

地方公共団体での橋梁定期点検における AI 活用の可能性

西尾 真由子*

現行の橋梁定期点検体制では、全国 70 万の橋梁で技術者が近接目視で部材ごとに損傷度を判定することがもとめられている。著者のグループでは、橋梁点検における「判断」のなかで AI・機械学習が代替しうるものがあるのか、現時点で蓄積されているデータでそれがどの程度可能であるのか、検討する試みを実施してきたので本稿で紹介する。地方公共団体が管理する橋梁の定期点検画像データを用いて、主桁と床版を対象に部材損傷度を判定する畳み込みニューラルネットワーク (Convolutional Neural Network, 以下 CNN) を構築した。そして、CNN での特徴量抽出を把握する可視化技術 Grad-CAM を適用し、CNN の部材損傷度判定根拠の検証を行った。可視化結果から各部材画像で判定に寄与した画像領域や特徴量の把握が可能であり、可視化技術が CNN の判定性能や受容性の向上に有効であることを考察した。

キーワード：部材損傷度、畳み込みニューラルネットワーク、判断根拠、可視化

1. はじめに

わが国の橋梁では、2014 年に定期点検要領^{1,2)} が設定され、それに基づいて全橋梁で点検技術者による定期的な目視点検を実施する体制が敷かれている。しかし、全国約 70 万もの橋梁 (橋長 2 m 以上) の約 9 割は地方公共団体の管理下にあり、さらに約 7 割は市区町村管理の橋梁である。このような地方公共団体ではとくに、現行の体制で定期点検を実施していくのに財政的な負担が大きいうえ、適切に損傷状況や構造状態を判断できる技術者の不足にも直面している³⁾。また、将来のわが国における人口減少社会を鑑みると、地方公共団体だけでなく国全体で、インフラ維持管理の財源不足とそれに関わる技術者の不足も懸念され^{3~6)}、将来に向けた持続可能な維持管理体制を考えていく必要がある。一方、近年ではビッグデータや AI・機械学習に関わる技術が社会的に注目されており、さまざまな分野でその活用を考えられる状況になっている。持続可能な橋梁維持管理体制の構築にも、この技術の活用を検討するべきと考える。

「AI」は Artificial Intelligence すなわち「人工知能」であるが、その定義は広範で年代とともに変遷しているうえに、関連の研究者によっても定義が異なる⁷⁾ のことである。そのなかでも近年話題となっている AI は、とくに機械学習の一つである「深層学習 (ディープラーニング)」の登場により、大量のデータ「ビッグデータ」をコンピュータ

で学習し、物事を「推論・予測・判断」するシステムを研究・構築することを指している⁸⁾ と筆者は捉えている。橋梁定期点検も、損傷の有無や度合いの評価から対策の判定まで、橋梁管理者・技術者の「判断」が大いに関わっているうえ、すでに全国で大量の点検データが蓄積されてきている。

そこで著者のグループでは、橋梁点検における「判断」の中で AI・機械学習が代替しうるものがあるのか、現時点で蓄積されているデータでそれがどの程度可能であるのか、検討する試みを実施してきた^{8,9)} ので、本稿で紹介したいと思う。具体的には、地方公共団体である横浜市の橋梁定期点検データを用いて、記録されている部材画像からその損傷度を判定する深層学習ネットワークの構築を行った。そして機械学習分野で活発に研究されている「可視化技術」を適用して、構築した部材損傷度判定ネットワークで入力画像の何をどのように見て判定を導いているのか、すなわち「判定根拠」を調べた。その結果を考察しながら、AI・機械学習システムが、それを管理者や技術者が受容しながら、将来の持続可能な橋梁維持管理に貢献できる可能性があるのか検討した。

2. 地方公共団体における橋梁定期点検

2.1 橋梁定期点検の流れ

「道路橋定期点検要領^{2,10)}」は、一般道 (都道府県道・市町村道) 橋梁の定期点検への技術的助言として示されているものである。これに対して「橋梁定期点検要領^{1,11)}」は、国土交通省が管理する国道橋梁の定期点検に対して、その標準的な内容や注意事項を規定したものである。地方公共団体の管理橋梁は、道路橋定期点検要領に沿って、そして橋梁定期点検要領を適宜参考にして定期点検体制を構築し、維持管理されている。2019 年 2 月と 3 月にはどちらの要領も改訂が行われたが^{10,11)}、本稿で紹介する検証ではこれまでに実施された定期点検でのデータを用いたので、改訂前の要領について、まずは簡潔にまとめる。

道路橋定期点検要領では、基本的に 5 年に 1 回の頻度で



* Mayuko NISHIO

筑波大学
システム情報系 准教授

定期点検を実施すること、そこでは基本的にすべての部材について近接目視やそれと同等の手段で健全性診断を行うこと、とされている。そして、その診断結果に基づいて補修・補強の実施、定期／常時監視、通行規制など必要な対策を講ずる。またこれとはべつに、部材単位の健全性診断結果を踏まえて橋梁ごとに総合的な健全性を診断し、道路管理者が保有する橋梁全体の状況を把握することがもめられている。また点検結果は統一された様式で記録し、当該橋梁が利用されている間は保存することとされている。

この定期点検の流れのなかでは、近接目視による部材単位の健全性診断が、その後の意思決定に重要な役割を担っている。しかし道路橋定期点検要領には部材の健全性診断について細かい記述はなく、点検する部材の分類や評価する変状の種類は国道で適用される橋梁定期点検要領を参考にできる、と記されている。一方、橋梁定期点検要領²⁾では、定められた部材ごと、損傷種類ごとに損傷程度を評価することがもめられている。そしてその「付録-1²⁾」には、鋼部材について「腐食」「き裂」、コンクリート部材について「ひび割れ」「剥離・鉄筋露出」というように、各部材と損傷種類について区分「a-e」の判定基準が示されている。また参考資料として「橋梁損傷事例集^{12,13)}」が国土技術政策総合研究所から発行されており、橋梁の損傷事例とその損傷区分判定が記されている。点検技術者はこの点検要領と参考資料などを踏まえ、現場での近接目視で損傷区分「a-e」を判定して記録する。地方公共団体の定期点検でも、国道と同様に現場で部材ごとの損傷度判定を実施し、それを基に部材単位または橋梁ごとの健全度診断を行っているところがあり、本検証で対象とした横浜市もこれに該当する。

2.2 横浜市の橋梁定期点検

地方公共団体のなかでも政令指定都市である横浜市は、一部の国道も含む1712橋もの橋梁を管理している(H30.4.1時点)。定期点検への取組みは比較的早く、2004年に横浜市橋梁点検要領を設定し、この年から原則5年に1回の定期点検を実施してきている。本稿で紹介するAI活用への検証で用いたのは「横浜市橋梁点検要領・第5版¹⁴⁾」に沿って実施された最近の点検データである。ここでは、各橋梁で基本的に全部材に対して近接目視を実施し、「損傷なし、損傷度(a), …, (e)」の6区分で、部材損傷度が判定されている。この区分設定は、橋梁定期点検要領²⁾の損傷度区分を参考としつつ損傷の有無を明確にするため、まったく損傷の認められない場合に「損傷なし」、もっとも軽微な損傷を「(a)判定」、そしてもっとも損傷が著しく安全確保の支障となるおそれがある場合に「(e)判定」とすることが定められている。損傷のない部材を(a)判定に含めるか分けるかの違いで、損傷度(b)-(e)の区分は橋梁定期点検要領²⁾と同様である。点検調査は橋梁単位または径間単位に数種の様式で作成され、その様式の一つである損傷写真台帳には部材画像、部材名、損傷の種類、そして損傷度が記録されている。そして、この各部材に判定された損傷度に応じて詳細点検や補修・補強の実施を決定するフローを定めており、また部材損傷度をスコア化して

橋梁健全性を指標化し記録している。

2.3 点検業務における「判断」の省力化

以上に横浜市の例を述べたように、地方公共団体での定期点検でも、国道での橋梁定期点検の流れに準じて部材損傷度の判定が実施されている。これは、道路橋定期点検要領¹⁾においても、近接目視ですべての部材を点検することが求められているためと考えられる。図-1は、改訂前の橋梁定期点検要領²⁾に記載されている点検のフロー図を、著者らが簡潔に書き直したものである。やはり近接目視による部材損傷度判定が、その後の対応の基となる「判断」であることが分かる。しかしこのフローを成り立たせるには、技術者が現場で目視に基づく判断を実施することが必須である。このための足場設置や点検車両の配備、交通規制などにかかるコストが膨大となること、そして部材損傷度判定を行える点検技術者を確保することが、将来の持続可能な体制構築へのボトルネックとなるであろう。

そこで著者らは、図-1中に示すように、この部材損傷度判定をAI技術でできないか、検討することとした。図-2に示すように、部材画像を入力として「部材損傷度(a)-(e)」といった指標を出力とする機械学習システムが可能となれば、各橋梁での現場作業は部材画像の取得のみとなり、これにはたとえば高性能カメラやドローン撮影などの技術を用いることも考えられ、現場業務の省力化が図れる。さらに、大量の部材損傷度判定が機械学習で実施出来れば、橋梁管理者や技術者はそれに基づいて、その後の対策や健全性の判断に集中できる。

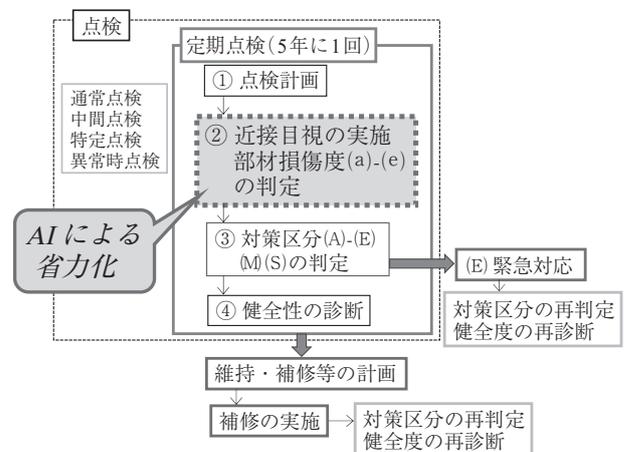


図-1 橋梁定期点検の流れにおけるAI活用

3. 橋梁部材損傷度判定 CNN の構築

機械学習は、データを計算機で解析して有用な規則性や判断基準を見出すことである。このなかでは、入力データから目的とする予測や判断に対して適切な関連性をもつ特徴量を抽出し、回帰や分類を実施する。ただし、データが大量であったり、1つ1つのデータが複雑であったりするとき、有効な特徴量が見いだせない場合も多い。これに対して、近年の計算機性能向上の貢献もあり、大量で複雑なデータそのものを入力して特徴量抽出も含めて解析する「深

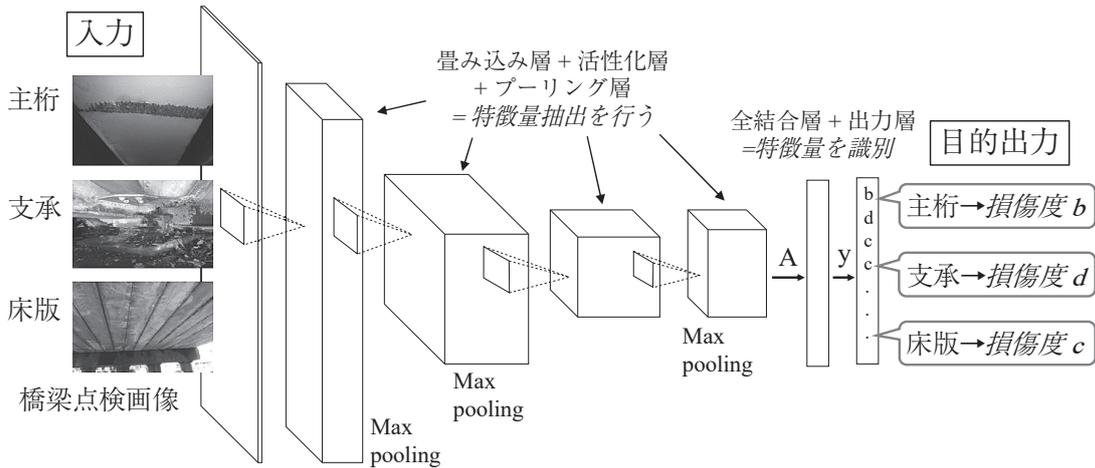


図 - 2 部材損傷度判定畳み込みニューラルネットワーク (CNN)

層学習」のさまざまなアルゴリズムが登場した。とくに画像に対する深層学習の手法として適用されるのが「畳み込みニューラルネットワーク Convolutional Neural Network」である。本検証の橋梁部材画像による損傷度判定にも、この CNN を用いた。

3.1 畳み込みニューラルネットワーク CNN の概要

畳み込みニューラルネットワーク CNN¹⁵⁾ では、図 - 2 中に示すように入力画像データを複数の演算の層を通して目的出力を得る。基本的な層構成は「畳み込み層」「活性化層」「プーリング層」「全結合層」からなる。

入力画像は数値化して、幅と高さ（行列）および RGB カラーモデルの 3 次元データとして取り扱う。「畳み込み層」では、入力データに対して重みのフィルタ行列を一定の間隔で移動させながら適用し、それぞれの場所でフィルタの要素と入力の対応する要素を乗算してその和を格納する畳み込み演算と呼ばれる処理を行う。次に「活性化層」で入力信号の総和を出力信号に変換する活性化関数を適用する。「プーリング層」は、縦方向と横方向の空間を小さくするプーリング演算を行う層である。画像認識では主に「Max プーリング」が使われる。この 3 つの層は特徴抽出部といわれ、目的の判断に関与する画像の特徴を捉えているはずである。しかし CNN では、どのような特徴量抽出を行っているかは基本的にブラックボックスである。「全結合層」では、画像データを 1 次元に展開し重み付き結合を計算する。適切な CNN は問題ごとに異なり、その構築では入出力関係が既知である学習データを用いて、重みなどのパラメータを推定する。誤差逆伝播法は CNN 構築で多用される勾配法の一つで、出力層における誤差に関する損失関数を最小化するようにパラメータを推定する。

3.2 CNN の入力データと判定区分

図 - 3 には、本検証で用いた横浜市の橋梁定期点検における部材画像データの構成を示す。対象とした部材は、損傷写真台帳のなかで画像データ数が多く、橋梁の耐荷性能にも影響の大きい主桁、床版、そして支承とした。各部材で損傷度ごとにデータ数をまとめると、損傷度 (b)-(c) にデータ数が偏っていることが分かる。これは管理橋梁の

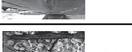
部材 損傷度	主桁	床版	支承部	
損傷なし	 24	 37	 161	損傷度 判定 I ↑
a	 31	 136	 1	
b	 1 421	 1 686	 35	
c	 1 062	 1 761	 1 032	損傷度 判定 II ↓
d	 317	 305	 129	
e	 5	 0	 0	

図 - 3 画像データ数の分布と CNN 判定区分

損傷状況を示しているともいえるが、一方で、損傷写真台帳の目的が発見した損傷の記録にあるため「損傷無し」「損傷度 (a)」の記載は少なくなることで、「損傷度 (e)」はそれに至る前に補修など対策を実施するため、数が少なくなることも偏りの原因と考えられる。

著者らが構築した CNN は、この 6 区分「損傷なし、損傷度 (a)、…、(e)」をそのまま出力するものとしなかった。機械学習の分類問題において性能を得るには、各分類区分で学習データを十分な数で均等に構成することが必要となり、図 - 3 に示す 6 区分では画像数の偏りが大きすぎたためである。そこで図 - 3 中に示すように「損傷なし、(a)、(b)」で「損傷度判定 I」、「損傷度 (c)-(e)」で「損傷度判定 II」と、2 区分で分類を行うものとした。これは、横浜市橋梁定期点検要領¹⁴⁾において、詳細点検の実施の有無が部材損傷度 (b) と (c) で分かれることをうけて設定した。

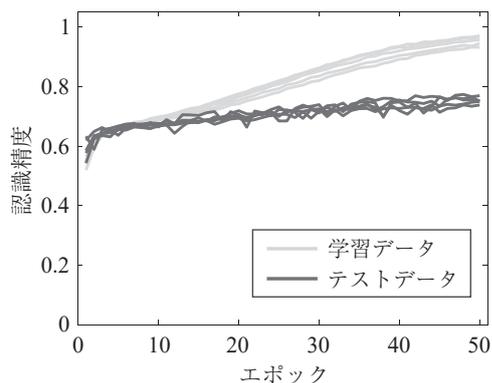
損傷写真台帳から取り出した元の画像データは画像ごとにサイズが異なっていたため、はじめに 80×80 pixel に統一する処理を行い、その上で元画像を回転・反転させてデータ数を増やす「データ拡張」を行った。そして、データが少ないほうの判定区分の数に合わせて、もう一方の区分のデータを無作為抽出で減らし、2 つの分類区分でのデータ

数を等しくした。なおここでは、材料による区別は行っておらず、主桁であれば鋼主桁とRCおよびPCのコンクリート桁を合せて扱っており、その比率は6:4程度であった。床版はRC床版が約9割に対して鋼床版が約1割であった。

3.3 構築したCNNの評価

CNNの構築や検証はプログラム言語Pythonによって実施し、パラメータの推定計算には深層学習フレームワークの1つであるChainer¹⁶⁾を用いた。主桁と床版いずれの部材損傷度判定CNNも8層の畳み込み層と3層の全結合層で構成し、活性化関数はCNNで一般的に適用されるReLU関数、プーリング演算はMaxプーリング、出力層の活性化関数はソフトマックス関数とした。パラメータ推定での損失関数には交差エントロピー誤差を用いた。各部材のデータは4:1に分け、それぞれ学習データ、テストデータとした。

図-4と図-5に、主桁と床版それぞれについて構築したCNNの認識精度プロットと混同行列を示す。認識精度プロットでは、学習過程の推移と精度を検証できる。横軸のエポックは、用意した学習データをすべて使って学習させる回数であり、エポック数が大きくなるにつれてその学習の繰り返し回数が増えてCNNの精度が上がっていく。いずれのCNNでも50エポック程度で学習精度が1.0すなわち100%に到達し、テストデータで70%程度の精度が得られた。混同行列は機械学習の性能を調べるときに用いるもので、図中に示すように4つの判定結果のパターンをTrue Positive (以下, TP), False Positive (以下, FP), False Negative (以下, FN), True Negative (以下, TN)として、テストデータで各判定を出力した画像数を示した。全体の正答率は全データ数に対するTPとTNの比率いわゆる精度であり、主桁で75%, 床版で71%となった。さらに、実際は損傷があるのに損傷と捉えられていない、つ



		目視点検	
		判定分類 I 損傷なし(a)(b)	判定分類 II 損傷度(c)-(e)
CNN	判定分類 I 損傷なし(a)(b)	TP=1 232	FP=398
	判定分類 II 損傷度(c)-(e)	FN=429	TN=1 263

図-4 「主桁」の精度プロット(上)と混同行列(下)

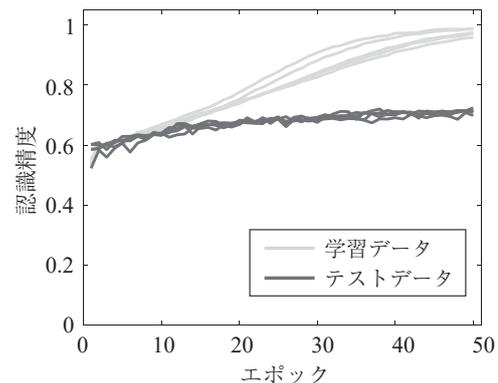
まり過小評価の度合いを調べる指標が適合率 (Precision) で、TP+FPに対するTPの比率である。構築したCNNでは主桁で76%, 床版で72%となり、いずれの部材でもCNNで「判定I」となった画像の4分の1程度が過小評価されたことになる。

4. AIの判定根拠と受容

部材損傷度判定は、点検要領のように「人」が設定した判断基準に沿って、技術者すなわち「人」が目視で専門知識や経験にも基づき判断する。この場合には、精度などの指標で評価するCNNの機械学習としての「正しさ」とともに、この判断に関わる人、すなわち橋梁管理者や点検業務を実施する技術者などの「正しそう」という認識が得られて初めて、構築したCNNは受容される。CNNによる判定が橋梁運用の現場で受容されるためには、その判定根拠を明確にする必要があると考える。CNNは一般的に、入力から出力を導く計算過程が特徴量抽出を含めて明らかでなく、その判定の根拠はブラックボックスである。しかし近年は、その判断根拠を調べる手法である「可視化技術」が活発に研究されており、構築した部材損傷度判定CNNにもその1つを適用して、判定根拠を検証し考察した。

4.1 CNNの可視化技術: Grad-CAM

著者らが適用した可視化技術は、比較的近年に登場したGrad-CAM¹⁷⁾という手法である。Grad-CAMでは、図-1に示すCNNの構造で、入力画像に対して出力された各判定区分に関する勾配から、最下層である畳み込み層の特徴抽出マップが判定結果に与える影響度を計算する。そして判定結果に正の影響を与えている画像ピクセルのみ活性化関数で値を出力し、各入力画像のピクセル間での相対的な影響度を「ヒートマップ」と呼ばれるコンター図で出力する。



		目視点検	
		判定分類 I 損傷なし(a)(b)	判定分類 II 損傷度(c)-(e)
CNN	判定分類 I 損傷なし(a)(b)	TP=1 535	FP=588
	判定分類 II 損傷度(c)-(e)	FN=696	TN=1 643

図-5 「床版」の精度プロット(上)と混同行列(下)

4.2 人とCNNの判定根拠の比較と受容

著者らは、プログラムコード共有サイトのGitHubを利用し、公開されていたGrad-CAMのPythonコードをダウンロードして、元の文献¹⁷⁾で定式化を確認しながら、構築した部材損傷度判定CNNに実装した。さらに、人の判断根拠との比較を行うため、各画像に対してマーキング作業を行った。ここでは、土木工学を専攻する大学院生複数名により、部材損傷度判定に寄与する画像領域を手動で塗りつぶす作業を実施した。たとえば、点検台帳にRC床版の「ひび割れ」に対する損傷度が判定されている画像に対して、その判断に寄与していると思われるひび割れ部を塗りつぶした。

得られたGrad-CAMヒートマップとマーキング画像を、元画像とともに並べたのが図-6である。ヒートマップは、赤に近いほど判定への影響度が大きかった箇所、逆に青となるほど小さい。図-6(a)は点検での損傷度(d)であった鋼主桁の腐食である。画像中央の錆が固まった箇所が該当する損傷部であり、中央の画像でも赤くマーキングしてある。一番右のヒートマップをみると、最も濃い赤が損傷部を示しており、CNNがこの部分を適切に重要視して損傷度の判定を出力したことを示している。

図-6(b)は、点検で鋼主桁の腐食として損傷度(b)が判定され、台帳でそれに添付されていた画像である。かなり遠望の画像であり、拡大すればかろうじて損傷部がマーキング画像のように捉えられる。一方、CNNでは主桁ではなくもっとも手前のRC床版を捉えて判定を出力している。一方、図-6(c)は鋼主桁とRC床版が写っている画像であるが、台帳に記録されていたのは鋼主桁の腐食で「損傷度(c)」である。しかし床版にはひび割れがみられ、CNNでも床版の領域を重要視して判定を行っている。これらはいずれも、判定結果はTPとTFに分類されており、CNNの判定としては成功している。しかしこのように可視化すると、CNNの判定結果は見るべき部材と損傷箇所をみて判断されたものではないことが分かり、CNNの受容が難しくなる。この2つの画像をみると、いずれもグレースケールであるコンクリート部を重要視する傾向にあると考えられる。

そして図-6(d)は、夜間に撮影された鋼主桁画像である。表面に軽微な塗膜の劣化がみられ、点検で「損傷度(b)」と判断されている。一方でCNNは、損傷度の高い区分である「損傷度判定II」を出力してFNとなっている。CNNをみると、白く塗装されている主桁の領域を捉えているものの、明暗差の大きいエッジとその少し外側の黒い領域をより重要視して判定していることが分かる。夜間に照明やフラッシュをたいて撮影した画像であるため、主桁が浮き上がるような画像となっており、エッジが非常に際立っている。このような画像では画素値が急峻な変化を示すことになり、本検証で構築したCNNはこのような箇所を特徴として抽出していると考えられる。

損傷部の見た目は、周囲との色や質感の変化で捉えられることは納得でき、図-6(d)のように画素値の急峻な変化部をCNNが捉えていることは受容できる。また、図

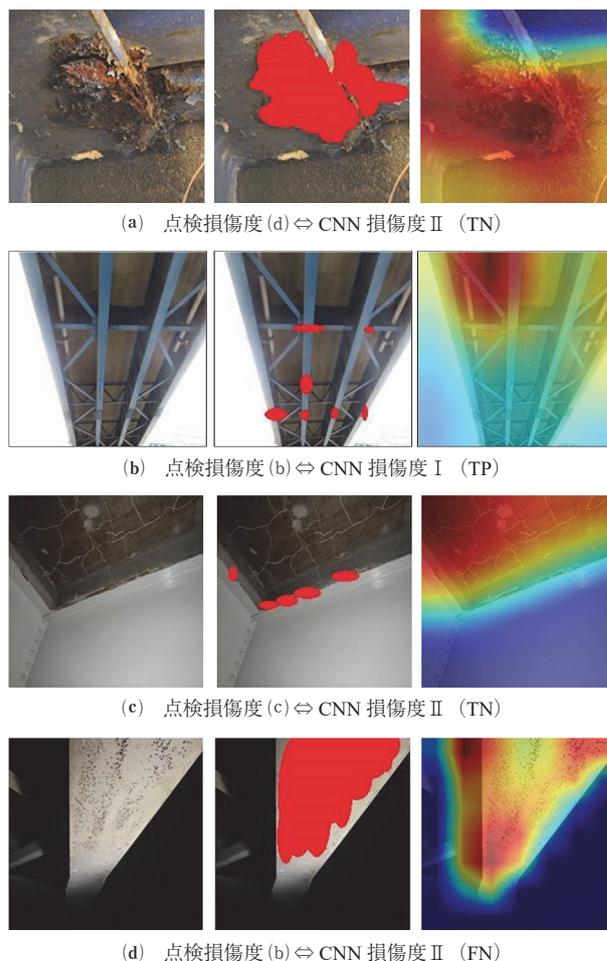


図-6 「主桁」損傷度判定での人とCNNの判断根拠の比較 (左：元画像，中央：マーキング，右：Grad-CAM)

-6(a)の腐食のようにいくつかの損傷部では変状によって黒色つまり輝度が低くなる傾向にあり、また図-6(b)や(c)でコンクリート部材を重要視していたことから、輝度の低い領域を捉えていることも考えられる。ただし、損傷を有する部材が画像全体のある程度の領域を占めていなければ、その損傷領域を捉えられないことも考察される。遠望の画像や1つの画像に複数の部材が写り込む画像に対してとくに受容できる判定結果が得られていないが、用いたデータは本来、点検台帳で記録保存しておくための画像である。このGrad-CAMの結果から、部材損傷度判定に適した画像データ取得を検討していくことも必要であると考察された。

5. おわりに

本稿では、著者らが実施してきている橋梁定期点検へのAI・機械学習活用への検討の試みを紹介した。これまで蓄積された橋梁定期点検でのデータを用いても、70%を超える精度で部材損傷度判定が可能なCNNを構築できた。そのうえでGrad-CAMによる可視化を行うことでCNNの判定根拠を考察することができ、そこからCNNへの受容を構築していくことの有効性を認識した。今後は、高い性能と可視化での受容が得られた画像データを学習させる

といった方法で、AI活用に適した画像データ構成、取得と蓄積、処理方法を検討していくことにしている。またこのようなAI活用への検討は、これまでの技術者自身の判断根拠の解明と伝承に向けた試みにもつながる。

2019年に改訂された橋梁定期点検要領¹¹⁾では、部材ごとに損傷度(a)-(e)を判定する必要性が記されなくなった。しかし橋梁定期点検要領¹¹⁾と道路橋定期点検要領¹⁰⁾のいずれにおいても、部材ごとの点検で健全性を診断し対策を判断しなければならないことは変わりなく、そのなかで本検証のようなAI・深層学習による判断の補完・代替は、今後ますます活用を考えていく価値があると考えられる。

参考文献

- 1) 国土交通省 道路局：橋梁定期点検要領，2014。
- 2) 国土交通省 道路局：道路橋定期点検要領，2014。
- 3) 国土交通省 道路局：道路メンテナンス年報，2017。
- 4) 一丸結夢，石田東生，岡本直久：橋梁および高速道路上の横断構造物に対する維持管理の実態と課題，土木学会論文集 D3, Vol.70, No.5：pp.1-45-1-54, 2014。
- 5) 工藤正行，杉本博之：ある地方公共団体に属する市町村の橋梁維持管理体制と課題，構造工学論文集，Vol.61A, pp.486-494, 2015。
- 6) 川西 寛，丸山 収，三木千壽：市町村の橋梁点検業務の費用

分析と対策について，構造工学論文集，Vol.62A, pp.459-471, 2016。

- 7) 総務省：情報通信白書平成28年度版，<http://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h28/html/nc142000.html> 2019 [2019/09/17 閲覧]
- 8) 鈴木達也，西尾真由子：橋梁定期点検における部材損傷度判定への深層学習の適用に関する検討，土木学会論文集 F3, 2019. (掲載決定)
- 9) 栗栖雄一，西尾真由子：深層学習の可視化で性能向上をはかる橋梁点検部材損傷度判定システムの構築，応用力学シンポジウム，2019。
- 10) 国土交通省 道路局：道路橋定期点検要領，2019。
- 11) 国土交通省 道路局：橋梁定期点検要領，2019。
- 12) 国土技術政策総合研究所：道路橋の定期点検に関する参考資料(2013年版) 橋梁損傷事例写真集，国総研資料 第748号，2013。
- 13) 国土技術政策総合研究所：道路橋の定期点検に関する参考資料(2013年版) 橋梁損傷事例写真集，国総研資料 第748号，2013。
- 14) 横浜市道路局建設部橋梁課：横浜市橋梁点検要領(案)，2015。
- 15) 斎藤康毅：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，オライリージャパン，2016。
- 16) Chainer: <https://chainer.org/> [accessed in October 11, 2017]
- 17) Selvaraju, Ramprasaath R., et al.: Grad-cam: Visual explanations from deep networks via gradient-based localization. Proc. IEEE International Conference on Computer Vision. pp.618-626, 2017。

【2019年10月4日受付】



刊行物案内

フレッシュマンのための PC 講座 — 増補改訂版 — 平成28年1月 発行

これからプレストレストコンクリートについて学ぼうとする方への教材として、おすすめの一冊です。

- イラストを多用し、平易な文章でプレストレストコンクリートの世界をわかりやすく解説
- 内容・資料・写真などを最新のものに更新、全ページをカラー化
- 維持管理と補修・補強(基礎編9)について追補



(A4判 全150ページ)

定 価 3,666円(税込) / 送料300円

会員特価 3,000円(税込) / 送料300円

公益社団法人 プレストレストコンクリート工学会

目次構成

基礎編 1	PC とは何か
基礎編 2	PC とはどんなものに利用できるか
基礎編 3	プレストレスの与え方について考えてみよう
基礎編 4	プレストレスは変化する
基礎編 5	荷重と断面力について考えてみよう
基礎編 6	部材に生じる応力度について考えてみよう
基礎編 7	プレストレス量の決め方について考えてみよう
基礎編 8	PC に命を与えるには (プレストレッシングとその管理)
基礎編 9	PC を長生きさせよう
PC 橋編 1	PC 橋にはどんなものがあるか
PC 橋編 2	PC 橋を計画してみよう
PC 橋編 3	PC 橋を設計してみよう
PC 橋編 4	現場を見てみよう
PC 建築編 1	PC 建築とは
PC 建築編 2	PC 建築にはどんなものがあるか
PC 建築編 3	プレキャスト PC 建築の設計について考えてみよう
PC 建築編 4	PC 建築でオフィスを設計してみよう