i$ は、全ての畳み込み部で5×5ピクセル、50枚とした。MAXプーリングは、2×2のメッシュ毎に最大値を求め、画像を圧縮する方法である。したがって、上記の場合では、最終的な画像縦・横サイズは入力画像の8分の1にまで圧縮され、50枚の圧縮画像が生成される。

なお、MAXプーリング後には、活性化関数が適用される（図-1）。活性化関数としては、シグモイド関数やtanhなど様々なものが提案されているが、本研究では、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<sup>12)</sup>を採用する。上記の最終画像群をベクトル化し、NN部に入力する。NN部の中間層は2層とし、それぞれ500、300ユニットとした。出力部は、本モデルで対象と



する「健全部」，「ひび割れ部」，「パッチング部」，「白線部」の4つのクラスに合わせ，4ユニットとなる．出力値と教師ラベルを基に，Softmax 関数により誤差を算出する<sup>12)</sup>．Softmax 関数は，ニューラルネットワークで分類問題を解く場合に通常用いられる活性化関数である．パラメータ更新の最適化には，様々な手法があるが，比較的性能が良いと言われている Adam<sup>13)</sup>を採用する．

学習方法としては，ミニバッチ学習を採用し，バッチ数を 100，ステップ数を 1000，エポック数を 2,000 とした．エポック数とは，一つの学習データセットで繰り返し行う学習回数であり，CNN 等のニューラルネットワークの学習においては重要な単位となる．1 エポックの中では，全学習データから，バッチ数分をランダムサンプリングした画像をモデルに入力し，教師ラベルと照らし合わせて誤差が算出され，これがステップ数分繰り返される．したがって，上記の設定で，各小片画像サイズの合計枚数（表-1）に対し，ほぼ全ての画像がモデルの学習に利用されることとなる．エポック内で使用した画像枚数に対して正答（出力された判別結果と教師ラベルが一致）となった枚数の割合をエポック内正答率として算出した．なお，使用した PC では，一つのモデルの学習時間が 2～3 時間程度であった．

## (5) モデル精度と判別画像サイズの関係

各モデルの学習過程を図-3 に示す．エポック内正答率の遷移を見ると，100 エポック周辺で 75%を超え，2,000 エポック周辺でも増加が見られるが，その増加は微小である．そこで，2,000 エポックで学習を終了することとした．最終的には，判別画像サイズが 120 以下では，サイズが大きいほどエポック内正答率が高くなり，150 以上ではさらに高いことが分かる．

学習後のモデルをテストデータに適用し，判別結果の内訳を調べた．一例として，判別画像サイズ 120，240 の判別正誤表を表-2 に示す．表中の網掛け部の合計が正答率（以下，テスト正答率）となる．また，ひび割れ部とパッチング部の誤検知と見逃しについて検討するため，これらの割合を求めた．例えば，表-2 のサイズ 120 に示したように，目視スケッチによるひび割れ部の合計（表中太枠）に対する，その内の CNN によるひび割れ部以外の合計の割合がひび割れの「見逃し率」となる．また，サイズ 240 に示したように，CNN によるひび割れ部の合計（表中太枠）に対する，その内の目視スケッチによるひび割れ部以外の合計の割合をひび割れの「誤検知率」として算出した．

テスト正答率，誤検知率，見逃し率を図-4 に示す．学習時における最終的なエポック内正答率は，判別画像サイズ 150 以上が 120 以下よりも高くなった（図-3）が，テスト正答率ではサイズ 120 でピークとなり，それ以上




図-3 各モデルの学習過程（学習データ）

表-2 判別正誤表（テストデータ）

判別画像サイズ120		単位：％			
テスト正答率：89.8%		目視スケッチ			
		健全部	ひび割れ部	パッチング部	白線部
CNN	健全部	22.9	5.3	1.5	0.3
	ひび割れ部	1.5	18.8	0.0	0.0
	パッチング部	0.6	0.3	23.4	0.0
	白線部	0.1	0.6	0.1	24.7
判別画像サイズ240		単位：％			
テスト正答率：87.0%		目視スケッチ			
		健全部	ひび割れ部	パッチング部	白線部
CNN	健全部	24.6	7.3	3.2	0.0
	ひび割れ部	0.3	15.7	0.0	0.0
	パッチング部	0.1	0.3	21.8	0.0
	白線部	0.0	1.6	0.0	25.0




図-4 テスト正答率，誤検知率，見逃し率の比較

では低くなる．したがって，判別画像サイズが 150 以上では過学習となり，未知データ適用時の信頼性が低いと言える．

図-4 に示したように，ひび割れ部の誤検知率は，サイズ 30 で約 17%となるが，サイズ 60 以上では，10%以下に低下する．一方，見逃し率は，サイズ 90，120 が最も低くなるものの約 25%を示した．すなわち，4 箇所の内

1 箇所が見逃しとなり、ひび割れの検出が歯抜け状になる可能性があるが、1m 程度の大きなメッシュ毎にひび割れの本数を数える場合には、ひび割れ率に大きな影響はないと考えられる。サイズ 150 以上になると、見逃し率が高くなり、また、粗い検出となるため、ひび割れ率への影響は大きいと推測される。なお、このような判別画像サイズとひび割れ率の関係については第 4 章で検討する。ひび割れ評価では、ひび割れの見逃しは最も危惧される事項であることから、実用化を進める上では、学習データの追加、再学習により見逃し率を低下させることが重要となる。

次に、パッチング部の誤検出率は、サイズ 30 と 210 以外では 5%以下となった（図-4）。また、見逃し率は、サイズ 90～210 で 10%以下となり、サイズ 120 では最小の約 6%となった。これらのモデルでは、ひび割れ部よりもパッチング部の方が精度良く検出できると言える。パッチング箇所は、通常路面（ポーラスアスファルト舗装）とは異なる材料で補修された部分であり、テクスチャが異なり、また、通常路面との境界が直線的である。上記の中間サイズのモデルでは、CNN 部でこれらの特徴が的確に抽出されているものと思われる。

## 4. CNNモデルによるひび割れ評価

### (1) 従来のひび割れ評価手法（従来目視法）

対象路線では、舗装調査・試験法便覧の路面性状測定車によるアスファルト舗装を対象とした目視スケッチによる手法<sup>1)</sup>（従来目視法）を基に、以下の手順でひび割れ率の計算を行っている。まず、撮影画像を参照しながら、ひび割れやパッチングを目視でスケッチする。次に、車線範囲に縦断方向1m×横断方向0.875m（車線4分割）の評価メッシュを描き、メッシュ毎にひび割れの本数（0本、1本、複数本）を目視で判定し、ひび割れ面積を算出する。ひび割れ面積は、ひび割れが1本の場合は当該評価メッシュ面積×0.3、複数本の場合は当該評価メッシュ面積×1として算出し、さらに、パッチング面積を加えて合計する。パッチング面積は対象マスキング部のピクセル量から求める。これらの値を基に、ひび割れ率を以下の式(1)で算出する。

$$\text{ひび割れ率 (\%)} = \frac{\text{ひび割れ面積 (m}^2\text{)}}{\text{評価対象区画面積 (m}^2\text{)}} \quad (1)$$

### (2) 本モデルによるひび割れ評価手法（CNN法）

図-2d「学習後 CNN モデルによるひび割れ評価」に示したように、路面画像に、学習後の CNN モデルを判別画像サイズのメッシュ毎に走査させながら適用して、ひ

び割れ部とパッチング部を検出し、それぞれのメッシュを着色する。CNN モデルの出力値では、全クラスで合計 1 となるように、各クラスに判別率が割り当てられる。ここでは、判別率が 0.5 以上となるクラスを当該箇所の路面状態とした。

次に、元の路面画像を用いて、ひび割れ評価の対象範囲となる車線部（以下、評価領域）を抽出する。具体的には、両側にある区画線の RGB 値からその位置を特定し、モデルによる検出画像から車線部を自動的にクロップする方法である。この画像に従来目視法と同じサイズの評価メッシュを自動的に描く（図-2d）。なお、パッチング面積は、検出により着色された部分のピクセル量から求める。

評価メッシュ内のひび割れ本数については、CNN 法によるひび割れ部の検出量で自動判定を試みた。NEXCO 中日本から取得したデータには、目視によるひび割れスケッチに加えて、評価メッシュ毎のひび割れ本数の目視判定結果が含まれている。そこで、上記の自動判定のための閾値（以下、判定閾値）を設定するために、全 124 枚の目視スケッチ画像とそれらの本数判定結果を用いて、評価メッシュ内のひび割れ本数とひび割れ検出量の関係について分析した。具体的な方法を以下に示す。

まず、目視スケッチ画像において、判別画像サイズのメッシュ毎にひび割れスケッチ線（白）をその RGB 値から検出し、当該メッシュを赤で着色する。これによって CNN 法と同じようなひび割れ検出画像（図-2d）が作成される。次に、評価メッシュ毎に、ひび割れ検出部が占める割合（以下、ひび割れ検出面積率）を算出する。目視による本数判定結果を基に、上記の全評価メッシュを、本数 0 本、1 本、複数本の 3 つに分け、それぞれひび割れ検出面積率の相対度数分布を作成した（図-5）。

まず、本数 0 ではひび割れ検出面積率が 0～8%程度の小さい範囲に分布し、1 本、複数本となるにつれて、値が大きい方にシフトすることが分かる。これらの分布範囲の切り替わり箇所に閾値を設定することで、本数の誤判定を最低限に抑えることができると考えられる。そこで、ひび割れ検出面積率 0%から順に、本数 0 と 1 本で相対度数を比較していき、1 本の方が初めて大きくなる値を両者の判定閾値として設定した。同様に、1 本と複数本についても求めた。これらの閾値は図-5に示してある。例えば、サイズ 90 では、ひび割れ検出面積率 3%未満の評価メッシュは「ひび割れ無し」、3%以上 15%未満の場合は「ひび割れ 1 本」、15%以上は「ひび割れ複数本」として判定される。

### (3) ひび割れ率の精度

パッチング面積率（評価領域に対するパッチング検出面積の割合）およびひび割れ率に関して、従来目視法と

CNN法の関係について分析した。ここでは、CNNモデルの学習に用いていないテスト用の路面画像62枚を用いる。判別画像サイズで精度を比較するため、パッチング面積率とひび割れ率について、それぞれ従来目視法とCNN法による両値の相関係数 $R$ を求めた。また、従来目視法による値を真値とみなして、CNN法の $RMSE$ （Root Mean Square Error）を算出した。

$R$ と $RMSE$ を図-6に示す。パッチング面積率では、全判別画像サイズにおいて $R$ が0.9以上となり、 $RMSE$ は約3%となったことから、CNN法によりパッチング面積率を精度良く算出できると言える。一方、ひび割れ率（全62枚）では、 $R$ がおおよそ0.5から0.8の間にあり、パッチング面積率よりも低い値となった。 $RMSE$ （全62枚）は、サイズが大きいくほど小さくなる傾向が見られるが、サイズ210以外では、約10%以上となり、精度が良いとはいえない。

精度を低下させる原因を探るため、両手法の値を散布図に示し、誤差が大きい画像を特定した。一例として、判別画像サイズ90、150、210を対象に、両手法による値の関係を図-7に示す。同図には、誤差の大きい路面画像の番号をプロットしてある。また、両手法による検出画像の一例を図-8に示す。

図-7のように、パッチング面積率に関しては、大きな誤差がほとんど無く、1対1の線付近にプロットされていることが確認できる。ただし、図-8の路面画像No.46のように、CNN法では、判別画像サイズが大きくなるほど検出が粗くなるため、パッチングの境界付近が検出されず、パッチング面積率が過少となる傾向がある。したがって、小さいパッチングへの対応を考えると、判別画像サイズは小さい方がよい。

次に、ひび割れ率について検討する。相関係数 $R$ 、 $RMSE$ が共に最も良好であったサイズ210では、大きな誤差が無い（図-7）。一方、サイズ90や150では、路面画像No.2、52、112のCNN法による値が従来目視法よりも20%以上大きくなった。一例として、図-8にはNo.52の検出結果を示してある。これを見ると、特に、サイズ90、150でひび割れ部の誤検出が目立つ。これは図-4で示した結果と符合する。この誤検出の箇所を調べたところ、舗装の劣化による骨材剥離が生じていた。骨材剥離の箇所では、細かく短いひび割れが散在するように見え、CNNモデルにおいてもひび割れ部として誤検出されてしまい、ひび割れ率が過剰となる。このような本モデルで判別対象としなかった損傷パターンについては、それらを含む画像を用いて学習を行うことで誤検出を低減できると考えられる。

本研究で検出対象としたひび割れに着目した結果を示すために、骨材剥離が顕著に存在する路面画像No.2、52、112を除外して、相関係数 $R$ と $RMSE$ を再度算出した（図-6）。判別画像サイズ180以上では、全62枚の場合と大き

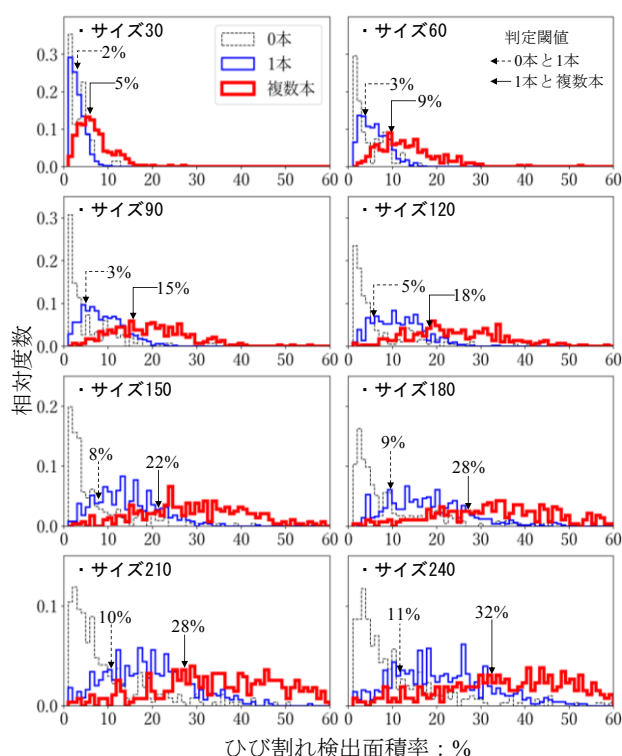


図-5 目視によるひび割れ本数とひび割れ検出面積率の関係




図-6 CNN法の精度比較

な差はないが、サイズ150以下では、 $R$ の増加および $RMSE$ の低下が見られた。最も良好なモデルはサイズ90であり、 $R=0.88$ 、 $RMSE=6.4\%$ を示した。

次に、検出画像の視認性に着目する。図-8に示したように、判別画像サイズが150、210のように検出が粗くなると、細かいひび割れやそれらの分岐などを捉えることが困難になる。サイズ90では、目視によるスケッチを再現しており、ひび割れ形状の把握が容易である。




図-7 CNN法と従来目視法の比較

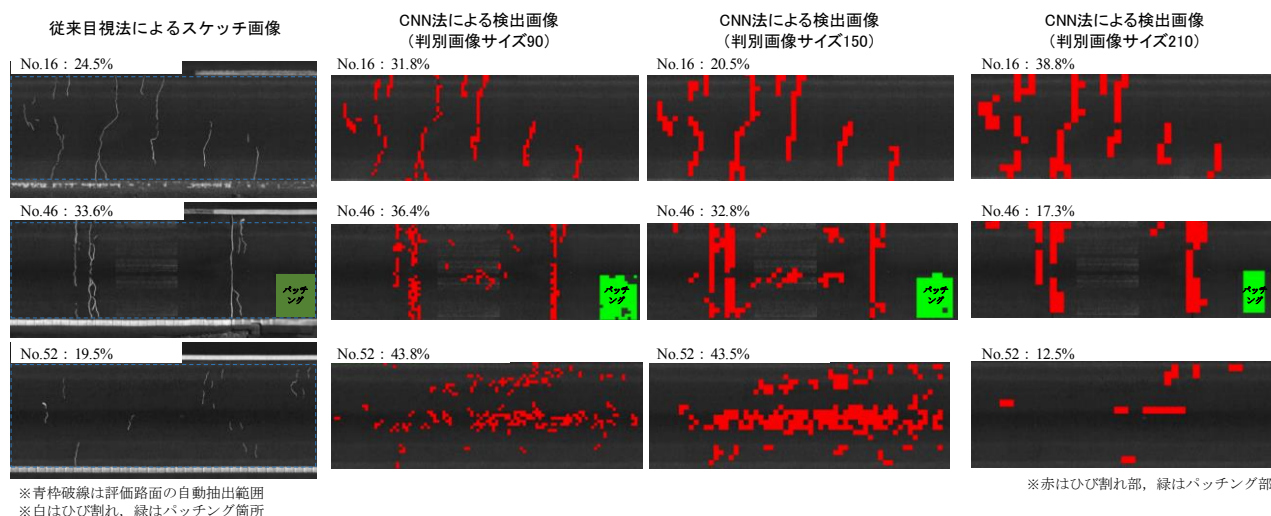


図-8 CNN法によるひび割れおよびパッチングの検出結果 (例)

以上から、今回対象としたひび割れとパッチングを検出する場合に限るが、モデルの過学習 (図-3, 4), ひび割れやパッチングの見逃しや誤検出 (図-4), ひび割れ評価の精度 (図-6), 検出結果の視認性 (図-8) を勘案すると、判別画像サイズ90 (実路面で10×10cm) が妥当であることが示唆される。このサイズ90のCNNモデルでは、路面画像1枚あたりの解析時間は、およそ2分ほどであり、目視でスケッチする場合と同等であった。本手法を用いることで、自動的にひび割れやパッチングを画像上に可視化し、ひび割れ評価結果とともにデータベース化できる。これにより、例えば、膨大な画像の中からひび割れ率の大きい区間を検索し、ひび割れが明瞭に可視化された画像を見ながら各種の診断を行うなど様々な応用が提案できる。

## 5. 結論

本研究では、路面性状測定車による高速道路の路面画像に CNN モデルを適用し、ひび割れとパッチングを高

精度で検出・可視化し、従来のひび割れ率を自動算出する手法を開発した。得られた結論を以下に示す。

- 目視によってひび割れとパッチングをスケッチした路面画像を用いて、各部の RGB 値を基に小片画像をランダムサンプリングにより抽出し、CNN モデル学習用の大規模なデータセットを自動生成した。
- CNN を適用する画像サイズ (判別画像サイズ) を 8 パターン設定し、それらのモデル別に学習、テストを行った。その結果、テスト正答率は、サイズ 120 でピークとなり、サイズ 150 以上では過学習が生じる可能性が示された。次に、ひび割れ部の見逃し率を求めたところ、サイズ 90, 120 が最も低い約 25% となり、それよりも小さいまたは大きいサイズでは見逃しが増加した。また、誤検出率は、サイズ 60 以上で 10%以下となった。パッチング部については、サイズ 90~180 において、見逃し率が 10%以下、誤検出率が 5%以下となった。
- 学習後モデルを路面画像に適用してひび割れとパッチングを検出し、ひび割れ率とパッチング面積率を算出した。これらの精度を見るために、CNN 法と従



来目視法との相関係数  $R$  および  $RMSE$  を求めた。骨材剥離がある路面画像を除外すると、サイズ 90 が最もひび割れ率の精度が良く、 $R=0.88$ 、 $RMSE=6.4\%$ を示した。以上に加え、検出画像の視認性を勘案すると、CNN を適用する判別画像サイズは、90（実路面で  $10 \times 10 \text{cm}$ ）が妥当であることが示唆された。

本研究では、昨今、多分野で着目されているCNNを導入し、ひび割れ評価への有効性が示されたが、課題も幾つか残る。現状では、モデルの学習に用いた路面画像は124枚、すなわち1,240m区間分と少なく、また、検出対象はひび割れとパッチングのみとしたことから、それ以外の損傷パターンが存在する区間への適用は難しい段階である。様々な路面状態を含む画像から学習を行い精度を向上させるとともに、路面画像1枚当たりの計算時間を短縮させるなど、実用化に向けた課題に取り組む。また、ひび割れの本数判定方法以外にも、検出量からひび割れ率を直接求める方法も考えられる。今後は、一般道路も対象に、道路管理者の要望や分析方法の有意性を踏まえ、CNNによる高精度検出をベースとした様々な路面評価アプローチについて開発を進めたい。

#### 参考文献

- 1) 武藤聡, 久保和幸, 藪雅行:「舗装点検要領」の策定について, 舗装, Vol.52, No.1, pp.11-15, 2017.
- 2) 日本道路協会: 舗装点検必携, 2017.
- 3) 田中直樹: レーザー画像を用いた路面からのクラック抽出, 土木学会論文集E, Vol.62, No.4, pp.631-640, 2006.
- 4) 全邦釘, 橋本和明, 片岡望, 蔵本直弥, 大賀水田生: ナイーブベイズ法によるアスファルト舗装撮影画像からのひび割れ自動検出手法, 土木学会論文集E1 (舗装工学), Vol.70, No.3, pp.1-18, 2014.
- 5) 浅田拓海, 亀山修一, 川端伸一郎, 佐々木克典: 走行車両から撮影した路面画像を用いた舗装のひび割れ評価手法の開発, 土木学会論文集E1 (舗装工学), Vol.70, No.3, pp.1-16, 2014.
- 6) 埴賢治, 西川貴文, 奥松俊博, 中村聖三: 低解像度画像を用いた路面の可視変状認識アルゴリズムの構築と実装化, 土木学会第67回年次学術講演会, V-316, 2012.
- 7) 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.
- 8) 宮崎文平, 風戸崇之, 濱梶方希, 小濱健吾, 貝戸清之: 高機能舗装を対象とした高速道路の路面管理基準に関する実証的研究, 土木学会論文集E1 (舗装工学), Vol.69, No.3, pp.175-183, 2013.
- 9) 小田宏一, 児玉英二, 青木一也, 貝戸清之, 小林潔司: 劣化ハザード率を用いた学習機能を有する舗装マネジメントシステム, 土木情報利用技術論文集, Vol. 18, pp.165-174, 2009.
- 10) 水谷大二郎, 小林潔司, 風戸崇之, 貝戸清之, 松島格也: 連続量を用いた劣化ハザードモデル: 舗装耐荷力への適用, 土木学会論文集D3 (土木計画学), Vol.72, No.2, pp.191-210, 2016.
- 11) 日本道路協会: 舗装調査・試験法便覧-第1分冊-, 2007.
- 12) ゼロから作るDeep Learning-Pythonで学ぶディープラーニングの理論と実装-: オーム社, 2016.
- 13) Chainer v2による実践深層学習: 株式会社オーム社, 2017.

(2018.6.14 受付)

## DEVELOPMENT OF HIGH-RESOLUTION DETECTOR FOR CRACK AND PATCHING BY USING CONVOLUTIONAL NEURAL NETWORK

Takumi ASADA, Kazumasa Kawamura, Atsunori Ishida and Shuichi KAMEYAMA

In this study, we developed the high-resolution detector for crack and patching on pavement of expressway by using convolutional neural network (CNN), and calculated the crack ratio by this method. First, small images such as crack and patching area was randomly sampled using sketch images. We set several image sizes to make the judgment by CNN. Then, the size and the judgment accuracy of the model were compared. As a result, over learning of models was observed for larger sizes, and accuracy of model reached a peak at an intermediate size. Cracks and patching were detected by the learned model, and the crack rate was calculated based on the conventional method. From the above results, it was shown that the accuracy of crack ratio is high with the judgment image size of 90 pixels, and the crack shape can be visualized in detail.