

# 畳み込みニューラルネットワークによる 舗装ひび割れの高解像度トレース手法の開発

浅田 拓海<sup>1</sup>・川村 和将<sup>2</sup>・石田 篤徳<sup>2</sup>・石井 麻貴<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)  
E-mail: kameyama@hus.ac.jp

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畳み込みニューラルネットワーク (CNN) を適用し、ひび割れを高解像度にトレースする手法を開発した。まず、目視によるトレース画像を基に、ひび割れ部やパッチング部をCNNモデルに入力する解析画像としてランダム抽出し、データセットを構築した。これを用いて学習・テストを行い、そのモデルを路面画像に適用して各部の抽出を行った。さらに、その画像を用いてパッチング面積率とひび割れ率を求めたところ、解析画像サイズが90×90ピクセルで精度が高くなり、ひび割れ形状を細かく再現できることを示した。これにより、ひび割れ評価を簡易かつ高精度に実施できること、さらには、ひび割れ形状から劣化の原因説明や予測に利用できる可能性を示した。

**Key Words :** *pavement, crack tracing, deep learning, 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の構築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、ストリークカメラで撮影した精緻な画像を目視しながらひび割れ評価が行われている。メンテナンスサイクル構築の観点から、膨大な手間と時間を要するこの部分を効率化、自動化すること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。一方、昨今、画像認識技術において Deep Learning が着目されており、上記のようなノイズを低減しながら、高精度なひび割れ検出を試みた研究事例も幾つか報告されている。全らは、一般道路で車載カメラから撮影した路面画像に畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) を適用してひび割れ部を検出し、その面積率からひび割れ状態を 3 段階で診断する手法を開発している<sup>7)</sup>。しかしながら、この研究では、従来のひび割れ評価指標であるひび割れ率との整合性について検証されていない。また、教師有り学習モデルを用いる際に重要となる学習・再学習のため

のデータ構築方法などの検討がなく、実用的な面での課題を残したままである。

一方、舗装の損傷の原因を探ることは、劣化予測や具体的な修繕方法を検討する上で重要となる。ひび割れにおいては、線状、亀甲状などの形状からその発生原因が類型化されており、補修の判断や具体的な措置が検討される。昨今、CNN などの AI 技術による舗装点検手法が積極的に開発されているが、現在の路面状態を簡易的に診断する目的のため、粗いメッシュ毎にひび割れの有無を判定するケースが多く、ひび割れの形状が把握できるようなアプローチは見られない。より高解像度にひび割れを抽出し、その形状を把握できれば、将来の点検業務に加えて、過去の画像データ活用による劣化の原因解明や予測など<sup>9),10)</sup>にも利用できると思われる。

本研究では、高速道路のひび割れ評価を対象とし、路面性状測定車によって撮影された路面画像に CNN を適用し、高解像度にひび割れをトレースする手法を開発する。さらに、学習済みモデルを路面画像に適用し、その結果からひび割れ率を求め、従来手法による結果との比較を行う。本研究の特徴としては、学習データの効率的な構築のために目視トレース結果を活用すること、路面性状測定車による精細な画像データを活用するために高解像度にトレースを行うこと、既存手法によるひび割れ評価との比較からモデルの精度を検証することが挙げられる。

## 2. CNNの概要

本研究では、路面画像内の各種の状態を高解像度にトレース・抽出し、自動的にひび割れ評価を行う手法を開発する。入力データが画像となることから、昨今、一般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、何らかの画像特徴量を設定、算出し、それらを SVM やニューラルネットワーク（以下、NN）などの分類器に入力し、教師データとの誤差を最小化する手法が一般的である。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、運用上の欠点が指摘されている。一方、CNN は、**図-1**に示すように、この画像特徴量を学習の中から自動的に抽出する手法である。

CNN では、画像特徴量を抽出する CNN 部と通常の NN 部が一体となった構成となる。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する。この畳み込み層とプーリング層により、画像情報を圧縮して特徴量を

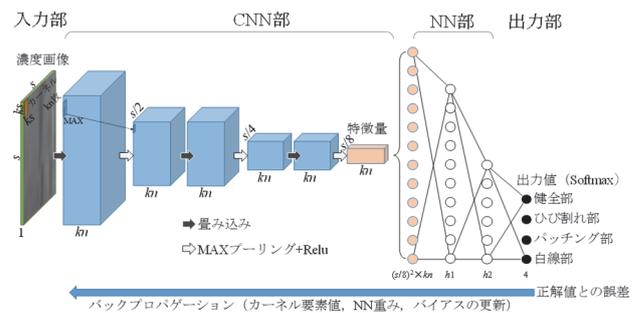


図-1 CNNモデルの構成

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、教師データを与え、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、誤差が最小化される。

通常の NN では、入力画像を初めからベクトル化して入力することで適用が可能となる。しかしながら、例えば、認識すべき視対象（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視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視対象の認識、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。

## 3. CNNによる路面状態判定モデル

本研究では、**図-2**に示すような手順で分析を行う。まず、①路面画像の前処理を行い、教師データに用いる画像のために、目視によるひび割れのトレースやパッチング部、白線部のマスキングを行い異なる色で区分する。次に、トレース部およびマスキング部の色情報を基に、各部の小片領域を路面画像からランダム抽出し、モデルのための②データセットを構築する。このデータセットを用いて、③モデルの学習を行い、テストデータにより判定精度を確認する。最後に、学習済みのモデルを路面画像に適用して、ひび割れやパッチングを自動的にトレースあるいはマスキングし、さらに、従来の方法に基づいた④ひび割れ評価を行い、その精度について検討する。以下に、詳細を示す。

なお、開発言語は Python 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 (TensorFlow-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) 路面画像および目視によるひび割れトレース画像

本研究では、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、ひび割れ率がばらつくように 124 枚の路面画像を分析用に選出した。この全 124 枚の路面画像を半分に分け、学習用とテスト用とした。

以降で説明する通り、教師データ作成のために以下の処理を行った。まず、路面性状評価従事者に目視によるひび割れのトレースとパッチングのマスクングを行ってもらった（RGB 画像）。本研究では、さらに、白線部をひび割れ部やパッチング部と区分するためにマスクングした（図-2）。

### (2) 解析画像サイズの設定

本研究では、ひび割れを高解像度にトレースすることを目的とし、路面画像の小片領域毎に各種の状態を判定するモデルを考えた。モデル自体の判定精度やひび割れトレース、路面評価の精度向上を図るため、この小片画像（解析画像）のサイズについて検討する。既往の研究では、0.5m×0.5m 程度の粗いメッシュ毎でひび割れ有無の判定などを行っているが、本モデルでは、30×30 ピクセル（実路面上で約 3×3cm）から 240×240 ピクセル（実路面上で約 27×27cm）までの 8 段階のパターンでモデルを比較する。

### (3) 判定クラスおよび学習データセットの構築

本研究では、「ひび割れ部」、「パッチング部」、「白線部」、これらの状態を含まない「健全部」の 4 つの状態（クラス）を判定するモデルを考えた。学習データの構築のために、目視によるトレース画像の色情報を基に、各部の画素の位置を中心とした小片領域を解析画像としてランダムで抽出し、当該ラベル（教師データ）と合わせてデータセットを作成した。

抽出した解析画像の枚数を表-1 に示す。一つのモデル当たり、およそ 50 万枚のデータセットを自動的にかつ迅速に構築することができる。1 モデルのデータ構築にかかる時間はおよそ 1 時間程度であった。なお、同じ条件で各部の解析画像を抽出すると特定のラベルにデータ数が偏りモデルの学習が適切に行えない可能性がある。そこで、各状態の全ての画素の位置から解析画像を抽出するのではなく、「健全部」は 3,000 枚を限度とし、「ひび割れ部」はその線の画素の 30% の位置から、「パッチング部」と「白線部」はそのマスクング部の画素の 0.1% の位置からランダム抽出した。

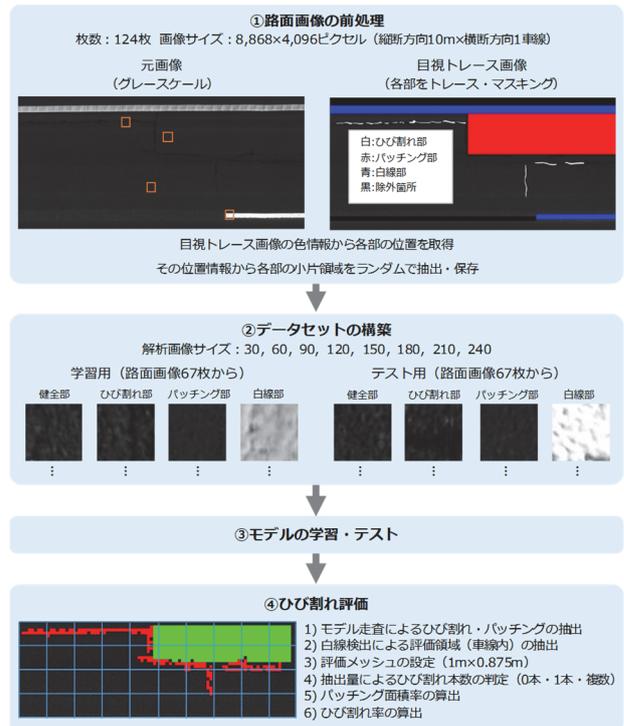


図-2 分析の流れ

表-1 学習およびテストに用いる解析画像の枚数

●学習用（路面画像番号奇数番：62枚）						
解析画像サイズ ピクセル	実寸 サイズ cm	健全部	ひび割れ部	パッチング部	白線部	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）						
解析画像サイズ ピクセル	実寸 サイズ cm	健全部	ひび割れ部	パッチング部	白線部	合計
30	3.3	186,000	131,149	67,829	145,229	530,207
60	6.7	186,000	107,403	65,374	132,813	491,590
90	10.0	186,000	94,274	63,174	120,524	463,972
120	13.3	186,000	84,396	60,624	108,514	439,534
150	16.7	186,000	76,269	58,250	96,572	417,091
180	20.0	186,000	69,741	56,327	84,864	396,932
210	23.4	186,000	63,843	53,981	73,212	377,036
240	27.7	186,000	58,180	52,074	61,443	357,697

### (4) モデルの構成

図-1 に示したように、CNN 部は、畳み込み→MAX プーリングを 3 回繰り返す層構成とした。入力画像（解析画像）の縦横のサイズをそれぞれ  $n$  とする。畳み込みのカーネルサイズ  $ks$  と枚数  $kn$  は、全ての層で 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、最終的には  $n$  が入力画像の 8 分の 1 にまで圧縮さ

れ、 $kn_c$  枚の画像が生成される。なお、MAX プーリング後には、活性化関数 ReLU を適用する。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、「健全部」「ひび割れ部」「パッチング部」「白線部」の 4 ユニットとなり、Softmax 関数を適用する。パラメータ更新の最適化手法には Adam 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 2000 とした。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正答率および誤差が算出され、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-2）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。なお、使用した PC では、一つのモデルの学習時間が 30 分程度であった。

(5) モデル精度と解析画像サイズの関係

上記のデータセットおよびモデル構成で、学習とテストを行った。各モデルの学習過程を図-3 に示す。判定精度の遷移をみると、学習は 800 エポック程度で収束していることが分かる。また、サイズが大きくなるほど、収束が速く、最終的な精度が高い傾向にある。

次に、テストデータを用いて、モデルの精度検証を行った。各モデルの判定精度を図-5 に示す。学習データでの精度では、解析画像サイズが最も大きい 240 で最大となる傾向（図-3）があったが、テストにおいては、サイズ 120 でピークとなった。以下では、この解析画像サイズ 120 のモデルに着目し、両端のサイズ 30 と 240 との比較から、判定正誤表（表-2）を見ながら誤差の原因について考察を行う。

まず、目視で「健全部」の画像において、モデルで「ひび割れ部」や「パッチング部」と誤判定し、損傷箇所を余分に抽出するケースがあった。その傾向は解析画像サイズが小さい場合と大きい場合で顕著となる。特に、「健全部」を「ひび割れ部」と誤判定する割合が大きい理由は、舗装材料が排水性アスファルトであり、表面が粗く、骨材剥離などの箇所はひび割れの状態と似ているためと考えられる。次に、目視で「ひび割れ部」の画像に関しては、特にサイズ 30 で「健全部」と誤判定している割合が大きく、ひび割れを見逃す傾向がある。この「ひび割れ部」の見逃しは、サイズが大きいほど少なくなる。解析画像サイズが大きいほど、ひび割れ形状が明瞭になり、見逃しが少なくなるが、サイズが小さくなると、ひび割れの部分がわずかしか存在しない場合や、画像内のほとんどがひび割れ面積である場合があり、「健全部」と判定され、見逃しが生じる可能性が高くなる。

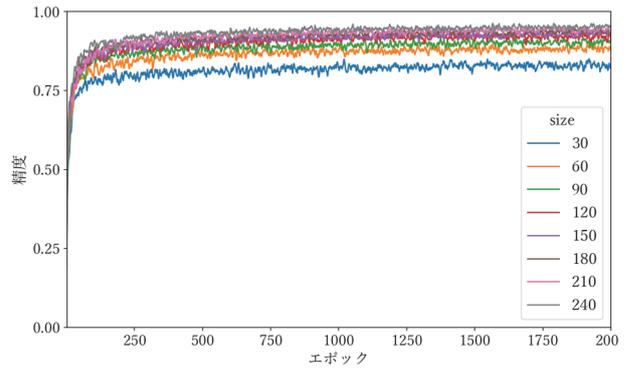


図-3 各モデルの学習過程

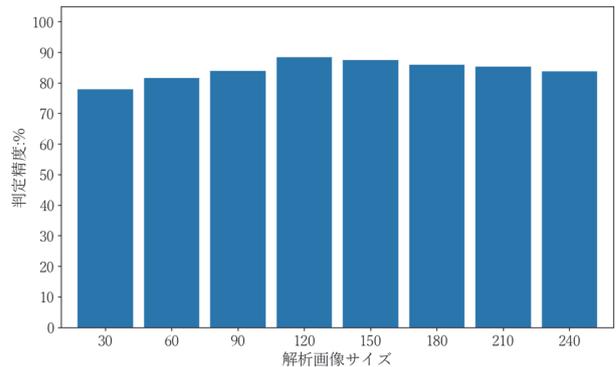


図-4 判定精度の比較（テストデータ）

表-2 判定正誤表（テストデータ）

・解析画像サイズ30		単位：%			
精度：81.3% (網掛け部合計)		予測 (CNNモデル)			
		健全部	ひび割れ部	パッチング部	白線部
観測 (目視)	健全部	20.6	7.5	3.8	0.8
	ひび割れ部	3.2	16.3	0.1	0.2
	パッチング部	0.9	0.6	20.5	0.2
	白線部	0.3	0.7	0.6	23.8
・解析画像サイズ120		単位：%			
精度：89.8% (網掛け部合計)		予測 (CNNモデル)			
		健全部	ひび割れ部	パッチング部	白線部
観測 (目視)	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
・解析画像サイズ240		単位：%			
精度：87.0% (網掛け部合計)		予測 (CNNモデル)			
		健全部	ひび割れ部	パッチング部	白線部
観測 (目視)	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

ただし、解析画像サイズが大きくなると、その代償として「パッチング部」や「ひび割れ部」を過度に抽出する傾向がある。「パッチング部」は、健全部の排水性アスファルトとは違う材料で補修された部分であり、テクスチャが異なるため高精度で判定できるが、上記のようにサイズが大きい場合では、「健全部」の箇所でも「パッ

チング部」と誤判定する割合が若干ある。「白線部」は明度が大きいので、他の状態との区別が容易である。

以上から、本モデルによって、「ひび割れ部」「パッチング部」「白線部」「健全部」の4つのクラスを高精度で判別できると言える。また、解析画像サイズが120で判定精度がピークとなり、「ひび割れ部」の見逃しおよび「ひび割れ部」と「パッチング部」の過剰な抽出が他のサイズよりも少なくなることがわかった。

#### 4. CNNモデルによるひび割れトレース画像を用いたひび割れ評価

##### (1) 従来のひび割れ評価方法

対象路線では、舗装調査・試験方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スケッチによる方法<sup>1)</sup>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トレース、マスキングする。次に、車線範囲に縦断方向1m×横断方向0.875mのメッシュ（以下、評価メッシュ）を描き、評価メッシュ毎にひび割れの本数（1本か複数本）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方法

本研究では、まず、学習済みモデルを路面画像の全領域に適用し、「ひび割れ部」と「パッチング部」をトレース、マスキングし、それぞれ判定された箇所に色情報を付加する。モデルの適用は、解析画像サイズのメッシュ毎に行う。なお、モデルによる出力値は、4クラスで合計1となるように各クラスに比率で得られる。ここでは、最大比率ではなく、比率が0.5以上となるクラスを当該箇所の損傷状態とした。

最後に、元の路面画像を用いて、ひび割れ率を算出する車線部（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色情報（白いため濃度値が高い）からその位置を特定し、上記のモデルによるトレース画像から車線部を自動的にトリミングする方法である。この画像に従来方法と同じサイズで評価メッシュを描く。

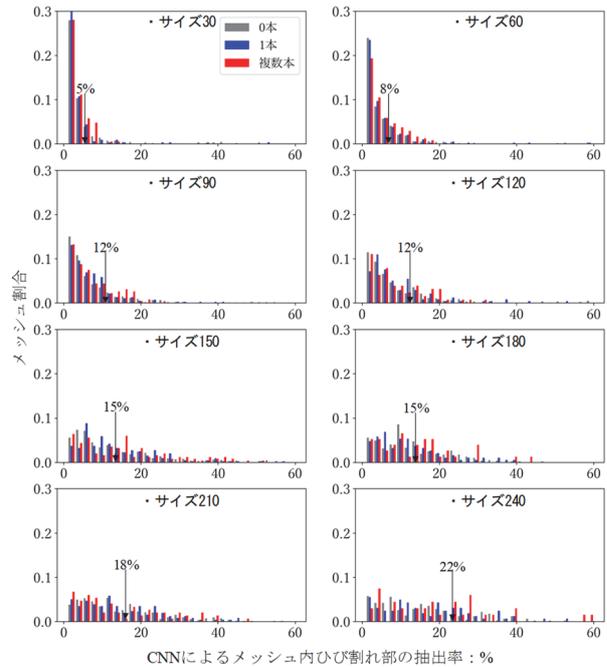


図-5 ひび割れ本数別のCNNモデルによる抽出率

パッチング面積は当該マスキング部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、「ひび割れ部」のピクセル量で判定する。まず、目視によって判定された評価メッシュ毎のひび割れ本数のデータを用いて、本数が0本、1本、2本以上の評価メッシュ毎に本モデルで抽出した「ひび割れ部」のピクセル面積率（以下、ひび割れ抽出率）の度数分布図を作成した（図-5）。本数が1本の場合はひび割れ抽出率が小さい範囲で分布し、複数本の評価メッシュでは、ひび割れ抽出率の分布が大きい範囲にシフトすることがわかる。明確な境界は判断できないが、ひび割れ1本よりも複数本の分布が大きくなる箇所をひび割れ本数の閾値として設定した（図-5）。なお、ひび割れ0本と1本の閾値については、ひび割れ抽出率1%とした。したがって、例えば、サイズ120では、ひび割れ抽出率1%以下の評価メッシュは「ひび割れ無し」、1~12%の場合は「ひび割れ1本」、12%以上は「ひび割れ複数本」として判断される。

##### (3) パッチング面積率およびひび割れ率の精度

パッチング面積率（評価領域に対するパッチング面積の割合）およびひび割れ率に関して、目視による値とモデルによる値の関係について調べた。まず、全モデルを比較するため、目視とモデルの相関係数を図-6に示す。パッチングに関しては、全解析画像サイズにおいて総相関係数が0.9以上となり、高い精度が得られた。一方、ひび割れ率では、サイズが大きいくほど相関係数が大きくなる傾向が見られる。解析画像単位で行ったモデルのテスト

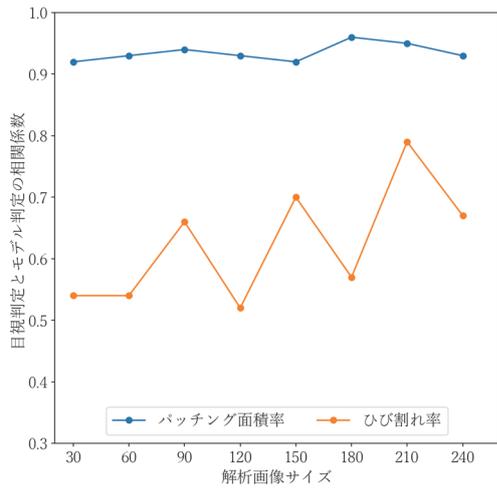


図-6 ひび割れ率およびパッチング面積率の精度比較

では、サイズ120で精度がピークとなったが、ひび割れ率においては、サイズ210が最も精度がよく、続いて、サイズ150、90となった。この原因については詳細な分析が必要であるが、以下では、相関係数が0.6以上となったサイズ90、150、210に着目し、ひび割れトレースの可視化に最適なサイズやひび割れ率の誤差の原因について考察する。

モデルによる結果と目視による結果の関係を図-7に示す。また、誤差の大きい路面画像の番号を同図に示すとともに、目視およびモデルによるトレース画像の一例を図-8に示す。

パッチング面積率に関しては、どの解析画像サイズにおいても1対1の関係にあり、高精度で抽出できることがわかる。ただし、図-8に示すように、サイズが大きくなるほど、解像度が低くなるため、境界付近が抽出されず、パッチング面積率が目視よりも小さい値になる。したがって小さいパッチングも存在することから、解析画像サイズを小さくすることが望ましいと言える。

次に、ひび割れ率では、ほとんどの路面画像において、目視と同程度の評価が可能となったが、サイズ90や150では、路面画像No.52、112のモデル値が目視よりも大きくなった。図-8をみると、目視によるトレースがない箇所にはひび割れを抽出していることがわかる。これら路面画像を調べたところ、No.48、52、112では、排水性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のような状態が広がる様に見える。そのため、本モデルにおいても「ひび割れ部」として判定されてしまい、過剰なひび割れ率となる。このような箇所の画像を用いて再度学習し、モデルを更新することで過剰な抽出を低減できると考えられるが、この骨材剥離による損傷をひび割れと同等に扱うのであれば、目視でのトレースは難しいことから、むしろ本モデル、

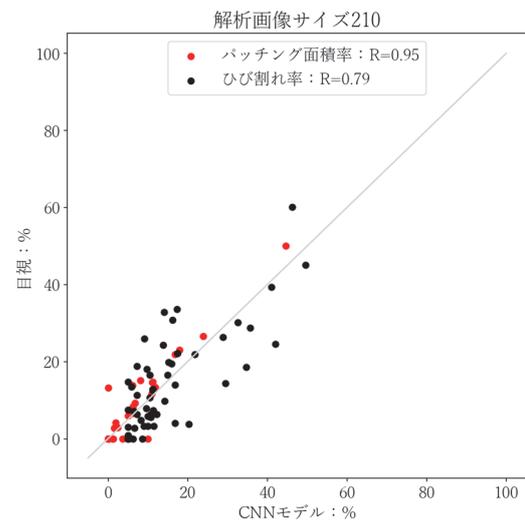
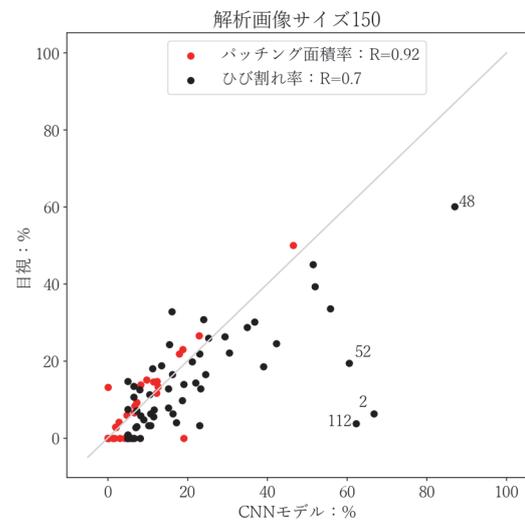
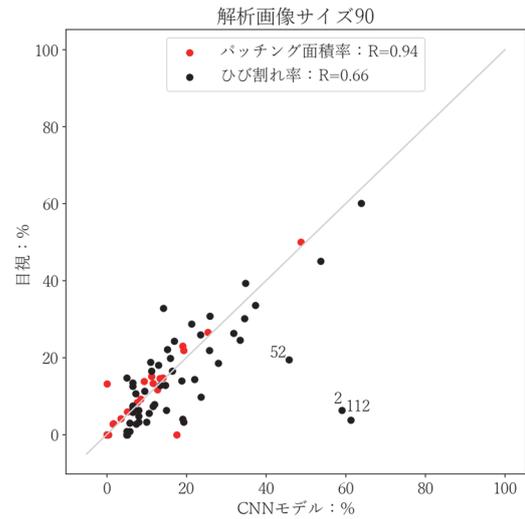


図-7 モデル適用結果と目視結果の比較

特に解析画像サイズが小さいモデルの有用性はより高まると言える。No.2に関しては、骨材剥離が確認できないため、その原因を調べるとともにモデルの改善が必要である。なお、これら4つの路面画像No.2、48、52、112を

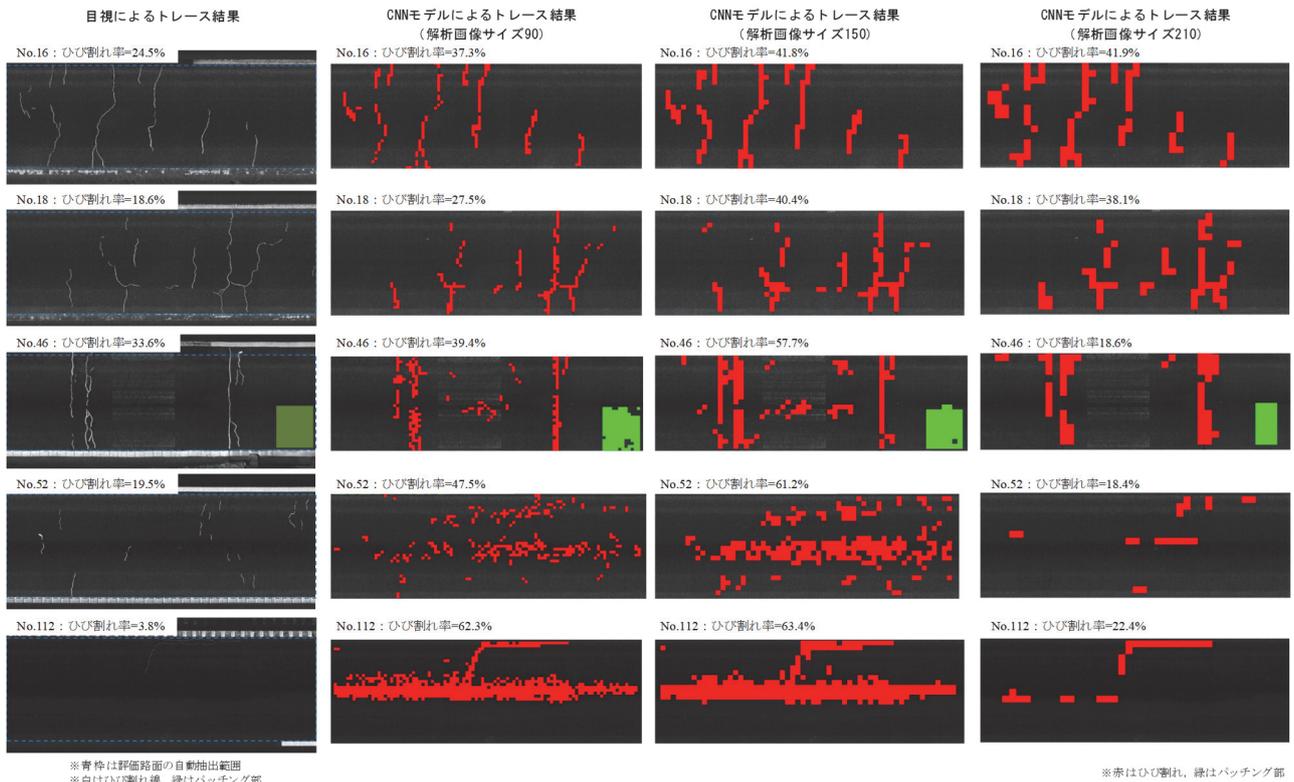


図-8 CNNモデルによるひび割れ・パッチングの抽出結果(例)

除いて再度相関係数を求めたところ、サイズ90が最も大きくなった。

各サイズのひび割れトレース結果を比較すると、解析画像サイズが大きくなると、ノイズが少なくなるものの、低解像度となるため、細かいひび割れを捉えることができない。これに対し、小さいサイズ90では、目視によるトレース線を再現しており、ひび割れ率だけではなく、亀甲状、縦方向、横方向などのひび割れパターンを容易に確認できる。

以上から、骨材剥離などの他の損傷形態を加えたモデルの再構築、再学習が必要であるが、解析画像サイズを90×90ピクセル(実際のサイズでは10×10cm)とすることで、ひび割れ率の精度が高くなり、また、細かいトレースによりひび割れの形状を容易に確認することが可能であることがわかった。

## 5. まとめ

本研究では、路面性状測定車により撮影された高速道路路舗装の路面画像にCNNを適用して、ひび割れを高解像度にトレースする手法を開発した。得られた成果を以下に示す。

- 目視によるひび割れのトレース、パッチングのマスキングを行った路面画像を用いて、各部の色情報を

基に小片領域をランダムに抽出し、CNNモデルの学習データを構築した。事前にトレース画像を作成してしまえば、画像処理を行うことで、大規模な学習データ・セットを迅速に構築できることを示した。

- CNNを適用する解析画像サイズを8パターン設定し、各モデルで学習およびテストを行った。その結果、サイズ120(120×120ピクセル)でテストデータによる精度がピークとなり、サイズが大きくなるに従って精度が低下する傾向が見られた。
- 学習済みモデルを路面画像に適用し、ひび割れおよびパッチング部を抽出した。各モデル(解析画像サイズ)で精度を比較し、サイズ90がパッチング面積率およびひび割れ率の精度が良く、トレース・マスキングの再現性が高いことがわかった。

今後は、今回のモデルで認識できなかった骨材剥離の箇所など他の損傷状態を加えた上でモデルの再構築あるいは再学習を行い、精度を向上させる予定である。ただし、このように新たな路面状態が現れる度に、学習が必要となり、教師データを作成する必要があるため、別のアプローチとして、教師無しあるいは半教師有りの学習モデルを考案したい。

## 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.I\_1-I\_8，2014.
- 5) 浅田拓海，亀山修一，川端伸一朗，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，I\_9-I\_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，I\_97-I\_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，I\_175-I\_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.