

基調講演

橋梁の維持管理における AI 技術の動向と今後の展望

TRENDS AND PROSPECTS FOR AI TECHNOLOGY IN BRIDGE MAINTENANCE

全 邦釘*

Pang-jo CHUN

ABSTRACT In recent years, artificial intelligence technologies, such as deep learning, have been developing rapidly. Artificial intelligence technology is beginning to be used in various fields and its performance is becoming well known. The application of AI technology to civil engineering work including inspection and diagnosis of bridges has been studied, and researches are underway to improve the accuracy and labor saving of such work. This paper gives an overview of conventional supervised machine learning and deep learning, and then describes their applications in the field of civil engineering, focusing on our research results. Finally, the prospects are discussed at the end of this article.

KEYWORDS: 人工知能, 教師あり学習, ディープラーニング

Artificial Intelligence, Supervised machine learning, Deep learning

1. はじめに

近年、ディープラーニングに代表される人工知能（以下、AI）技術が急速に発展しており、様々な分野において活用がなされ、またその性能・威力について知られてきている。橋梁への点検業務や診断業務への AI 技術の活用についても検討が行われており、これら業務の高精度化や省力化などを目指した研究が進められている。

文献 1), 2)において、業務は、定型手仕事業務（あらかじめ定められた基準に対して正確な達成が求められる作業）、定型認識業務（管理、検査などあらかじめ定められたルーティン的な処理による事務的作業）、非定型手仕事業務（状況に応じて個別に柔軟な対応が必要となる作業）、非定型相互業務（交渉、管理、助言などコミュニケーションを通じた価値の創造、提供）、非定型分析業務（研究、調査、設計など抽象的な思考による課題解決）、と分類されている（図-1）。現状の人工知能技術は、蓄積されたデータに基づいて学習することで高性能な内挿を行う技術であり、それによって代替できるのは主に非定型手仕事業務である。現状で、インフラメンテナンスの AI 技術活用は主に非定型手仕事業務への活用が考えられている。なお明確な基準値などがある定型手仕事業務は AI を活用せずとも自動で ICT 技術により解決できる業務が多く、非定型相互業務や非定型分析業務、定型認識業務への活用は難しいために後回しになっている。

AI 技術は大きく分けて教師あり学習、教師なし学習、強化学習に分類される。それぞれメリットやアプリケーションは存在するが、土木分野で現状用いられている AI 技術はこのうち教師あり学習が多い。そこで本稿、本講演では主に教師あり学習について述べることにする。また、ディープラーニングも一般的には教師あり学習に分類される。AI 技術と教師あり学習、教師あり学習の一種であるニ

*Ph. D. 東京大学特任准教授 工学系研究科社会基盤学専攻 (〒113-8656 東京都文京区本郷 7-3-1)

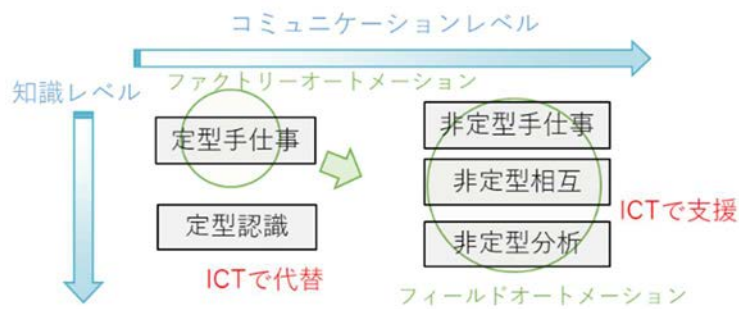


図-1 業務の種類と ICT 化の効果

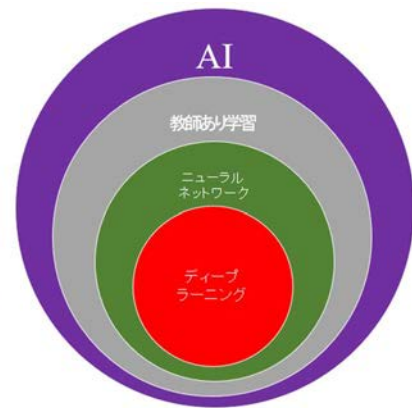


図-2 AI の分類

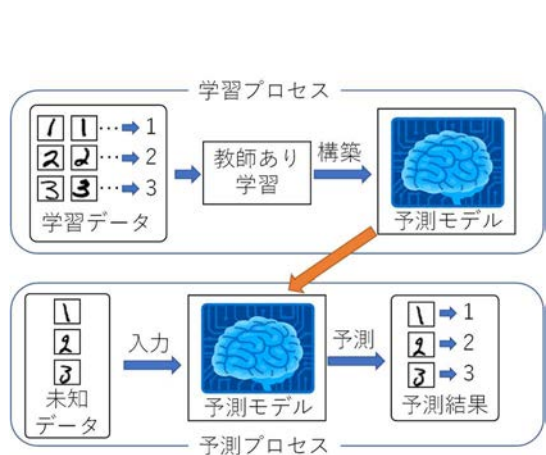


図-3 教師あり学習の概念図

特徴量					種類
萼片長さ	萼片の幅	花弁長さ	花弁の幅		
5.1	3.5	1.4	0.2		Setosa
5.1	3.7	1.5	0.4		Setosa
7.0	3.2	4.7	1.4		versicolor
5.1	2.5	3.0	1.1		versicolor
6.3	2.9	5.6	1.8		Virginica
5.9	3.0	5.1	1.8		virginica
6.4	3.1	5.5	1.8		?

学習データ

学習データから作成されたAIにより分類可能

図-4 あやめの分類

ニューラルネットワーク、ディープラーニングの関係を図-2に示す。図よりわかるように、教師あり学習はAI技術の一種、ニューラルネットワークは教師あり学習の一種、ディープラーニングはニューラルネットワークの一種である。

本稿では従来型の教師あり学習、ディープラーニングについて概要を述べた後に、土木分野での適用例について著者らの研究成果を中心に述べ、また展望について末尾で述べる。

2. 教師あり学習

2.1 教師あり学習の概要

教師あり学習とは、事前に与えられた学習データを教師として、適切な分類・回帰を行うためのアルゴリズムを構築する手法である。模式図を図-3に示す。図-3の上部のように、まず事前に与えられているデータを教師とみなし予測モデルを構築する。そうすれば、図-3の下部のように、未知のデータについても精度良く答えを予測できるという手法である。教師あり学習としてよく知られた手法としては、上述のニューラルネットワークやサポートベクターマシン、Random Forestといった手法が挙げられる。背景に備える理論は異なるものの、利用者側の観点からは共通している事柄も多い。すなわち、分析すべきデータを特徴づける変数である「特徴量」を定義した上で、学習データにより、それぞれの特徴量が出力結果に与える影響度を求めるという大まかな流れは共通している。講演ではあやめの分類の例をまず紹介している。あやめの中に、setosa, versicolor, virginica と呼ばれる種類があり、これらは人間の目にはなかなか区別がつかない。一方で、がく片の長さや幅、花弁の長さや幅といった4つの値を特徴量として、その傾向を各種50サンプルずつのデータで学習すれ

ば、あやめを分類することのできるAIを構築できるというものである(図-4)。このあやめの分類例は非常に有名な例であり、ほぼ100%の精度が得られることが知られている。

あやめに限らず、土木工学分野の問題においても、特徴量を定めることの出来る問題の場合、教師あり学習は簡単な割に高い精度を得やすい。その例として講演では、腐食鋼板の残存耐力評価と、コンクリート表面からのひび割れ検出を紹介する。

2.2 土木工学分野での適用例(鋼板腐食・コンクリートのひび割れ)

腐食は疲労き裂と並んで鋼構造物の主要な劣化要因である。腐食は疲労き裂と比較すると進行性が高くないと判断されることが多く、緊急対応を要すると評価されるケースは少ないが、それでも実際に腐食を原因とした事故も近年起こっている。そこで様々な荷重条件、境界条件下において腐食による表面形状の変化がどのように耐荷力などに影響を与えるか、検討が必要である。講演では、板厚計測結果として、平均板厚、板厚標準偏差、最小平均板厚、最小板厚を得られたケースを想定し、それらに加え材料定数を特徴量として、座屈耐荷力を出力として求めるニューラルネットワークを構築、学習した事例を紹介する⁴⁾(図-5)。また、餘部橋梁などの実橋から取得した合計23体の供試体(図-6に試験の様子を示す)、藤井らにより提案された空間的自己相関モデルに従い生成された仮想的な腐食鋼板供試体の有限要素モデル1000体(図-7に例を示す)をもとに提案手法の妥当性を調べた。試験結果と本手法による予測結果の比較を図-8に示すが、非常に精度良く予測できている。他にも、引張強度⁵⁾などでも研究を進めており、良好な精度が得られている。

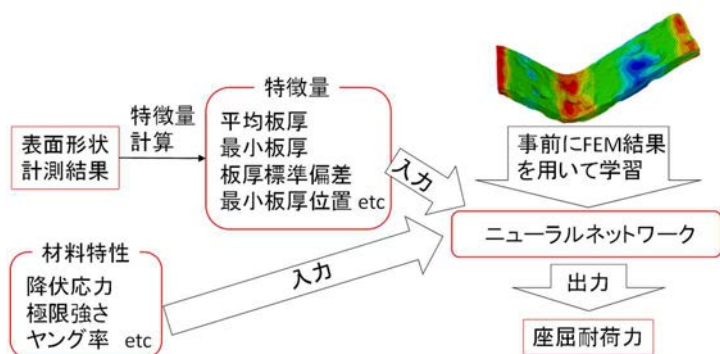


図-5 腐食鋼板の座屈耐荷力評価AIの概念図



図-6 腐食鋼板の座屈試験




図-7 腐食鋼板のFEMモデルの座屈解析例

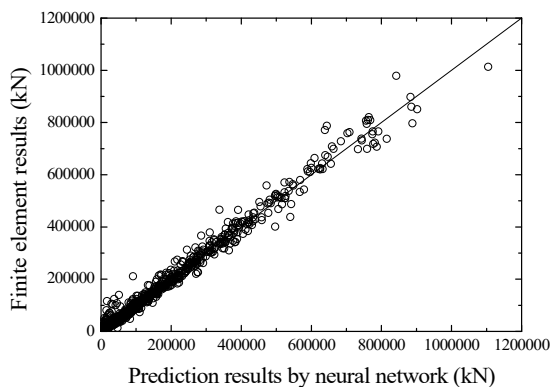
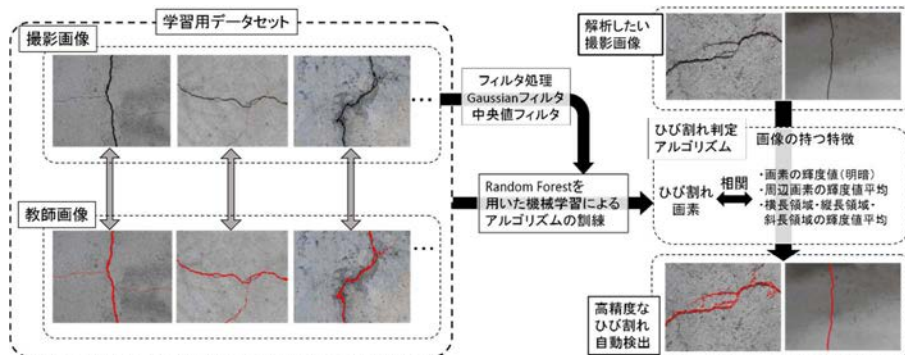


図-8 FEMとAIの耐荷力評価結果の比較



図－9 教師あり学習によるひび割れ検出手法の概念図



図－10 ひび割れ解析結果（赤で塗られている部分がひび割れとして検出された結果）



図－11 SfM との組み合わせによる点検記録の3D化

また、コンクリート表面を撮影した画像からひび割れを自動で検出する手法についても教師あり学習により構築した。ひび割れはコンクリート構造物の点検における重要な項目の1つであり、一般的には目視により調べられている。しかしこのような目視を基本とする点検では、点検員によって判定がばらつくという主観性、非定量性が問題となる。また、トンネルなどコンクリート壁面の面積が大きい構造物の場合には、目視点検では膨大な作業量になってしまうという問題もある。自動検出手法はこれらの問題を解決しうる技術であり、それゆえ国内外で多くの研究がなされている。著者らは教師あり学習をこの問題に適用し、高い精度を得ることができた。ひび割れは、周辺画素と比較してやや暗く、そしてその暗い画素が連続的、かつ線上に繋がっているという特徴を一般的に持つ。そこで、これらの特徴を特徴量とし、入力として与え、着目してる画素がひび割れかどうかを判定し出力するAIを、教師あり学習の一種である Random Forest により構築した(図－9)^{6),7)}。解析結果例を図－10に示すが、良好な精度の結果が得られており、またトンネルやダムにおいて実務での実装段階にある。

また、このひび割れ検出手法は画像処理手法全般と相性がよく、組み合わせて用いることができる。例えば複数枚の画像から3次元形状を復元する手法である Structure from Motion(SfM)と組み合わせた結果を図－11に示す。橋梁を3次元復元し、そこに損傷をプロットすることができており、現状の記録手法と比較してはるかに現場再現度が高い点検記録を残すことができると考えている。

この手法は一般性が高く、特徴量と出力を定めてデータを揃えれば他の問題でも解ける。例えば振動計測結果を特徴量として、構造物の損傷を予測する手法についての研究も著者らは進めている^{8)・10)}。

3. ディープラーニング

3.1 ディープラーニングの概要

前節で、特徴量と出力を定めた上で教師データにより学習する、従来型の教師あり学習について述べた。この手法は理屈としてわかりやすい反面、分析すべきデータを特徴づける変数である特徴量を見つけることは人間にとって必ずしも容易でないことも多く、その場合、高い精度を得られないことが多かった。ディープラーニングは特徴量を自動で、かつ大量に見つけ出すことができるという点に強み・新規性があり、この問題の解決が可能である。図-12に、自転車・三輪車・自動車の分類を例とした概念図を示す¹¹⁾。従来型の教師あり学習では、車輪の数を特徴量として注目するように人間により指定する必要があったが、ディープラーニングは、車輪の数に注目すればよいことをデータから自動的に把握できる。なぜそのようなことが可能となったかといえば、計算機的能力向上とアルゴリズムの発展、データ収集の仕組みが整備されてきたことを基盤として、ある意味力任せで探索することが出来るようになったためである。

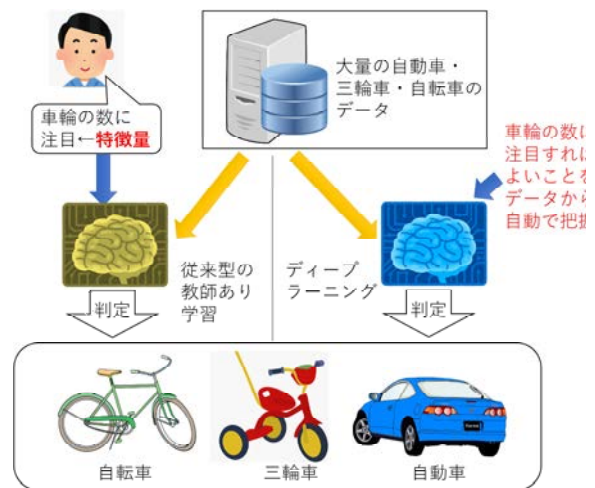


図-12 ディープラーニングと従来型の教師あり学習の違い

ディープラーニングの適用先は画像・動画・音声・波形・文書など多岐に渡るが、その中でも特に画像解析は非常に強力である。既にこなれてきた画像解析タスクとして「分類」、「物体検出」、「セグメンテーション」の3種類がある(図-13)¹²⁾。分類とはある画像が全体として表しているものが、あらかじめ用意したクラスのいずれに相当するかを判断するタスク、物体検出とは画像全体の中から目的の事物の存否や存在範囲を判断するタスク、セグメンテーションとは画像内の個々の画素が属するクラスを画素単位で判別・分類するタスクである。

これら3つのタスクは異なるように見えて、問題設定から解析までの流れは類似している。図-14にフローチャートを示す。まず解きたい問題を設定し、それに従うデータを集め、データに対してアノテーションを行うことで学習データを作成し、ネットワークを学習し、そしてそのネットワークにより新たな画像について解析を行う、という流れは共通している。なお、常に課題となる点も共通しており、それはデータ収集と学習データ作成である。ディープラーニングは特徴量の探索まで行う関係上、データが大量にないと最適なモデルに近づくことすらできない。(しかも、問題によってどの程度の数が必要かというのはオーダーすら変わるため、試行錯誤が必要となる)。また、膨大な数のデータに対して正解をつけて学習データとする必要があるが(アノテーションと呼ばれる)、大変な労力を要する作業である。このようなハードルはあるものの、これを超えれば、様々なことが近年のディープラーニング技術では実現できる。次節でその例を示す。



図-13 画像処理におけるタスクの例

3.2 土木工学分野での適用例（耐候性鋼材・橋梁形式・劣化発見・地すべり検出）

本節では、前節で述べた3つのタスクである分類、物体検出、セグメンテーションについて土木工学分野での適用例を、著者らの研究成果¹²⁾より紹介する。

我が国では耐候性鋼材が鋼橋の材料として1965年頃から試験的に採用され始めた。これは、耐候性鋼材表面に形成される保護性さびにより従来必要であった塗装が不要となりLCCが抑制できるためである。保護性さびの形成は、環境条件、部材条件、材料条件により影響を受けるため橋梁によって形成状況が異なる。また、同一橋梁においても部位によって常に湿潤環境になる場合があるなど、保護性さびの形成状況に差が生じる場合が多い。これら保護性さびの状態は、外観目視により5段階で評価され、把握されている（表-1）。外観評点が3~5であれば腐食摩耗量は片面当たり平均0.5mm以下/100年とされ、耐候性鋼材の適用環境として適当であり、環境の変化が無い限りは腐食速度が急激に増加する可能性は低い。よって、正常か要観察かを判断するために、評点3以上か2以下かを判定することが重要である。

このようなさびの状態の分類を人間が行う場合、主観や経験などの個人差により、差が生じることがある。特に、写真から判断する場合には判断のバラツキが生じる。そこで、熟練技術者が評価した写真データと評点を教師データとして用いて耐候性鋼材のさびの評点を判定するAIの開発を試みることにした¹²⁾。これは、分類タスクに該当する。解析にあたっては、図-14のフローに従い、学習データを収集・整理し、次いで学習データにラベルを紐付け（アノテーション）、そしてネットワークを設計して学習する、ということを行った。構築したAIを用いて判定した結果を表-2に示す。正解率は85%を超えており、良好に解析できている様子がわかる。今後、学習データを増強することで、さらなる精度向上も期待できる。講演では他にも、橋梁形式の分類例や、赤外線調査による損傷分類例を示す予定である。



図-14 ディープラーニングの作業・解析フロー

表-1 耐候性鋼材の外観評点

評点	1	2	3	4	5
写真					
錆の状態	層状剥離	大きさは5~25mm程度 うろこ状	大きさは1~5mm程度	大きさは1mm程度以下 で細かく均一	量が少なく、比較的明るい色調
錆の厚さ	約800μm超	約800μm未満	約400μm未満	約400μm未満	約200μm未満
今後の処置の目安	板厚測定	経過観察	不要	不要	不要

表-2 耐候性鋼材のAIによる分類結果

		技術者による評点				
		1	2	3	4	5
AIによる評点	1	39	6	7	0	0
	2	2	44	20	0	0
	3	0	0	99	2	0
	4	0	0	1	55	0
	5	1	0	0	4	20



図-15 UAVによる橋梁撮影




図-16 損傷検出結果例（赤枠）



図-17 斜面崩壊領域検出結果例

物体検出の事例としては、UAVによる撮影画像からの劣化・損傷発生位置発見手法を示す。UAVを用いれば、高所にある図-15のような橋梁についても点検が可能である^{12),13)}。ただ、UAVから得られた撮影動画・画像から損傷を発見し、評価するのもにも労力を要するため、物体検出手法を用いたものである。物体検出の場合でも、上述の分類の場合と同様に、図-14のフローに従いデータを集めて、アノテーションを行うこととなる。そして、学習アルゴリズムを物体検出に適したもの（ここではYOLOv3というアルゴリズムを用いた）と入れ替える。構築した物体検出AIを用いて解析した結果を図-16に示すが、的確に検出できている様子がわかる。講演では他にも、橋梁の検出例³⁾や、工事現場での物体検出例などを示す予定である。

セグメンテーションの事例としては、航空写真からの斜面崩壊領域の検出事例を示す。日本では、地震や豪雨に伴う斜面崩壊が数多く発生している。これらの被害状況を把握するために、国土地理院により被災地域の航空画像の緊急撮影が行われており、これらの撮影画像は関係する自治体などに共有されるとともに、国土地理院等のホームページで公開されている。これらの航空写真は各自治体等において、被災状況把握や災害査定に利用されるなど、被災地の復旧・復興業務に役立てられている。しかし、被災箇所の地図を作成する際、斜面崩壊領域の判読、抽出は作業者が目視、手作業で行っている。そのため、被害状況の迅速な把握が難しい状況にある。そこで、セグメンテーション技術の一手法であるMask R-CNNを用いて、航空写真の斜面崩壊領域を自動で検出する手法の構築を行った¹⁴⁾。

セグメンテーションの場合でも、分類や物体検出などと同様に、図-14のフローに従いデータを集めて、アノテーションを行うこととなる。そして学習済AIを用いて解析した結果を図-17に示す。的確に斜面崩壊領域が検出できており、今後、斜面崩壊領域の面積を求めて災害査定に用いる、などにも繋がっていくと見込んでいる。

4. 今後の展開とまとめ

ここまで、AI技術の概要と、土木分野での適用例について、著者らの研究成果をもとに紹介した。上記のディープラーニングを含む教師あり学習は、大量のデータを用いた学習により、帰納的にモデルを構築するものである。特に、データが考えられる全ての境界条件のもとで網羅的にあり、かつ入

力の形式と出力の形式が固まっていれば、的確な内挿の実現により高い精度の結果が得られるところに有効性がある。しかし現状では、解くべき問題と活用可能なデータ量（あるいは質も）のバランスが取れていない。上記のような適切な結果が出ている例はまれであり、大抵の問題では、活用可能なデータは、一般的に教師あり学習の入力として求められる量よりはるかに（おそらく数オーダーは）少なく、しかも偏ったものしか得られないことが多い。その原因としては、

- 土木構造物は建設される環境が異なるために一品生産物であり、工場製品と比べて個体差が大きく、網羅性が低くなること
- センサによる計測のコスト（特に設置コスト）が一般的に高価で、かつ計測器具、計測手法、計測位置は技術者の裁量により定められるため、同種のデータが揃わないこと
- 管理者の意向により非公表となるデータが多いこと
- 対策予算の都合など、様々な事情によりデータが操作され得ること
- 実現象を再現するための実験は、必然的に大規模でコストが大きくなりがちなこと

などが挙げられる¹⁵⁾。そのため、教師あり学習の「学習範囲外の状況に弱く、実世界状況への臨機応変な対応ができない」という欠点の影響を避けることが出来ない。そしてデータ数が少ないというのは本質的な課題であり、仕組み・枠組みの変更がどうしても要求される。

例えばデータプラットフォームの敷衍は一案である。現在、土木分野でもデータプラットフォームは各種提案されており、また用いられている。ただしそれらが、仮にデータが単純にアップロードされている（あるいはリンクが貼られている）データポータルのような形では、それはそれで有用なもの、本質的なデータ不足という課題解決にならない。データ構造をユースケースを見据えて設計し、またデータそのものも PDF や紙のような形式だけでなく解析に適用可能な形で蓄積し、そして AI 導入による計測自動化やセンシング技術の新規開発を通して次元の異なるデータ収集を実現することが必要である。しかしこれを土木分野の専門知識が無い情報工学分野の技術者に丸投げしてしまうと、ユースケースのかゆいところに手が届かず、持続可能なものとならない。つまり、土木工学分野の専門知識を持つ技術者こそが、AI、データプラットフォームといった情報工学技術に対して主体的に取り組むことが、持続可能かつ実質化されたシステム構築に繋がると考えている。

参考文献

- 1) Autor, D., Levy, F., and Murnane, R.: The Skill Content of Recent Technological Change: An Empirical Exploration, The Quarterly Journal of Economics, November 2003
- 2) Autor, D. and Dorn, D.: The Growth of Low-Skill Service Jobs and the Polarization of the US Labor Market, American Economic Review, 103(5), pp.1553-1597, 2013
- 3) 杉崎光一, 阿部雅人, 全邦釘, 河村圭: AI によるインフラメンテナンスの生産性向上, 第 44 回土木情報学シンポジウム, 2018
- 4) 全邦釘, 秋山大誠, 真鍋祐輔: ニューラルネットワークを用いた腐食鋼板の座屈耐荷力推定, 土木学会論文集 A2, Vol. 71(2), pp. I_39-I_47, 2015
- 5) Karina, C. N., Chun, P., and Okubo, K.: Tensile strength prediction of corroded steel plates by using machine learning approach. Steel Compos. Struct, 24, pp.635-641, 2017.
- 6) 全邦釘, 井後敦史: Random Forest によるコンクリート表面ひび割れの検出, 土木学会論文集 F3 (土木情報学), Vol. 71(2), pp. I_1-I_8, 2015
- 7) 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
- 8) Chun, P., Yamane, T., Izumi, S., and Kuramoto, N.: Development of a Machine Learning-Based Damage Identification Method Using Multi-Point Simultaneous Acceleration Measurement Results. Sensors, Vol.20(10), 2780, 2020

- 9) Chun, P., Yamashita, H., and Furukawa, S.: Bridge damage severity quantification using multipoint acceleration measurement and artificial neural networks. Shock and Vibration, Vol. 2015, 2015
- 10) Chun, P., Ujike, I., Mishima, K., Kusumoto, M., and Okazaki, S.: Random Forest-based evaluation technique for internal damage in reinforced concrete featuring multiple nondestructive testing results. Construction and Building Materials, Vol. 253, 119238, 2020
- 11) 全邦釘：インフラメンテナンスにおける AI の活用例と、今後の態勢構築への提言（特集 ICT 先端技術（AI などの適用事例）），JACIC 情報，Vol. 33(2)，pp. 9-13，2019
- 12) 全邦釘，党紀，佐野泰如，杉崎光一，宮本崇，阿部雅人，清水隆史：AI を活用した鋼構造物の腐食損傷の点検・診断の現状及び展望，防錆管理，Vol. 64(6)，pp. 193-200，2020
- 13) 遠藤広大，党紀，春田大二郎：地震時応急橋梁点検に活用する汎用小型無人機(UAV)の必要性能評価，土木学会論文集 F4S，Vol. 74，No. 2，pp. I_50-I_61，2018
- 14) 叶井和樹，山根達郎，石黒聡士，全邦釘：Semantic Segmentation を用いた斜面崩壊領域の自動検出，AI・データサイエンス論文集（掲載決定）
- 15) 全邦釘：土木工学分野における人工知能技術活用のために解決すべき課題と進めるべき研究開発，AI・データサイエンス論文集（掲載決定）