

# 橋梁点検のための床版ひび割れの領域検出と劣化指標

安野 貴人<sup>1</sup>・中島 道浩<sup>2</sup>・野田 一弘<sup>3</sup>・岡野 将大<sup>4</sup>

<sup>1</sup> 非会員 八千代エンジニアリング株式会社 技術開発研究所 (〒111-8648 東京都台東区浅草橋 5-20-8)  
E-mail: tk-yasuno@yachiyo-eng.co.jp (Corresponding Author)

<sup>2</sup> 正会員 八千代エンジニアリング株式会社 事業開発本部 (〒111-8648 東京都台東区浅草橋 5-20-8)  
E-mail: mch-nakajima@yachiyo-eng.co.jp

<sup>3</sup> 正会員 八千代エンジニアリング株式会社 インフラマネジメント部 (〒111-8648 東京都台東区浅草橋 5-20-8) E-mail: kz-noda@yachiyo-eng.co.jp

<sup>4</sup> 非会員 八千代エンジニアリング株式会社 技術開発研究所 (〒111-8648 東京都台東区浅草橋 5-20-8)  
E-mail: ms-okano@yachiyo-eng.co.jp

我が国の約 70 万橋の橋梁が老朽化するなか、5 年に 1 回の橋梁点検を持続可能にすることが根本的な課題となっている。点検から措置までのサイクルをベースアップするため、ばらつきを抑え一貫性のある健全度判定を行い、数値指標を用いた補修工法の選定が求められている。本稿では、橋梁部材の損傷画像から損傷の特徴を抽出するために、床版ひび割れの画像とその教師ラベルを対象に、セマンティック・セグメンテーションにより、損傷の特徴抽出に有用な領域検出器を学習し、劣化指標を自動計算する手法を提案する。最後に、橋梁点検支援ツールの汎用化の課題に言及する。

**Key Words:** bridge inspection, supervised learning task, semantic segmentation, repair index

## 1. はじめに

### (1) 関連する研究開発の概要

2014年に画像の深層学習において、人を上回る圧倒的な精度を発揮して以来、医用画像分析や工場の異常検知に人工知能の導入が進展している<sup>1)</sup>。土木構造物の維持管理における点検・診断支援においても、例外ではない<sup>2)</sup>。橋梁やトンネルのコンクリート構造物を中心に、ひび割れや剥落の損傷を自動検出する手法の研究が行われている<sup>3,4)</sup>。町田らは、深層学習により、コンクリート構造物の劣化要因を判定支援する 5 クラスの分類器の人工知能を構築している<sup>5)</sup>。ここで、損傷写真のサイズは 400×300 であり、分類器の入力サイズ 120×120 の畳み込み CNN が用いられている。近接目視点検の損傷写真から、ASR、塩害、中性化、凍害、乾燥収縮の劣化要因を判定するものである。この 5 クラス分類の正解率は、40% であり精度改善が課題に残された。劣化の要因から措置を考えるために、有用な基礎研究と言える。青島らは、Faster-RCNN と YOLOv3 の物体検出の解法により、コンクリート構造物のひび割れ、漏水・遊離石灰、つら

ら、剥離・鉄筋露出、錆汁を対象に、矩形領域 (bounding box) で推論した結果を報告している<sup>7)</sup>。物体検出の主な手法を比較整理しており、R-CNN から SSD、YOLOv3 まで紹介されている。また、画像分類の学習結果に Grad-CAM を事後処理することにより、損傷の着目領域を可視化した結果も報告している。この Grad-CAM という自動計算の手法は、特徴量を取り出すレイヤーを指定すれば、画像分類のネットワークに汎用的に適用できる利点がある。画像分類と物体検出により、見落としなく損傷を検出できる可能性を示唆している。物体検出は、損傷の有無とおおよその位置を特定することに長けているが、損傷の形状や面積の把握できない限界がある。

土木研究所では、2019 年から 2021 年まで、AI を活用した道路橋メンテナンスの効率化に関する共同研究に着手している<sup>7)</sup>。床版を貫通するひび割れに着目し、診断 AI のプロトタイプを作成している。我が国の 70 万橋といわれる直轄国道から地方自治体までの管理橋梁を対象に、点検の損傷検出、劣化要因の診断、さらに補修工法の措置選定まで、サポートする人工知能の構築が期待されている。山根らは、Mask R-CNN によるコンクリート

表面のひび割れ検出を行う手法を提案し、ひび割れのシグナルと異なる P コン跡と型枠跡のノイズを除去して、ひび割れの検出率を高める工夫を施している<sup>8)</sup>。床版や桁、建物の内壁からなる 45 枚の画像 (5,184×3,456) に適用した結果を報告している。Chun et al は、柔軟なツリー型のアルゴリズムである LightGBM による 2 段階のコンクリート表面のひび割れ検出手法を提案し、高速の学習と高い精度を発揮した評価結果を報告している<sup>9)</sup>。しかし、これらの研究は、ひび割れ検出率の精度向上を追求した基礎研究であり、経年変化によるひび割れの進行性を確認したり、補修の優先順位を判断するための損傷の評価指標に関しては触れられていない。

著者らは、ダムや橋梁のコンクリート構造物を対象に、ポップアウト（凍害による軟石の突出、剥離変状）、鉄筋露出の領域検出を行うことに加え、損傷が広がる範囲の面積による劣化指標の算出を自動化する手法を提案し、適用結果を報告している<sup>10)11)</sup>。コンクリート表面で頻発するひび割れが進行しているかどうかは、補修の必要性を判断するために重要である。さらに、ひび割れが進行している場合に、それらが一方向であるか、二方向であるか、ひび割れの劣化度を実寸評価し、補修対策を講じる優先順位を比較検討するための劣化指標が必要となる。

## (2) 橋梁点検から措置までのペースアップ

平成 26 年に橋梁の定期点検が法制化されて 5 年に 1 回の 1 巡目を終えて、令和元年度から 2 巡目に入り、点検作業の円滑化が課題となっている<sup>12)13)</sup>。橋梁の熟練技術者が減少し、点検診断の的確さとばらつき抑制も課題である。点検後の措置に関しては、地方自治体の管理橋梁で着手率が 2 割程にとどまっている。投資的経費に充てる予算の制約もあるが、早期措置や緊急措置の判定を理由づける意思決定をサポートする劣化指標の情報出力が求められている。予算を投入して、予防保全と長寿命化のための補修工法に踏み切るために、劣化指標による補修の優先順位の相対比較を可能とする必要がある。著者らは、コンクリート構造物の鉄筋露出を手始めに、近接目視の損傷写真を用いた橋梁点検と劣化指標の算出をサポートする教師あり学習のタスクフローを継続開発し実装を試みている<sup>10)</sup>。

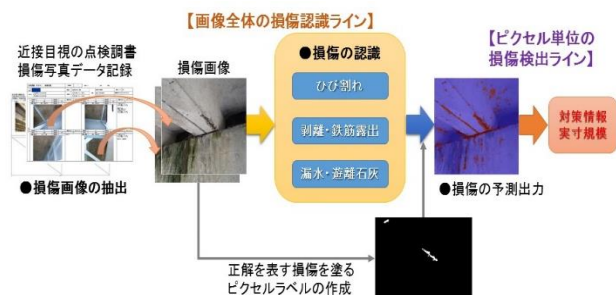


図-1 損傷抽出の教師あり学習のタスクフロー

図-1 に示すように、膨大な近接目視画像のなかから、損傷画像のクラス分類を行い、Grad-CAM により推論した損傷の位置を可視化することが可能である。損傷分類の可視化は、青島ら<sup>10)</sup>がすでに報告している。この画像分類と可視化によって、見落としなく損傷を 1 次把握することが可能となる。異なる地域の異なる構造物に対して、点検項目を網羅して、5~10 クラスの損傷分類器を精度向上することが課題となる。法定の判定区分までならば、画像の分類器で対応できるが、補修工法を選定する措置までサポートするには、ピクセル単位で損傷の領域を検出し、劣化指標の自動算出が必要となる。4 段階の健全度判定をこえて、劣化の傾向を数値指標にスコアリングできれば、補修工法の選定と優先順位の判断をサポートできる可能性がある。

本稿では、橋梁部材の損傷画像から損傷の特徴を抽出するための深層学習の手法を提案する。具体的に、床版ひび割れの画像とその教師ラベルを対象に、セマンティック・セグメンテーションにより、領域検出器を学習し、劣化指標を自動算出する手法を提案する。最後に、橋梁点検支援ツールの更新と汎用化の課題に言及する。

## 2. 損傷領域の検出と劣化指標

### (1) セマンティックセグメンテーション

本稿では、損傷領域を塗り分けた教師ラベルと元画像をペアにした画像データセットを対象に、セマンティック・セグメンテーションを学習し、ピクセル単位で損傷の領域を検出できる人工知能を構築する。具体的に、医用画像の分析に汎用されている U-Net を用いて、スクラッチの領域検出器の構築を試みる<sup>14)</sup>。また、ImageNet の膨大な特徴量を学習済みの VGG-16 を背骨に据えた SegNet を用いて、転移学習による領域検出器の構築を試みる<sup>15)</sup>。SegNet は、著者らがダムのポップアウト損傷やコンクリート橋梁の鉄筋露出に対して、相対的に高い精度を発揮している実用性を理由に、本稿においても適用する。さらに、密な畳み込みの操作を駆使した DeepLabv3+ を用いて、効果的な損傷領域の検出が可能であるか確認する<sup>16)</sup>。背骨に据えるネットワーク構造は、汎用的な ResNet18 を用いて、転移学習による領域検出器の構築を試みる。もちろん、セマンティック・セグメンテーションのネットワーク構造は、多彩な工夫とカスタマイズが可能である。本稿で用いる領域検出器そのものに新規性はない。本稿の目的は、床版ひび割れの教師画像に対して、汎用的な領域検出器を適用し、精度確認するとともに、劣化指標を自動算出するタスクフローを実装することにある。

## (2) 損傷推論と劣化指標

### a) 損傷領域の推論出力

対象とする損傷の画像データセットに対して、学習を行い、最大の精度を発揮した領域検出器を用いる。これにより、入力画像を読みこみ、ピクセル単位で損傷の領域を自動的に推論出力することが可能となる。損傷の推論出力には、損傷の領域を明示的に表現するため、1) 白黒のマスク画像、2) 紫と緑の反対色を強調した画像、3) 元画像をベースに損傷の領域を透明に塗った画像を用いることが多い。床版ひび割れの場合は、発生パターンが1方向であるか、2方向であるかが重要である。また、ひび割れが連結しているか、分離しているかも、ひび割れの劣化進行の度合いを理解するために必要である。本稿では、ひび割れの領域をプロブ分析し、分離している場合は、異なるカラー表示とする。2方向のひび割れの場合は、異なる方向のひび割れが連結し、同一のカラーで表示される。床版ひび割れの劣化指標を算出するには、白黒のマスク画像により、損傷の領域と背景の領域を区別した出力が必要である。

### b) 劣化指標の自動算出

学習済みの領域検出器を用いて、ピクセル単位で床版ひび割れを推論出力できる。推論出力として、白黒のマスク画像を用いて、ひび割れ領域の白いピクセルを画像処理により、自動的にカウントすることが可能である。1ピクセルあたりの原単位 (m<sup>2</sup>) を設定すれば、ひび割れ損傷の領域面積を近似計算することができる。さらに、モーフォロジー分析を用いて、ひび割れ損傷の領域が分離したものごとに、楕円で囲んで長い方の軸の延長をピクセル単位でカウントし、原単位で換算し、ひび割れ長さを近似計算することができる<sup>17)</sup>。




図-2 ひび割れを楕円で囲んだ長軸による延長の近似 (概念)

図-2 の上部中央に十字型で例示したように、分離した一つのひび割れ領域と同じ正規化された2次中心モーメントを有する楕円の長い方の軸の長さをひび割れ長さとして近似することとする。数値計算にあたり、MATLAB の Image Processing Toolbox に装備された regionprops を利用で

きる。本稿では、ひび割れの劣化指標として、ひび割れ延長あたりの領域面積を設定する。これにより、同じ長さのひび割れであっても、ひび割れ幅が開いている場合は、劣化指標が大きい値をとる。また、1方向のひび割れよりも、2方向のひび割れの方が、損傷面積が大きいので、劣化指標が大きくなる。交通荷重による疲労を診断するため、床版全体を俯瞰的に評価するには、この劣化指標の総和を用いることができる。一方、交通荷重が設計基準をこえない場合に、局所的に床版ひび割れが著しく進行しているか確認するために、床版の分割画像に対して劣化指標を算出し、要注意の候補位置を抽出することに利用できる。橋梁点検が2巡目に入ると、1巡目との比較を行う際に、俯瞰的な見た目の解釈に加え、劣化指標のスコアを比較することによって、劣化が進行しているか否かをより正確に判定することが可能となる。

## 3. 学習推論と指標算出の結果

### (1) データセット

AI 開発支援プラットフォームから教師画像の基準づくりに参画するなかで、精度確認を行った。橋梁床版のひび割れ画像、ひび割れを塗り分けた教師ラベル合計6枚の提供を受けた。表-1に、元画像のサイズを示す。本稿では、学習用の入力サイズを224×224を設定する。元画像の画質の特徴量を失うことなく、ユニット画像を切り出すため、幅と高さが224の整数倍になるようにリサイズした。表-2のように、入力サイズ224の整数倍となる最も画質情報のロスが少ないサイズにリサイズした。最終的に、学習用のユニット画像は、No1が132×81=10,692枚、No3が136×67=9,112枚、残りの4枚が各々52×26=1,352枚となり、合計25,212枚の画像を整備した。

表-1 床版の元画像のサイズと学習用のリサイズ分割

画像 No.	幅 $w$ (pixel)	高さ $h$ (pixel)
1	29,527	17,990
2	11,597	5,699
3	30,296	14,819
4	11,597	5,699
5	11,597	5,699
6	11,597	5,699

表-2 学習用にユニット画像224×224の整数倍に近似したリサイズ (U=224を表す)

画像 No.	幅 $w$ (pixel)	高さ $h$ (pixel)
1	$132 \times U = 29,568$	$81 \times U = 18,144$
2	$52 \times U = 11,648$	$26 \times U = 5,824$
3	$136 \times U = 30,464$	$67 \times U = 15,008$
4	$52 \times U = 11,648$	$26 \times U = 5,824$
5	$52 \times U = 11,648$	$26 \times U = 5,824$
6	$52 \times U = 11,648$	$26 \times U = 5,824$

## (2) 領域検出器の学習結果

表-3 に、床版ひび割れを塗り分けた教師ラベルと元画像のペアのデータセットに対し、セマンティック・セグメンテーションの汎用的な3つのネットワーク U-Net, SegNet, DeepLabv3+ResNet18 を適用した場合の計算時間と精度指標を示す。30エポック、2万回の学習を行った。

訓練と試験の割合は、95:5 に設定した。ミニバッチは、16 と設定した。3つのネットワーク構造の比較に関する限り、F1 スコア、平均 IoU、ひび割れと背景のクラス IoU は、SegNet において最大の精度を発揮している。

表-3 各モデルの計算時間と精度指標の比較表

architecture	runtime	Mean F1	Mean IoU	Back-ground IoU	Crack IoU
U-Net	362m	0.6359	0.6769	0.9740	0.3799
SegNet-VGG16	451m	0.6891	0.7022	0.9784	0.4259
DeepLabv3+ResN18	160m	0.6195	0.6746	0.9734	0.3759

図-3 に、領域検出器の精度に関する学習プロセスを図示する。SegNet と DeepLabv3+ResNet18 は、転移学習であり、精度の振れ幅は相対的に小さい。一方、U-Net はスクラッチ学習であるため、前半に精度の振れ幅が見られるものの、2万回の反復計算により、安定収束に到達していることが読みとれる。図-4 に、領域検出器の予測誤差（損失）に関する学習プロセスを図示する。2万回の反復計算により、予測誤差を最小な水準に安定収束していることが読みとれる。さらに、224×224 サイズのユニット画像に対して、推論出力が不正解の領域が小さく、損傷の見落としがないか、教師ラベルと推論領域のオーバーレイ画像を作成し、精査することとする。

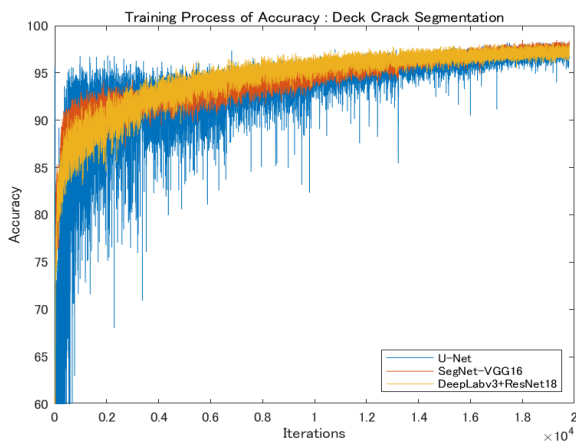


図-3 領域検出の精度に関する学習プロセス

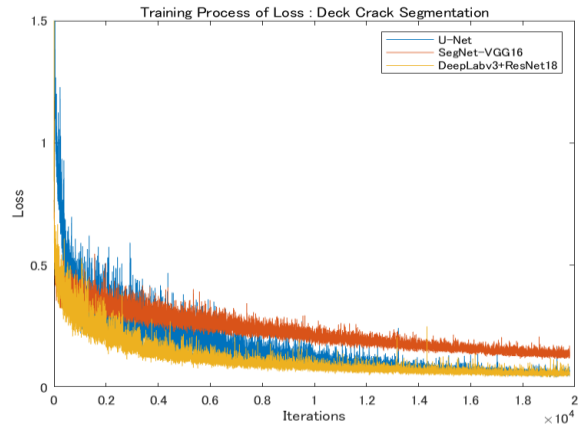


図-4 領域検出の予測誤差（損失）に関する学習プロセス

図-5 に、学習済みの U-Net にユニット画像を読み込んだ推論出力を示す。ここで、ひび割れを塗り分けた教師ラベルと重ね合わせた。白色の領域は、推論出力と実損傷が一致（正解）を表す。また、緑色の領域は、実損傷の周りに余分な推論（不正解）があることを表す。さらに、紫色の領域は、推論出力が実損傷を捉えていない（推論の漏れ・見落とし）を表す。黒色の領域は、背景領域の正解を表す。U-Net は、ひび割れの漏れはないものの、正解の領域（白色）の周りに余分な推論が含まれており、やや過大な損傷推論となっている。




図-5 学習済みの U-Net によるひび割れ損傷推論と教師ラベル画像のオーバーレイ

図-6 に、学習済みの SegNet にユニット画像を読み込んだ推論出力を示す。この場合、ひび割れの推論漏れはなく、正解の領域の周りに、わずかな余分な推論が残る。




図-6 学習済みの Seg-Net によるひび割れ損傷推論と教師ラベル画像のオーバーレイ




図-7 学習済みのDeepLabv3+ResNet18によるひび割れ推論  
教師ラベル画像のオーバーレイ

表-4 SegNetの再学習の計算時間と精度指標

archite- cture	runtime	Mean F1	Mean IoU	Back- ground IoU	Crack IoU
SegNet -VGG16	1510m	0.9697	0.8215	0.9914	0.6515

図-7に、学習済みであるDeebLabv3+ResNet18にユニット画像を読み込んだ推論出力を示す。密度の高い畳み込みを行うアルゴリズムであるため、正解の領域の周りに、食欲に損傷領域を拾いすぎていると解釈される。

以上のように、3つの領域検出器の学習結果を比較した結果、ひび割れ損傷の領域検出器として、SegNetを選択した。表-4に、さらに精度を発揮するため、100エポック、6万回の反復学習を繰り返し、25時間を要した。精度指標は、平均IoUが0.8215となり、F1スコアが0.9697まで高まった。




図-8 再学習したSeg-Netによるひび割れ損傷推論と  
教師ラベル画像のオーバーレイ

図-8に示すように、紫色のひび割れ領域の推論漏れ (less-recall) はまったく見られない。同時に、緑色の余分な不正解の推論 (over-prediction) がこれまで比較したなかで最大限に抑えられていることが読み取れる。以下では、再学習して精度を高めたSegNetを用いて、床版ブロック画像ごとに劣化指標を自動的に算出する。

### (3) 劣化指標の自動算出結果

2枚の床版画像に対して、SegNetの推論に輸入可能なサイズに、ブロック分割した画像ごとに劣化指標を自動算出する。No.4.5の床版画像は、8×8分割し、ブロック

画像のサイズを1,456×728とした。1ピクセルの原単位は、画像からコア抜き跡を参考に、それが直径10cmであることをふまえ、概算値として設定した。撮影する際に、床版までの距離と解像度を正確に把握することにより、1ピクセルの原単位を精緻に設定し、劣化指標を実寸評価することが可能となる。

図-9に、床版画像No.4を64分割したブロックごとに、劣化指標を自動計算した棒グラフを示す。ひび割れ延長あたりの損傷面積がブロックごとに小さい値をとる場合もあれば、著しく大きい値をとることもある。

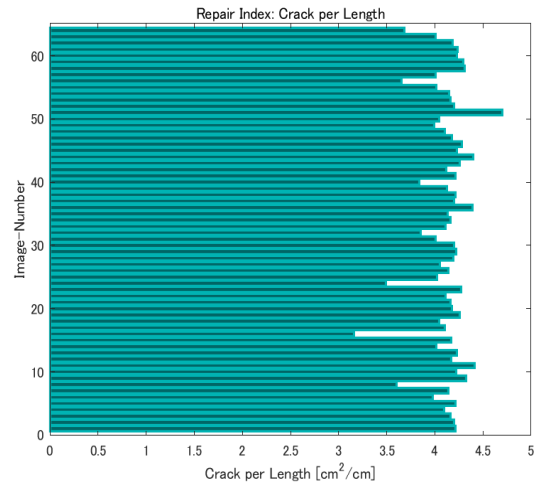


図-9 No4分割画像64ブロックの劣化指標の算出結果




図-10 SegNetによるひび割れ損傷(分離色分け)の  
推論出力 (No4の8×8分割;51番目の例示)

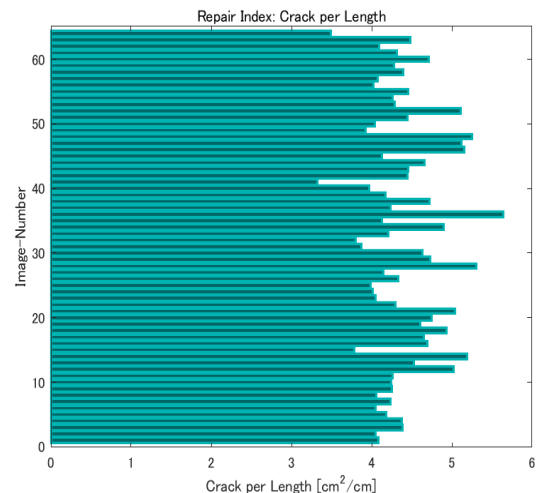


図-11 No5分割画像64ブロックの劣化指標の算出結果




図-12 SegNetによるひび割れ損傷（分離色分け）の推論出力（No5の8×8分割;36番目の例示）

図-10に、劣化指標の最大値をとった51番目のひび割れ領域の推論出力を示す。分離したひび割れは、異なるカラーで図示した。左下部に、2方向のひび割れが発生していることが読みとれて、そのことが楕円に含まれるひび割れ面積を増やし、劣化指標が大きくなっている。

図-11に、床版画像No.5を64分割したブロックごとに、劣化指標を自動計算した棒グラフを示す。この場合は、劣化指標の多寡が異なっており、著しく大きい値をとる場合が目立っている。図-12に、劣化指標の最大値をとった36番目のひび割れ領域の推論出力を示す。この中央部と右下部において、2方向のひび割れが発生している推論出力となっている。もちろん、床版画像No.4,5に対して、ひび割れ損傷のブロック別の推論出力を全体合成した損傷図の出力できるが、画像サイズの容量が膨大で、本稿の図から割愛せざるを得なかった。床版画像を俯瞰した場合に、2方向ひび割れの進行が読みとれる場合がある。1回の床版画像だけからでは、推論出力で認識された床版ひび割れが劣化進行しているものか、乾燥収縮により進行性はないものか、的確な判断は促せない。今後、5年に1回の点検に合わせて継続的に画像取得を行い、領域検出器の再学習と劣化指標の再計算を行うことが可能である。そこで、5年前と当該時点の劣化指標を比較することにより、劣化傾向の進行性を実評価できると考える。

#### 4. おわりに

##### (1) 損傷画像の教師あり学習と劣化指標の自動算出

本稿では、橋梁部材の損傷画像から損傷の特徴を抽出するための教師あり学習のタスクフローを提案した。具体的に、床版ひび割れをピクセル単位で塗り分けた教師ラベルと元画像を1対1のペアとする画像のデータセットを用いて、3つのセマンティック・セグメンテーションにより領域検出器を学習し、ひび割れ領域をピクセル単位で推論出力を可能とした。措置の選定支援のために、ひび割れの延長当たりの面積を近似した劣化指標を自動算出する方法を提案した。これによって、床版画像のな

かで、2方向ひび割れが進行しつつある予防保全の措置が求められる分割ブロックを抽出できた。本稿では、床版ひび割れを対象としたが、著者らは、このほかに鉄筋露出、塗装劣化、腐食、浮き剥落、漏水、遊離石灰において、教師あり学習の領域検出を行い、損傷の面積指標を自動計算するタスクフローが実行可能であることを確認した。本稿と同様の手順に沿って、異なる損傷ごとに教師画像を作成し、その領域を検出するためのパラメータを再学習できる。学習済みのネットワークを用いて、複雑な形状でも柔軟に損傷領域を推論し、それをピクセルカウントすることで、損傷の面積を劣化指標として自動計算することが可能である。今後も、土木構造物の点検・診断を支援するAI解析の実践を重ねていきたい。

##### (2) 今後の課題：希少損傷の教師なし学習と異常検知

橋梁点検の項目には、めったに表れないレアな損傷の点検も含まれる。例えば、コンクリートの抜け落ち、鋼材の亀裂・破断は、老朽化したとしても頻発するものではない。レアな損傷はデータマイニングに根気強く取り組む時間を要することが、教師あり学習の課題となる。この場合、異常検知のアプローチが有望であり、（損傷の特徴の）教師なし学習が健全な画像だけを用いて可能と考える。著者らは、20～60年を経過したコンクリート構造物の堤体に対して、画像生成による異常検知の手法を提案している<sup>18)</sup>。事前に、点検項目に含まれない予期せぬ異常な状態を検知できる可能性がある。今後、教師あり学習を補完する目的から、橋梁部材のレアな損傷に対して、教師なしの異常検知を実行可能性を確認することが課題である。トンネルの覆工画像において、ひび割れ、浮き剥落、漏水、遊離石灰の損傷が発生しうが、教師ありの領域検出の学習が可能である。トンネル管理において、第三者被害を回避するための緊急措置を判定するための劣化指標の設定が課題である。

橋梁の余寿命予測において、劣化曲線の推定が求められる。従来の劣化曲線の縦軸は、健全度判定ランクや詳細調査による測定値を用いていたが、本稿で提案した劣化指標を用いれば、客観的な損傷の数値に基づいた劣化曲線の推定が可能となる。近接目視の画像全体からではなく、損傷の領域検出した劣化の数値指標を用いることで、人の判定によるばらつきを抑制できる。また、詳細調査による時間と費用を軽減できると考える。平成26年度に橋梁定期点検要領が定められてから、1巡目を終えて、2巡目に入る管理者が多いなか、本稿で提案した教師あり学習のタスクフローを汎用導入することで、点検から措置までのサイクル迅速化に寄与することが可能と考える。

さいごに、2014年以降、画像のディープラーニングに関するアルゴリズム実装と実用研究の蓄積がめざましい。

NeurIPS, CVPR, ICML, ISARC 等の最前線の学会では、損傷認識に関連する画像の適用事例が多く報告されている。最新の論文をサーベイし、背景の潮流と独創的な方法論を楽しく理解するため、専門図書<sup>20,22)</sup>を推薦します。

**謝辞**：本稿の教師あり学習と推論にあたり、MathWorks の蔵本進一氏、福本拓司氏より、MATLAB リソースの情報提供を頂いた。ここに感謝の意を表します。

## 参考文献


- 1) Sejnowski T.J., *The Deep Learning Revolution*, MIT press, 2018.
- 2) Xu S., Wang J., Shou W., Computer vision technique in construction, operation and maintenance phases of civil assets: a critical review, *36th International Symposium on Automation and Robotics in Construction (ISARC)*, 2019.
- 3) Kucuksubasi, F., Sorguc A.G., Transfer learning-based crack detection by autonomous UAVs, *35th International Symposium on Automation and Robotics in Construction (ISARC)*, 2018.
- 4) McLaughlin E., Charron N., Narasimhan S., Combining deep learning and robotics for automated concrete delamination assessment, *36th International Symposium on Automation and Robotics in Construction (ISARC)*, 2019.
- 5) Gopalakrishnan K., Gholami H. et al., Crack damage detection in unmanned aerial vehicle images of civil infrastructure using pre-trained deep learning model, *International Journal for Traffic and Transport Engineering*, 8(1), pp1-14, 2018.
- 6) 町田敦志, 喜多敏春, 多田徳夫, 武井宏将, 近田康夫: ディープラーニングによるコンクリート建造物の劣化要因判定支援システムの開発に関する基礎的研究, 構造工学論文集, Vol.64A, 2018.
- 7) 青島亘佐, 河村伸哉, 中野 聡, 中村秀明: 深層学習による画像認識を用いたコンクリート建造物の変状検出に関する研究, 土木学会論文集 E2 (材料・コンクリート構造), Vo.74, No.4, pp293-305, 2018.
- 8) 金澤文彦: 道路橋メンテナンスにおける AI・ICT の活用, 令和元年度土木研究所講演会, 2019.
- 9) 山根達郎, 全邦釘: Deep learning による Semantic Segmentation を用いたコンクリート表面ひび割れの検出, 構造工学論文集 A, Vol. 65, pp. 130-138, 2019.
- 10) Chun, P., Izumi, S., and Yamane, T.: Automatic detection method of cracks from concrete surface imagery using two-step light gradient boosting machine, *Computer-Aided Civil and Infrastructure Engineering*, pp.1-12, 2020.
- 11) Yasuno T., Fujii J. Amakata M.: Pop-outs segmentation for concrete structure prognosis indices using UAV monitoring and per-pixel prediction, *Proceedings of 12th International Workshop on Structural Health Monitoring*, 2019.
- 12) 中島道浩, 安野貴人, 永富大亮, 野田一弘他: 目視点検の損傷画像による鉄筋露出セグメンテーションの転移学習, 人工知能学会, 新潟大会, 2019.
- 13) 国土交通省 道路局 国道・防災課: 橋梁定期点検要領, 床版ひびわれ, pp.24-25, 2014.
- 14) 国土交通省 道路局: 道路橋定期点検要領, 床版ひびわれ, pp.47-50, 2014.
- 15) Ronneberger, O., Fischer, P., Brox, T.: U-Net: Convolutional Networks for Biomedical Image Segmentation, *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, Springer, LNCS, Vol.9351: pp.234-241, 2015.
- 16) Badrinarayanan, V., Kendall, A. et al., SegNet: Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, arXiv:1511.00561v3, 2016.
- 17) Chen, L-C., Zhu, Y., Papandreou, G. et al.: Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation, arXiv:1802.02611v3.
- 18) Gonzalez, R.C., Woods, R.E., Eddins, S.L.: *Digital Image Processing Using MATLAB*, 2nd edition., McGraw Hill Education, 2010.
- 19) Yasuno, T., Ishii, A., Fujii, J., Amakata, M., Takahashi, Y.: Generative Damage Learning for Concrete Aging Detection using Auto-flight Images, *37th International Symposium on Automation and Robotics in Construction (ISARC 2020)*, 2020(forthcoming).
- 20) 原田達也, 画像認識, MLP, 講談社, 2017.
- 21) Chollet, F., *Deep Learning with Python*, Manning Publications, 2017, (和訳) Python と Keras によるディープラーニング, マイナビ, 2018.
- 22) Sejnowski, T., *The Deep Learning Revolution*, Newton Press, 2019, (和訳) ディープラーニング革命, ニュートンプレス, 2019.

(Received June 30, 2020)  
(Accepted July 31, 2020)

## FLOOR SLAB CACK SEGMENTATION LERANING FOR INSPECTION AND NUMERICAL DETERIORATION INDICATOR

Takato YASUNO, Michihiro NAKAJIMA, Kazuhiro NODA and Masahiro OKANO

Among the deterioration of 700,000 bridges in Japan, making the bridge inspection once every five years sustainable is a fundamental issue. In order to speed up the cycle from inspection to repair measures, it is required to inspect consistently health condition while suppressing variations, and to select a repair method using numerical indicators. In order to extract the pixel-wise region of bridge elements, we propose a method that learns a target region detector useful for feature extraction of damage by semantic segmentation using the dataset for the images of the floor slab and its crack annotated labels. This method automatically calculates a deterioration index for scaling crack area. Finally, we address the issue of generalization of bridge inspection support tools.



補図-1 元画像（左）と SegNet 推論出力の Green-Magenta 強調色対比（右）（No4 の 8×8 分割; 51 番目）




補図-2 SegNet 推論出力のマスク画像（No4 の 8×8 分割; 51 番目）



補図-3 元画像（左）と SegNet 推論出力の Green-Magenta 強調色対比（右）（No5 の 8×8 分割; 36 番目）



補図-4 SegNet 推論出力のマスク画像（No5 の 8×8 分割; 36 番目）



補図-5 SegNet 推論出力のマスク画像（No5 全体の損傷図）