

AIによる画像解析技術が拓く土木分野の課題解決へのアプローチ

全 邦 釘

近年、ディープラーニングに代表される人工知能技術が急速に発展している。人工知能技術は様々な分野で活用され始めており、その性能も知られつつある。本稿では、ディープラーニングの枠組みにおける画像解析の中心技術である畳み込みニューラルネットワークについて概要を紹介したのち、筆者の研究成果である舗装のひび割れ評価、埋設管探索とそれを活用した埋設管自動回避動作生成、航空写真からの地すべり領域検出といった課題解決事例を通して、実現可能なタスクについての紹介を行う。

キーワード：AI、ディープラーニング、畳み込みニューラルネットワーク、CNN、画像解析

1. はじめに

日本の土木技術の強みは、歴史的に、高度な力学的素養をもとに演繹的なモデル構築を通して錬成された要素技術にある。しかし近年、異常気象やインフラ老朽化の顕在化、環境問題などに代表されるように、土木工学が扱うべき問題が多様化、複雑化しており、従来型の演繹的なアプローチのみでは対応が難しくなってきた。一方で、データ取得のコストは低下し続けており、その現状を踏まえるとデータを活用した帰納的なアプローチの併用は課題解決に寄与すると考えられる。その代表的な手法が人工知能（以下、AI）技術である。AI技術は近年急速に発展してきており、様々な分野において活用がなされはじめている。土木・建設分野でも各種業務へのAI技術の活用について検討が行われており、研究開発が進んでいるもの、あるいは実装まで進んでいるものもある。筆者の専門分野は、橋梁やトンネルなどのインフラ構造物の維持管理であり、同分野内でAIを活用しようとおおよそ2012年頃から先駆的に取り組んできた。その当時と比較して、特に画像解析技術については格段に精度が向上してきた。その基本となったのは、ディープラーニング手法の一つである畳み込みニューラルネットワーク（Convolutional Neural Network, 以下CNN）である。

CNNを含むディープラーニングによる画像解析についての研究は相当程度成熟してきており、的確な問題設定・データセット構築を行えば非常に高い性能を発揮することが知られている。例えばCIFAR-10という60,000枚の画像を10種類に分類しているデータ

セットの解析では、94%程度と言われている人間の精度を複数のモデルは上回っている¹⁾。これらのアルゴリズムはgithub²⁾と呼ばれるソフトウェア開発プラットフォームで入手することが可能であり、そしてこれらを動作させるフレームワークやライブラリも整備されており、情報工学分野での成果を我々他分野の人間が活用することも容易になってきている。また、ディープラーニングによる解析を行う場合にはこれまでは強力な（かつ高価な）GPUサーバを購入する必要があるが、それが一種の障壁となっていたが、現状ではGoogle Colab³⁾のような無料で動かすことの出来るサービスでもかなりのことが出来るようになってきている。さらに、それでは計算能力が不足する場合でもGoogle Colab ProやAmazon Web Services⁴⁾のようなサービスを活用すれば、GPUサーバを購入するよりも安価に計算ができる。そういった背景を踏まえ、本稿では、上記のCNNを中心に、技術の概要を説明した上で、筆者の研究結果の一部を紹介する。CNNで実現可能なタスク自体は明快であるため、本稿に刺激を受けて、手元の課題を解いてみようと思っていたら、そして課題解決になんらかの寄与ができれば幸いである。

2. CNNとは

ディープラーニングを用いて画像データに対する分類などのタスク処理を行う場合は、CNNやその発展的なモデルが上述のように多く用いられる。以下に、CNNの計算過程の概要について述べる。

画像に対するタスク処理を行う際には、画像内のエッジ部分などの特徴を、次式に示すフィルタ処理によって強調・抽出したうえで後続の計算処理に繋げることが有利になるケースが多い⁵⁾。

$$Z(i, j) = \sum_{r,s} I(i+r, j+s) \cdot F(r, s) \quad (1)$$

上式 (1) はグレースケール画像のフィルタ処理の式であり、 $Z(i, j)$ はフィルタリング後の画素値、 $I(i, j)$ は入力画像の画素値、 $F(r, s)$ はフィルタをそれぞれ表している。この式は、図-1のように、小さなサイズのフィルタを、位置をずらしながら入力画像に重ねて積和を取る畳み込み演算を表している。抽出したい特徴や目的に応じてこれまでに様々なフィルタが設計されており、例えば図-1は、二次微分を利用して画像から輪郭を抽出する空間フィルタであるラプラシアンフィルタを表している。また図-2にラプラシアンフィルタを作用させてエッジを検出した結果を示す。

このようなフィルタ処理は効果的であり、数十年前から活用されていたが、どのようなフィルタを利用するか、すなわち画像のどのような特徴を抽出してタスク処理に利用するかは、画像処理の実施者に委ねられていた。そのため従来は、タスク処理において有効と考えられる特徴を、事前知識に基づく考察や試行錯誤によって決定する必要があったが、そのように決定された特徴（すなわちフィルタ処理）が必ずしもタスク

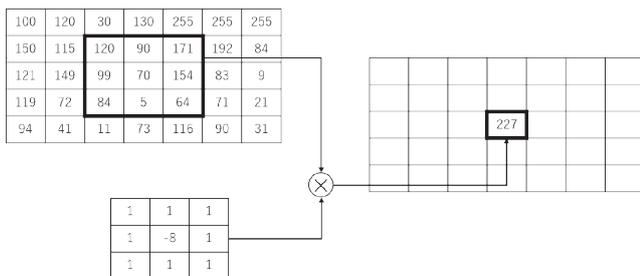


図-1 ラプラシアンフィルタの計算の模式図



図-2 ラプラシアンフィルタ適用によるエッジ検出の例 (左: 検出前, 右: 検出後)

処理上最適であるとは限らないという問題があった。また、複数の特徴を考慮したい場合、複数のフィルタ処理を実行する必要があるが、それぞれの結果にどう重みを設定するかなど、結局人間が決める必要があり、精度・実用性向上のボトルネックとなっていた。

これに対し、CNNは誤差逆伝播法を通じてフィルタの形状を変化させ、与えられたタスク処理に応じたフィルタを自動的に構成することによって、上記の問題を解決したニューラルネットワークモデルである。CNNは、画像に対してフィルタを多数、多重、並列に作用させていく点に特徴がある。また、畳み込み層に加えて出力値のサイズを小さくしながら局所的な特徴を画像全体の特徴へ統合していくプーリング層や、通常のニューラルネットワークと同様の全結合層などを組み合わせてそのネットワーク構造が設計される。その結果として膨大なパラメータ数となり、例えばResNet-152というモデルでは、パラメータ数は6,000万を超える⁶⁾。パラメータ数が少ないモデルでも数百万くらいあることは普通である。このパラメータ群の最適化計算を教師データをもとに行っていくこととなるため、膨大な教師データが必要となり、また強力な計算機能も求められることとなる。

CNNは、タスクに応じた最適なフィルタを上述のように多数構成することで、従来の画像処理プロセスに比較して大きな性能の向上を遂げている。また、上記の計算過程は、画像の持つ重要な特徴を数理的なモデルが自動的に獲得しているとも解釈できることから、CNNは従来の計算モデルとは本質的に異なる意義を有したものとみなされ、その後の様々な画像処理モデルの基礎となっている。

特に基本的な、CNNで実現可能な画像処理タスクとして、「画像分類」、「物体検出」、「セグメンテーション」の3種類がある。画像分類とは、画像に写っている物体のカテゴリを判断して出力するタスク、物体検出とは画像全体の中から検出したい事物の存在範囲を

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カテゴリを画素単位で判別・分類するタスクである。それぞれのタスクの違いを図一3に示す。次章では、これらタスクの事例について、筆者らの研究成果を例に挙げ紹介する。

3. 適用例

(1) アスファルト舗装のひび割れ検出

図一3のうち、まず画像分類タスクについて紹介する。筆者らは文献(7)において、車両に設置したカメラで路面を撮影した画像から、図一4のようにアスファルト舗装のひび割れ評価を行った。ひび割れの検出は、ディープラーニング登場以前はしばしば図一2のようなエッジ検出のラプラシアンフィルタなどが用いられていた。しかし、アスファルト舗装の撮影画像には、影、白線、隣接車のタイヤ、マンホール、排水口など様々な被写体が写っており、これらにもエッジは含まれているため、ひび割れのみを検出するという都合のよい解析は非常に難しかった。これらの存在に惑わされずひび割れのみ検出するには、多くのフィルタを適用して統合的に評価する必要があるため、ディープラーニングを活用した解析が必須であ



(a) 画像分類

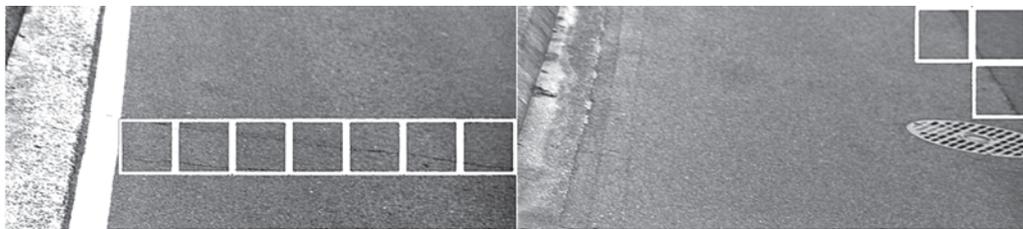


(b) 物体検出

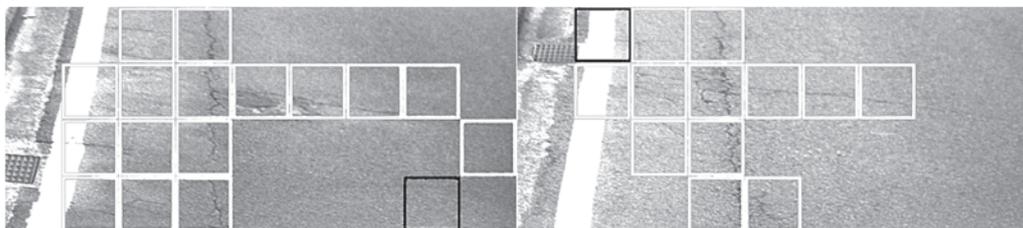


(c) セグメンテーション

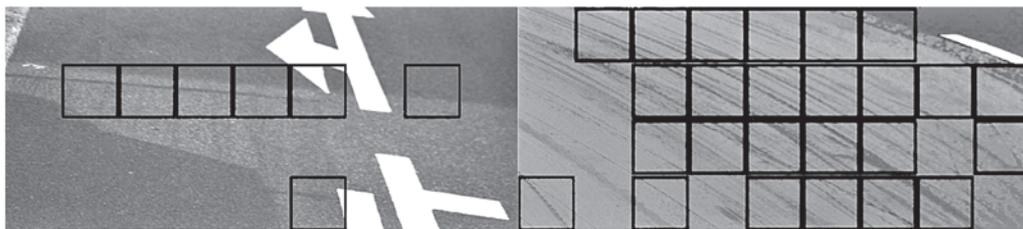
図一3 画像処理におけるタスクの例⁵⁾



(a) 適切に検出できている例



(b) わずかな誤検出を含むが、良好に検出できている例



(c) 適切に検出できていない例

図一4 舗装ひび割れ検出結果例⁷⁾

る。この研究では撮影画像を、 4×9 に分割し、それぞれの分割された画像がひび割れか否かを分類している。図-4において、白色の四角が正解したところ、黒色の四角が不正解だったところである。概ね高い精度が得られたものの、図-4(c)の線状の影のような、学習データにあまり見られず、かつひび割れと誤認しそうなものは誤判定してしまっている。このような誤判定を解消するためには、この画像に類似した学習データを集めることが効果的であり、実際にそのような再学習を行った現在ではこういった誤判定は防ぐことができるようになった。

(2) 地中レーダによる埋設管検出と、掘削時回避動作生成

筆者らは文献(8),(9)などにおいて、地中レーダによる地中構造可視化結果から地下埋設物を高速で検出する手法を構築した。埋設管の長手方向の向きに直角に電磁波の送受信アンテナを移動させながら計測すると、埋設管からの反射波形は双曲線形状を描く。本研究ではその性質を利用して、図-3(b)のような物体検出により双曲線形状を検出するAIを構築し

た。具体的にはYOLOv3¹⁰⁾というモデルを用いている。解析結果を図-5に示すが、適切に検出できている様子がわかる。

また、この解析から得られた埋設管位置情報をデータベースに入力し、そしてそのデータをもとに、自動掘削機能を持つ建設機械が埋設管を回避する動作を生成・実現するシステムを構築した。システムの構成図を図-6に示す。

本研究で構築したシステムは、埋設管の両端の位置と半径、油圧ショベルの位置・姿勢、掘削軌道のパラメータを入力すると、図-7のように埋設管を回避可能な掘削軌道を生成する。なお、地中レーダによる埋設管探査は、その性質上深さ方向には誤差を持つため、適切なマージンを設定する必要があり、図中の灰

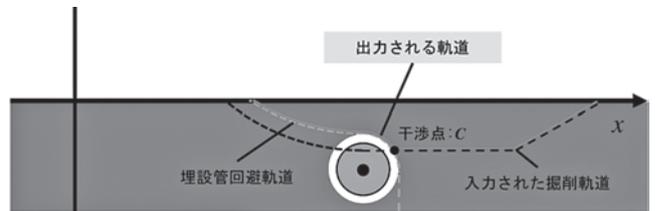


図-7 埋設管を回避する掘削軌道

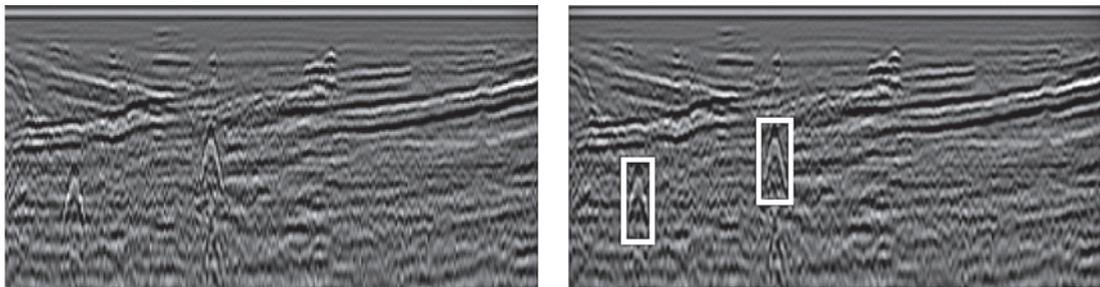


図-5 埋設管からの反射波検出例(左図:解析前,右図:解析後)⁵⁾

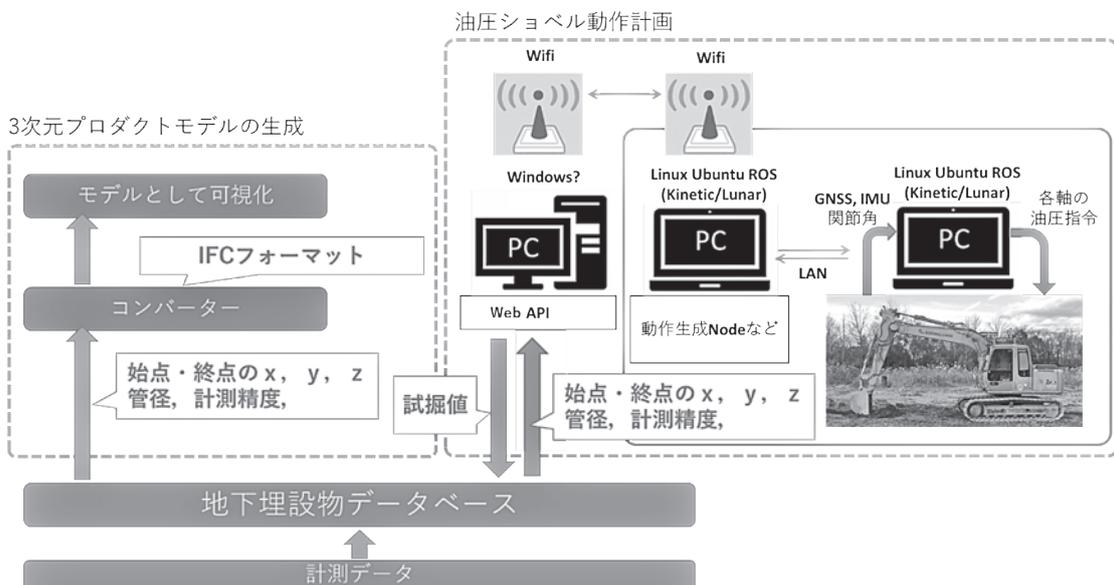


図-6 計測データからの埋設管回避動作生成などを行うシステムの全体像

色の円形で示された埋設管の周辺の白色部分はそのマージンを意味している。

本研究ではさらに、開発した埋設管回避掘削システム全体の有用性を検証することを目的として、土木研究所のフィールドに管を埋め、実証実験を行った。掘削時の様子を図-8の左図に、埋設管の掘削領域の三次元点群を図-8の右図に示す。事前に設定していたマージンは0.225 mであった一方で、図-8左図の回避距離は0.212 mと、非常に精度よく回避できていた。

このように、AIによる検出結果を利用して情報を抽出して、次のプロセスに活かすという方法は、今後まだまだ発展の余地があると考えられる。

(3) 斜面崩壊領域の検出

本節では、航空写真からの斜面崩壊領域の検出事例について紹介する^{11),12)}。問題としては、図-3(c)に示したようなセグメンテーションタスクに相当する。国土地理院は、災害発生後に斜面崩壊領域を測量用航空機や無人航空機により緊急撮影を行い、災害発生直後のオルソ補正（歪み補正）を行った航空写真を公開している。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、斜面崩壊領域の判読や抽出は、作業者が手作業で行っており、被害状況の迅速な把握のボトルネックとなっている。災害時には、完璧な検出結果が得られなくても、高速に高い精度の結果が自動で得られれば役立つケースは多く、そのような場合AIの活用は有効であることが多い。

本研究ではそういった背景を踏まえ、Mask R-CNN¹³⁾という手法により斜面崩壊領域のセグメンテーションを行った。その結果と正解画像との比較を図-9に示す。白く塗られている部分が検出結果を

意味している。概ね適切に検出できていることがわかる。一番下の写真は適切に検出できていない例であるが、舗装のひび割れ検出の節でも述べたように、AIの場合はこのような学習データが蓄積されれば検出できるようになることが期待される。

4. おわりに

本稿では、CNNの概要の説明をまず行い、そしてCNNの一般的なタスクである画像分類、物体検出、セグメンテーションについて、筆者らの研究成果を例に挙げ紹介した。事例紹介を通して、CNNで実現可能なことが概ね理解していただけたのではないかと期待している。近年は、Vision Transformerと呼ばれる最新画像解析技術が出現していたり、また画像解析以外にも自然言語処理に関しても高性能化してきており、技術の最先端の様相が変化しつつあるが、CNNはいまだに現役であり、かつ少し勉強すれば使える技術でもある。また、近年は計算コストも極めて低下してきているので、興味のある方、データドリブンで解決できそうな課題をお持ちの方は是非試しに使っていただければと考えている。

なお、筆者らは令和2年よりAI・データサイエンスシンポジウムというシンポジウムを開催している。これまで2回開催しており、第1回は500名以上、第2回は800名以上の方に参加していただいている。第3回は今年の11月16日、17日に開催予定であり、様々な事例紹介がなされると思われるので、興味のある方は参加をご検討されたい (<https://committees.jsce.or.jp/struct1002/node/16>)。また、これら論文内容の情報共有、および国際的な発信を考え、オープンアクセスの論文集を発刊し（和文誌名「AI・データサイエンス論文集」、英文誌名「Intelligence, Informatics and Infrastructure」）J-STAGEへ登録している (<https://>

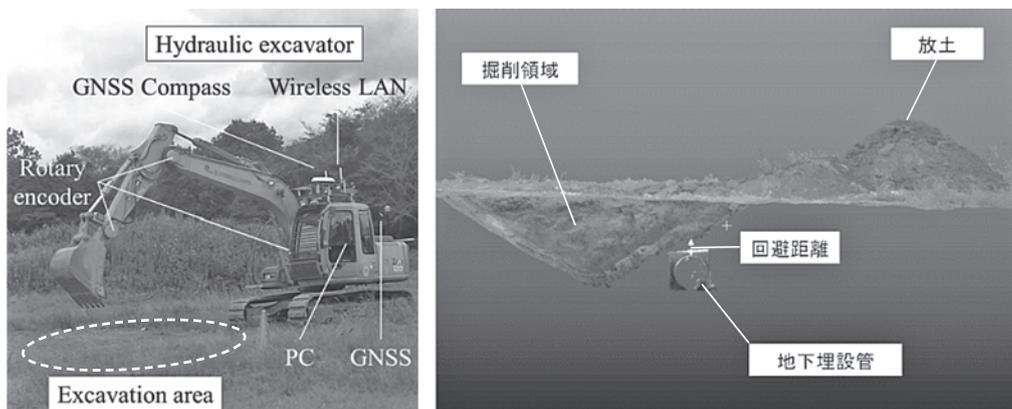
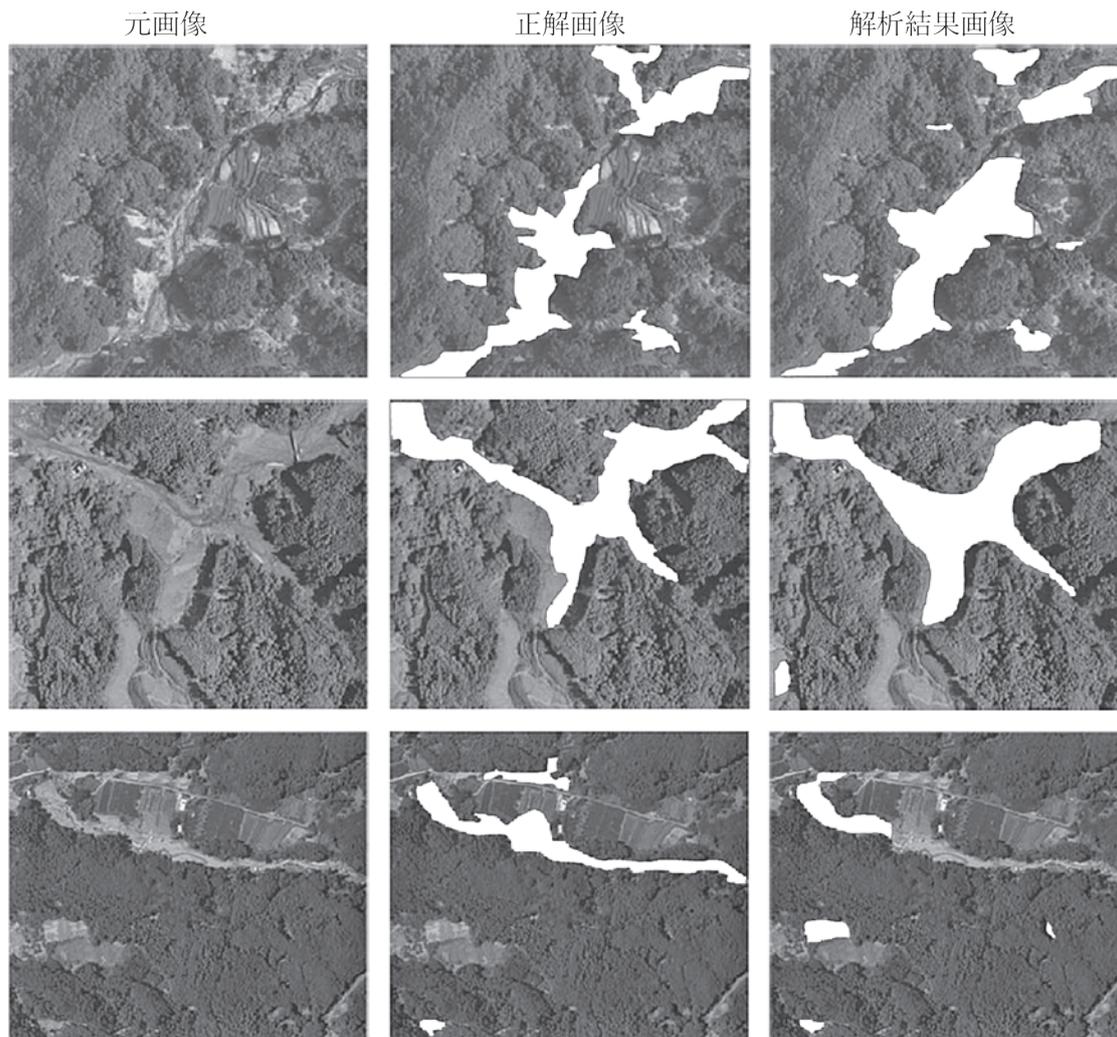


図-8 土木研究所における実証実験とその結果



図一 9 斜面崩壊領域の検出結果例^{11), 12)}

committees.jsce.or.jp/struct1002/node/16)。これまでに合計約 200 編の論文を掲載しており、多様なアプリケーション・課題を、様々な AI 手法やデータサイエンス手法により解決している事例が多く報告されているため、情報共有にご活用していただくとともに、AI 技術などを活用した課題解決事例をお持ちの読者の方は是非ご投稿いただければ幸いです。



《参考文献》

- 1) <https://www.kaggle.com/c/cifar-10/leaderboard> (閲覧日:2022/4/26)
- 2) <https://github.co.jp/> (閲覧日:2022/4/26)
- 3) <https://colab.research.google.com/?hl=ja> (閲覧日:2022/4/26)
- 4) <https://aws.amazon.com/jp> (閲覧日:2022/4/26)
- 5) 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, No. 6, pp.193-200, 2020.
- 6) He, K., et al. "Deep residual learning for image recognition." *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
- 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, Vol. 73, No. 3, pp.I_97-I_105, 2017.
- 8) 鈴木慎人・加藤祐悟・全邦釘: ディープラーニングを用いた地中レーダ探査による埋設管の位置推定, 土木学会論文集 F3, Vol. 77, No. 1, pp.39-48, 2021.
- 9) Yajima, R., et al. "Development of an excavator-avoidance system for buried pipes." *Advanced Robotics* 35, 23 (2021): 1468-1483.
- 10) Redmon, J. and Ali, F. "Yolov3: An incremental improvement." *arXiv preprint arXiv: 1804.02767* (2018).
- 11) 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, 1 (J1), pp.421-428, 2020.
- 12) 叶井和樹・久保栞・山根達郎・全邦釘: Mask R-CNN による航空写真からの土砂崩壊地自動検出手法, AI・データサイエンス論文集, Vol. 2, No. J2, pp.223-231, 2021.
- 13) He, K. et al. "Mask R-CNN" *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017.

【筆者紹介】

全 邦 釘 (ちよん ばんじょ)
 東京大学大学院
 工学系研究科 社会基盤学専攻
 特任准教授

