

深層学習を用いた鋼構造物の素地調整時の除錆度判定システムの開発

大 屋 誠・河 原 達 哉・小 瀧 初 音

インフラの整備・維持管理を将来にわたって持続的に実施するために建設現場の省力化・省人化を目指し、デジタル技術と AI 等によるオートメーション化が進められている。今後、デジタル技術を活用した少ない人数で、安全で、快適な環境で働く生産性の高い建設現場の実現が重要である。

本稿では、鋼構造物の補修施工時を支援するために著者らが開発を試みた深層学習を用いた腐食した耐候性鋼材（さび度 D）の塗替え塗装の素地調整時の除錆度判断を支援するシステムについて報告する。

キーワード：鋼構造，除錆度，CNN，ViT，XAI，GAN

1. はじめに

我が国の橋梁・トンネル等のインフラ施設は、供用後 50 年を経過した構造物が増加し、労働人口の減少や高齢化により、現状のままでは、国民の生活・経済活動を支えるインフラの整備・維持管理を将来にわたって持続的に実施することが難しくなっている。これらの課題を解決するためにデジタル技術の活用¹⁾が積極的に行われている。建設業の生産性向上に向けた取組みとして、2016 年度より建設現場において ICT 活用等による「i-Construction」が推進され、3 次元設計データの活用、UAV やレーザースキャナを用いた 3 次元測量や自動制御された ICT 建設機械等での施工による効率化が進められてきた。今後、更なる労働人口の減少に向け、国土交通省は、2024 年 4 月に「i-Construction 2.0」²⁾を策定し、AI、5G、クラウドなどのデジタル技術とオートメーション化により、少ない人数で、安全で、快適な環境で働く生産性の高い建設現場の実現を目指す方針を示した。近年、インフラ施設の 5 年に 1 度の定期点検を持続可能とするため、人材不足の解消や点検費用の削減を目的に、AI 等を用いた点検や維持管理の効率化に関する研究が積極的に行われているが、補修施工時を支援する研究はほとんど実施されていないのが現状である。

深層学習における画像分類問題では、畳み込みニューラルネットワーク（Convolutional Neural Network）（以下、CNN と略称）と Transformer という自然言語処理で利用されているアーキテクチャを用いた Vision Transformer（以下、ViT と略称）がよく知ら

れた手法である。深層学習では、層の数が多ければ一般的に良い判断や予測をするが、なぜその判断や予測をしたかが分かりにくくなるため、インフラ分野に AI を導入し、省人化や省力化を行うには、その判断や予測の根拠を明確にする必要がある。また、インフラ施設の施工や維持管理に AI を適用する場合、データ不足に陥りがちで生成 AI による課題解決が検討されている。

著者らは、深層学習を用いた腐食した耐候性鋼材（さび度 D）の塗替え塗装の素地調整時の除錆度判断を支援するためのシステム開発^{3)~6)}を行ってきた。本稿では、素地調整時の除錆度判定システムとして、(1) CNN と ViT の 2 つの手法によるシステム構築の可能性について検討を行った結果^{3), 4)}を報告する。(2) 開発した除錆度判断支援システムの学習モデルの判断根拠を視覚的に説明可能か検討^{4), 5)}し、(3) 構築した除錆度判定システムの汎化性能の向上を目的として、4 段階の除錆度に対する教師画像を生成 AI の一つである敵対的生成ネットワーク（Generative Adversarial Networks：GAN）により生成可能か検討した結果⁶⁾を報告する。最後に、開発した除錆度判定支援システムを現場で利用可能とするために、Raspberry Pi を用いたエッジ AI により、実装の可能性を検討した結果を報告する。

2. 深層学習による除錆度判定システムの開発

素地調整時の除錆度判定システムとして、除錆度を判定するための画像分類問題に CNN と ViT が利用可

能か検討した結果^{3), 4)}を報告する。本システムは、あらかじめ除錆度がグレーディングされた画像を教師データとして学習させ、未知の画像を除錆度の4つのクラス Sa1, Sa2, Sa2 1/2, Sa3 に適切に分類するシステムである。システムの概要を図-1 に示す。

(1) CNN による除錆度判定学習モデル³⁾

CNN は何段もの深い層を持つニューラルネットワークで、中間層として、畳み込み層とプーリング層の2種類の層を持つことに特徴がある。CNN の一般的な構成を図-2 に示す。入力層で入力された画像に対し、局所的な特徴を抽出する畳み込み層と情報を圧縮するプーリング層を組み合わせることでデータの複雑な特徴を抽出し、それを基に、全結合層で重み付きの結合計算がなされ、出力層において分類結果を出力する。最後の出力層では、ユニット数を分類クラスと同数となるようにし、ソフトマックス関数により尤度を求め、尤度が最大となるクラスを予測クラスとして出力する。本稿では、学習済みモデルとして、画像認識で高い性能を発揮することが知られている Resnet50 を使用し、除錆度がグレーディングされた教師データ




図-1 除錆度判定システムの概要

を用いて追加学習により除錆度判定学習モデルを構築した。

(2) ViT による除錆度判定学習モデル⁴⁾

ViT は、画像認識タスクに Transformer を利用したモデルである。画像を画像パッチ（patch）が連なったシーケンスデータとして単語（トークン）として扱うことで画像処理に Transformer を適用する。ViT は、CNN における畳み込み層の代わりに、Self-Attention が用いられる。ViT の全体図を図-3 に示す。ViT は、大きく [1] Input Layer, [2] Encoder, [3] MLP Head の3つの部分で構成される。Input Layer では、公開されているモデルの中でも、比較的によく知られている ViT-B/16 に基づき 16×16 画素のパッチに分割し、チャンネル（RGB）と合わせ、768 の大きさを持つベクトルに変換した。Encoder は、12 層の Encoder Block から構成し、MLP Head は、Layer Norm および線形層からなるクラス分類を行う分類器である。画像分類タスクでは、MLP Head の出力するベクトルの長さはクラス数（除錆度のグレード：Sa1, Sa2, Sa2 1/2, Sa3）と同数の4として出力した。




図-2 CNN の概要




図-3 ViT の概要

(3) 入力画像と学習

システム開発に用いた腐食した耐候性鋼材(さび度: Grade D) のブラスト処理後の画像データ(元画像)を図-4に示す。これらの画像から切り出した256×256画素の小領域の画像(図-5)を入力データに用いた。CNNでは、分類精度を向上させるために、切り出した画像を回転させ、画像枚数の拡張を試みるが、本稿では、CNNとViTの精度比較を行う目的で、データを軽量化するため、画像枚数の拡張を行わずに検証を行った。表-1に除錆度のグレード毎に元画像とデータの枚数を示す。画像データは、学習モデル構築用データを10分割し、training dataとvalidation dataの割合を8対2としてK-分割交差検証法(K=10)により、Case1～Case10の10通りの学習モデルの構築を行った。また、構築したシステムの評価に際し、本稿では、補修塗装時のブラスト後の除錆度として、Sa2 1/2以上が求められることから、混合行列を表-2のように定め、式(1)から式(4)で定義される定量的な4つの指標により、テスト用データによる構築した学習モデルの精度検証を行った。




図-4 ブラスト後の鋼材表面元画像




図-5 教師データ

$$\text{正解率 (Accuracy)} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (1)$$

$$\text{再現率 (Recall)} = \frac{TP}{(TP + FN)} \quad (2)$$

$$\text{適合率 (Precision)} = \frac{TP}{(TP + FP)} \quad (3)$$

$$F\text{値} = \frac{(2 \times \text{Recall} \times \text{Precision})}{(\text{Recall} + \text{Precision})} \quad (4)$$

ここに、TP: True Positive, TN: True Negative, FP: False Positive, FN: False Negativeである。再現率は、実際に陽性(Sa3およびSa2 1/2とした)であるものが、陽性と予測された程度を評価する指標で、見逃さない確率を表し、1に近いほど性能が高いといえる。適合率は、陽性と予測されたものが実際に陽性であった程度を評価する指標で、誤検出しない確率を表し、1に近いほど性能が高いといえる。一般的に、性能評価の指針となることが多いのは、適合率と再現率の調和平均であるF値である。また、それぞれの手法における学習モデルについて、学習モデルの大きさ(パラメータ数)および計算速度を比較したものが表-3および表-4である。表-3のTotal paramsは、モデル全体のパラメータの総数で、Trainable paramsが訓練対象のパラメータ(学習によって更新されるパラメータ)数、Non-trainable paramsが訓練対象ではないパラメータ(学習によって更新されないパラメータ)数である。パラメータ数が多いほど、複雑なモデルを学習することができ、高度な特徴抽出が

表-1 元画像と切り出した画像枚数

データ グレード	元画像	学習モデル 構築用データ	テスト用 データ
Sa1	1	40	25
Sa2	3	60	25
Sa2 1/2	3	70	25
Sa3	3	270	25
Total	10	440	100

表-2 クラス分類の混合行列

正解 予測	Sa3	Sa2 1/2	Sa2	Sa1
Sa3	TP	FP	FP	FP
Sa2 1/2	FP	TP	FP	FP
Sa2	FN	FN	TN	FN
Sa1	FN	FN	FN	TN

表—3 学習モデルの大きさ (パラメータ数)

分類器 \ 指標	Total params	Trainable params	Non-trainable params
CNN	23,595,908	23,542,788	53,120
ViT	85,856,359	85,854,801	1,558

表—4 計算速度の比較


分類器 \ 指標	1 エポック目 [s]	2 エポック目以降平均 [s]	30 エポック合計 [s]
CNN	169	6	349
ViT	354	23	1024

可能となるが、モデルのサイズが大きくなるため容量が増大し、また、モデルの解釈性が低くなる可能性がある。表—3と表—4より、ViTは、CNNに比べ、学習パラメータ数が4倍程度多く、高度な特徴抽出が可能のため、学習開始から30epochが終了するまでの計算速度が3倍程度遅い結果となった。


(4) システムの評価

K-分割交差検証法の Case1 における学習状況の推

移について、横軸に繰り返し回数 (epochs) とし、図—6にCNNにおける正答率 (accuracy) および損失 (loss)、図—7にViTにおける正答率 (accuracy) および損失 (loss) を示す。なお、CNNとViTは、共に同様のデータセット (256 × 256 画素) とモデル運用条件 (batch size = 8, epoch = 30, 最適化アルゴリズム = SGD) で分類器の構築を行った。図—6より、CNNは、training dataによる正答率は15回程度で100%近くに収束しており、損失も10回程度でほぼ0に収束している。また、validation dataも30回程度で正答率が95%以上に収束し、損失はほぼ0近くに収束している。一方、図—7より、ViTは、少ないepoch時から比較的正答率が高く、損失が小さい。正答率は、15epoch程度で90%近くに収束しており、損失関数もほぼ0に収束している。また、表—5に、構築したCase1～Case10の分類器にテスト用データを適用した際のクラス分類結果の平均値を示す。判定精度については、ViTはすべての指標でCNNを上回り、80%以上の分類精度を示した。




(a) accuracy




(b) loss

図—6 CNNの学習結果と認識結果の推移



(a) accuracy



(b) loss

図—7 ViTの学習結果と認識結果の推移

表一 5 判定制度の比較

指標 分類器	正解率	再現率	適合率	F 値
CNN	0.8140	0.8657	0.8233	0.8424
ViT	0.8444	0.9152	0.8433	0.8770

3. XAI による深層学習の判断基準の可視化^{4),5)}

深層学習では、なぜその判断をしたか、また、なぜその予測をしたかが分かりにくく、社会インフラに AI を適用する場合、構築した学習モデルが適切な判断根拠に基づいているか説明することが必要である。近年、機械学習モデルの予測根拠を説明する XAI (eXplainable AI) 技術がいくつか開発されている。本報では、除錆度判定システムを CNN で構築した場合の判断根拠の可視化手法として Grad-CAM を用い、ViT で構築した場合については Attention Map による可視化手法を用いた。CNN および ViT で構築した学習モデルの判断根拠を視覚的に説明可能か検討した。

(1) Grad-CAM による CNN の可視化⁵⁾


Grad-CAM は、CNN の特徴マップの勾配（重み）を用い、画像中の重要領域を強調する粗い局在マップを生成するものである。図一 8 に Grad-CAM の概要を示す。画像とクラスが入力として与えられると、学習モデルの CNN 部分を通して順伝播させ、タスク固有の計算を通して、ソフトマックス関数によるクラスのスコアを得る。この信号は次に、畳み込み層に逆伝播され、特徴マップと組み合わせてヒートマップを計算することで、学習モデルが判定する際にどこを注視しているかを可視化する。

(2) Attention Map による ViT の可視化⁴⁾


ViT は Self-Attention 機構を用いて特徴を捉える手法である。Attention Weight は、ソフトマックス関数により尤度を求め、尤度が最大となるクラスを出力結果として出力するため、1つのクラスにピークを持つことから、Self-Attention において内積計算して得られる Attention Weight により、Attention Map を示すことで判断根拠を可視化できる。

(3) 各学習モデルによる判断基準の可視化


テストデータにおいて、正しく判定された除錆度の各グレードの可視化結果を図一 9 と図一 10 に示す。



図一 8 Grad-CAM の概要



図一 9 CNN における Grad-CAM による判断基準の可視化



図一 10 ViT における Attention Map による判断基準の可視化

図—9は、CNNによるSa1のGrad-CAMの適用結果である。Sa1の判定において、ヒートマップは人が判断する黒ずみや凹凸付近を特徴として捉え、Sa2の判定においては、ヒートマップは人が判断する小さな凹凸を特徴として捉えていることが分かる。したがって、学習モデル構築時に学習情報として凹凸の大きさは与えていないが、構築した学習モデルはSa1とSa2を凹凸の大きさで判断しているものと考えられる。一方で、Sa2 1/2およびSa3の適用結果は、画像端に集中しており、黒ずみや凹凸の特徴が少ないため、ヒートマップが特徴を明確に捉えていない。したがって、同一画像内において勾配の変化が顕著に現れず、画像全体を特徴として捉えていると考えられることから、Sa2 1/2以上の判別基準は色であると考えられる。各グレードで判断基準が存在することから、CNNによる判断は適切に行われていると結論付けた。図—10にViTのAttention Mapを示す。Attention Mapは、グレースケールで示され、Attention Weightが小さい（重要度が低い）領域を黒く塗りつぶす。したがって、Attention Mapが出力された画像の中で認識できる特徴が判断根拠として最も有力であると考えられる。Sa1において、Attention Mapからは、大きな凹凸を認識できる。Sa2においては、Attention Mapから、小さな凹凸が認識できる。このことから、これらの判定においては、CNNと同様に凹凸の大きさを判断基準としていることが考えられる。一方、Sa2 1/2においては、表面に点在する細々とした斑点を認識できる。Sa3においては、さらに小さな斑点を認識でき、また、他のグレードのAttention Mapより黒みが薄くなっている。したがって、Sa2 1/2以上は、表面が滑らかであり、表面に点在する斑点、特徴の少ない場合は色を判断基準としていることが考えられる。

4. 敵対的生成ネットワーク（GAN）による教師画像の生成⁶⁾

近年、インフラ分野にAIを導入する上での課題は、教師データが少ないことである。社会インフラにおいては大量で適切なデータを収集することは難しいことが報告⁶⁾されている。深層学習において、高い精度を達成するには大量のデータを学習する必要があるが、実問題への適用を考えた場合、そのような大量データを準備することが難しく、限られたデータでどう精度を高めるかが課題となっている。例えば、従来の画像データの拡張方法は、画像を傾けたり、色を変えたりして人工的にデータを増やす手法が用いられてい


る。近年、既存画像などのデータを生成する敵対的生成ネットワーク（Generative Adversarial Networks：GAN）は、データ不足に陥りがちな深層学習において、教師データを増やす拡張技術の1つの手法として期待されている。著者らが構築した除錆度判定システムの汎化性能の向上を目的として、構築するシステムの強化につながる4段階の除錆度に対する教師画像が、GANにより生成可能か検討した結果を報告する。

(1) 敵対的生成ネットワーク


GANは、図—11に示すように生成器（Generator）と識別器（Discriminator）という2つのニューラルネットワークから構成される。生成器は、ノイズを入力として擬似データ（生成画像）を生成する。識別器は、あらかじめ用意したデータセット（教師データ）を入力として、生成器から生成された擬似データが本物であるかどうかの確率を出力する。このとき生成器は、識別器が擬似データ（生成画像）を偽物と判別しないように、識別結果から擬似データを生成する際のパラメータを更新し、学習を行う。一方で、識別器は入力される教師データと擬似データを適切に見分けることを目的に順伝播を行ったあと、出力と正解の誤差を逆伝播させることでパラメータを更新し、学習を行う。識別器と生成器が学習を繰り返し、データセットの特徴を含んだ画像が生成される。このように2つのニューラルネットワークが、競い合いながら敵対的に学習を行うことから、敵対的生成ネットワークと呼ばれる。

(2) 生成画像の評価

図—12にSa1の生成画像の学習回数（epoch）と正答率（accuracy）の推移を示す。また、表—6に生成画像各CASEの学習回数と正答率の関係を示す。識別器の生成画像の正答率（accuracy）と学習回



図—11 GANの概要



図—12 Sa1 の生成画像の学習回数と正答率の推移

表—6 生成画像各 CASE の学習回数と正答率の関係

除錆度		CASE1	CASE2	CASE3
Sa1	epoch	15	498	2000
	accuracy	37.50	100.00	98.44
Sa2	epoch	20	496	2000
	accuracy	75.00	100.00	98.44
Sa2 1/2	epoch	20	495	2000
	accuracy	35.94	100.00	100.00
Sa3	epoch	15	600	2000
	accuracy	59.38	100.00	96.88

数 (epoch) は変動しながら推移するため一律でない値をとっており, CASE1 は accuracy が 30 ~ 75% 程度で 20epoch 程度の場合, CASE2 は accuracy が何度も 100% となり学習が収束したと判断した場合, CASE3 は CASE1 よりさらに学習を進め, 過剰に学習を繰り返すことにより, 生成器がデータセットとほぼ同じ特徴の画像ばかり生成するモード崩壊が予測される場合である。データセットと類似した画像は, 除錆度判定システムの汎化性能の向上を目的とした教師画像として不適切であるため, 画像間の類似度が小さく, モード崩壊が発生していない画像を判別する必要があるが, GAN を用いて生成した画像の評価は目視で確認する方法以外に確立されていない。そこで本稿では, 構造的類似性指標 SSIM (Structural SIMilarity) により, 生成画像の教師画像との類似度を評価した。SSIM は, 比較で用いる画像を小領域で切り取り, 輝度, コントラスト, 構造の変化を比較した値で, 以下の式 (5) により算出される。


$$SSIM = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (5)$$

ここに, 2 枚の比較画像をそれぞれ x, y とすると, μ_x, μ_y は小領域内の画素値の平均, σ_x, σ_y は標準偏差, σ_{xy} は共分散である。また, C_1 および C_2 は, 分母の値が小さくなった際に出力値を安定させるための定数で

ある。この計算を小領域に対して全ピクセルで行い, その平均値が 0 に近いほど画像間の類似度が小さいことを示す。例として, Sa1 の SSIM 値を図—13 に示す。図—13 より, Sa1 の CASE3 では, CASE2 と比較すると, epoch 数の増加に伴い, SSIM 値が 0 に近づく。一方で, SSIM 値が 0.5 ~ 0.7 程度を示すデータセットに極端に類似した画像を 72 枚生成した。SSIM 値が 0.5 ~ 0.7 程度を示す結果の一部を図—13 に示す。生成器により生成された画像が, データセットに非常に類似した画像を生成していることが確認できる。この結果より, GAN を用いて画像を生成する場合, epoch 数の増加に伴う過学習によるモード崩壊によりデータセットに類似した画像が生成される可能性があるが, SSIM 値の算出により, 類似した画像を判別することが可能であることが確認された。

(3) 教師画像への適用

図—1 に示す除錆度判定システムの教師画像として, GAN により生成した画像が使用可能か検討するため, 除錆度判定システムの training data に生画像を混入させて構築した分類器によって test data の分類性能を試験した。validation data と test data は, 元画像から切り出した画像を各除錆度で 25 枚とした。分類性能は, 式 (1) から式 (4) で定義される指標で評価した。training data は除錆度毎に 100 枚とし, GAN により生成した画像を混入させた枚数の割合と分類性能指標の評価結果を表—7 に示す。教師画像 100 枚がすべて GAN により生成した画像の場合, 分類精度はやや低下するものの, 生成した画像を



図—13 GAN により生成した Sa1 画像の SSIM 値


表一 教師画像に混入した生成画像の割合と結果

混入割合 [%]	正解率	再現率	適合率	F 値
0	1.00	1.00	1.00	1.00
10	0.95	1.00	0.90	0.95
20	0.97	1.00	0.94	0.95
30	0.89	0.85	0.94	0.97
40	0.97	1.00	0.94	0.90
50	0.97	1.00	0.94	0.97
60	0.97	1.00	0.94	0.97
70	0.97	1.00	0.94	0.97
80	0.97	1.00	0.94	0.97
90	0.98	1.00	0.96	0.98
100	0.85	0.93	0.76	0.84

90%混入した場合であっても、分類性能指標の4つの定量的な指標で90%以上の値を得られていることから、GANにより生成された画像は、教師データとして使用可能であることが示唆された。

5. 実装

構築した除錆度判定システムを現場に適用するため、Raspberry Piを用いたエッジ AIにより、実装の可能性を検討した。学習モデルをデバイスにデプロイするため、学習モデルを軽量化し、モデル形式を.pb形式から.tflite形式に変換した。この際、メタデータを挿入し、ラベルリストを作成した。図一14にRaspberry Piのエッジ AIによる除錆度判定の状況を示す。デバイス上部に付属するカメラによって鋼材表面を撮影すると、撮影された映像から物体認識の要領で、リアルタイムに除錆度が分類される。カメラで撮影された映像は、スクリーンに映し出され、画面左上に赤字で表示されるグレード毎の確率によって、除錆度を判断することが可能となる。



図一 14 Raspberry Piのエッジ AIによる実装例

6. おわりに

本稿では、腐食した耐候性鋼材（さび度 D）の素地調整時の除錆度の程度を分類する除錆度判定システムを CNN および ViT で学習モデルを構築した結果を報告した。本研究で得られた結論をまとめる。

- (1) 限られた画像枚数であっても、高精度に除錆度のグレードを4種類に分類するシステムを CNN と ViT で構築することができた。精度検証における認識結果は、すべての指標で80%以上であることから、十分な精度を有していることが確認できた。
- (2) Grad-CAM と Attention Map により、構築した除錆度判定システムは特徴が多い Sa1 及び Sa2 では、凹凸や黒ずみを判断し、特徴の少ない Sa2 1/2 及び Sa3 は色を判断して分類しており、グレード毎に明確な判定基準のもと、除錆度を分類していることから、除錆度の判定に深層学習が適用可能であることが示唆された。
- (3) GAN を用いて、除錆度判定システムの汎化性能の向上を目的として、教師画像生成を試みた。システムの汎化性能の向上のためには、データセットと類似した画像の生成は不適切であるため、SSIM 値を用いた生成画像と教師画像の類似度の評価からモード崩壊による教師画像の強化に不適切な画像を判別することが可能であることを確認した。また、GANにより生成した画像を用いて教師画像を強化することによって、除錆度判定システムの汎化性能の向上を図ることが可能であることを確認した。
- (4) Raspberry Pi によって、構築したシステムの現場への実装の可能性を示すことができた。

謝 辞

本研究にあたり、腐食した耐候性鋼材のブラスト後の貴重な画像データと除錆度の分類結果を日鉄防食(株)より提供いただいた。

JICMA

《参考文献》

- 1) 国土交通省：国土交通白書 2023, 令和5年6月30日。
- 2) 国土交通省：i-Construction2.0～建設現場のオートメーション化～, 令和6年4月16日。
- 3) 大屋 誠, 諏訪太紀, 河原達哉, 武邊勝道, 広瀬 望：深層学習を用いた鋼構造物の指示調整時の除錆度判定システム, AI・データサイエンス論文集, 2巻, J2号, pp.771-776, 2021。
- 4) 河原達哉, 大屋 誠, 武邊勝道, 広瀬 望：耐候性鋼橋梁の素地調整時の除錆度判定における Vision Transformer の適用に関する検討, AI・データサイエンス論文集, 4巻, 3号, pp.20-25, 2023。

- 5) 河原達哉, 大屋 誠, 武邊勝道, 広瀬 望: 耐候性鋼橋梁の除錆度判定への深層学習の適用に関する検討, AI・データサイエンス論文集, 3巻, J2号, pp.248-254, 2022.
- 6) 小瀧初音, 河原達哉, 大屋 誠, 武邊勝道, 広瀬 望: 敵対的生成ネットワークを用いた耐候性鋼橋梁の素地調整画像生成, AI・データサイエンス論文集, 3巻, J2号, pp.287-291, 2022.
- 7) 土木学会技術推進機構 SIP インフラ連携委員会: インフラ維持管理へのAI技術適用のための調査研究報告書, 2019.

[筆者紹介]

大屋 誠 (おおや まこと)
松江工業高等専門学校
環境・建設工学科
教授



河原 達哉 (こうばら たつや)
長岡技術科学大学
大学院修士課程 工学専攻環境社会基盤工学分野
大学院生



小瀧 初音 (こだき はつね)
アイコンヤマト(株)
システム推進

