

## (47) 道路管理者向け道路損傷検出システムの構築

前田 紘弥<sup>1</sup>・檜山 武浩<sup>1</sup>・関本 義秀<sup>2</sup>・瀬戸 寿一<sup>3</sup>・小俣 博司<sup>1</sup>

<sup>1</sup>非会員 東京大学 生産技術研究所 (〒153-8505 東京都目黒区駒場4-6-1 生産技術研究所)  
E-mail:maedahi@iis.u-tokyo.ac.jp

<sup>2</sup>正会員 東京大学 生産技術研究所 (〒153-8505 東京都目黒区駒場4-6-1 生産技術研究所)

<sup>3</sup>非会員 東京大学 東京大学空間情報科学研究センター (〒277-8568 千葉県柏市柏の葉5-1-5)

多くの自治体では、道路管理者が管轄地域内の道路を車で巡回し、車上から道路路面の目視点検を実施しているが、それぞれの自治体が管理する道路延長が長く、点検業務が負担となっている。一方で、機械学習手法が洗練され、スマートフォンが高性能化しているため、スマートフォンのみでも高精度な画像認識が可能となっている。そこで、本研究では、自治体の点検業務を効率化するために、スマートフォンのみで道路点検を実施できる仕組みを構築し、国内10以上の自治体で1年間実運用を行なった。結果として、100万枚を超える道路損傷画像を蓄積し、F値5%の検出精度向上を達成した。

**Key Words:** Deep Learning, Image Processing, Infrastructure Inspection

### 1. はじめに

多くの自治体では、道路管理者が管轄地域内の道路を車で巡回し、車上から道路路面の目視点検を実施しているが、日本の道路の実延長は、一般国道 55,637km、都道府県道 129,666km、市町村道 1,029,787km と長く、全ての道路をそれぞれの道路管理者が目視点検を行うことは難しい。特に、財政や専門家が不足している市区町村では、日常的な道路の目視点検を実施することが困難であり、十分なデータ・工学的知識・技術力を有していない地方自治体が多い。一方、ここ数年でスマートフォンなどモバイルデバイスの進歩により、AI・IoT の進歩が著しく、様々な分野で実社会への応用が始まっている。深層学習を用いた画像処理手法は非常に高い精度で画像認識が可能であり、さらにスマートフォンに搭載されたセンサーやカメラの性能も格段に向上している。一般的に深層学習で学習させたモデルはサイズ・計算量が大きく、モバイル端末上で動作させることは非常に難しかったが、モバイル端末上でも十分な実行速度を出すことができるようになってきている。

そこで、本研究では、自治体の点検業務を効率化するために、深層学習を活用することで、スマートフォンのみで道路点検を実施できる仕組みを構築し、国内 10 以上の自治体で 1 年間実運用を行なった。結果として、100 万枚を超える道路損傷画像を蓄積し、F 値 5% の検出精度向上を達成した。

### 2. 深層学習を活用した道路損傷検出

本研究では、道路損傷を検出するスマートフォンアプリと、アプリが発見した道路損傷候補を蓄積・可視化するダッシュボードを構築し、いくつかの自治体で実験を行った。本章では、道路損傷データセットの作成、道路損傷検出アルゴリズムの構築とダッシュボードの機能の概略を述べる。道路損傷データセットと道路損傷検出アルゴリズムの詳細については、前田ら<sup>2)</sup>を参照されたい。

#### (1) 道路損傷データセットの作成

国内の7つの自治体(市原市、千葉市、墨田区、長久手市、足立区、室蘭市、長久手市)で収集された道路画像の中から、道路協会「舗装の維持修繕ガイドブック 2013」に沿って道路損傷の矩形情報を付与したデータセット Road Damage Dataset 2018 が一般に公開されている<sup>2)</sup>(図-1)。しかしながら、このデータセットではいくつかの矩形情報が欠損しているデータが含まれていることが指摘されている<sup>3)</sup>。また、ポットホールと特徴が似ているマンホールが、ポットホールとして誤判定されてしまうことが多かった。そこで、Road Damage Dataset 2018 を拡張する形で、矩形情報を再度見直すとともに、さらに道路損傷データ数を増加させ、マンホール画像を別クラスとして新設し、Road Damage Dataset 2019 を作成、一般に公開した。図-2 はマンホールカテゴリのサンプル画像である。Road Damage Dataset 2018 と 2019 のデータ数の違

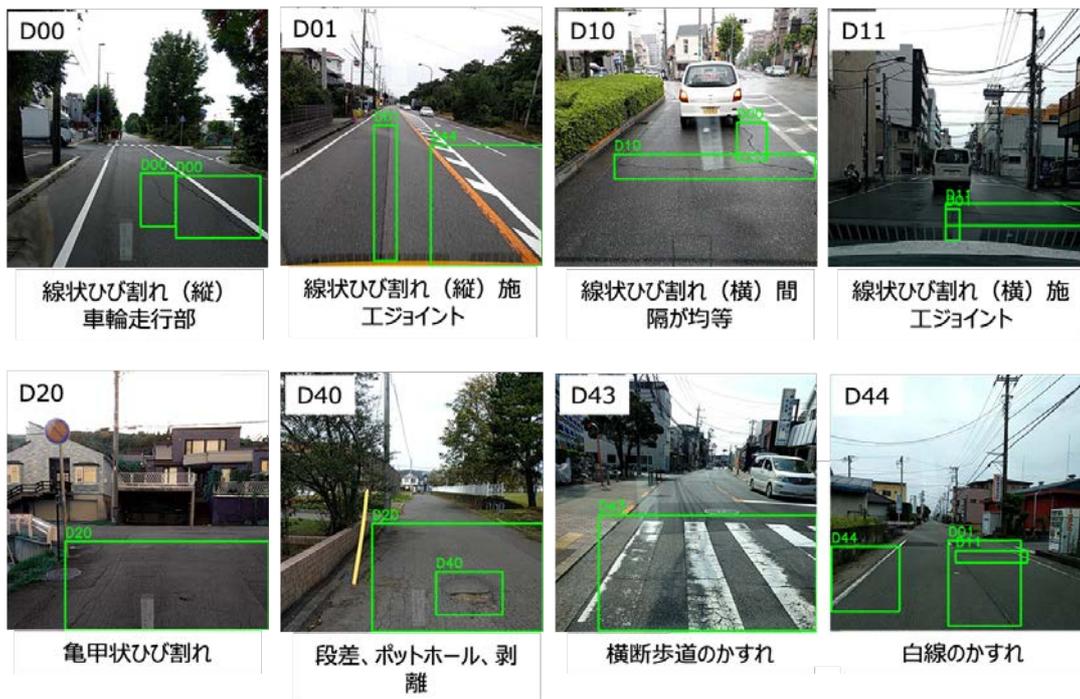


図-1 Road Damage Dataset の損傷種類一覧



図-2 マンホールカテゴリのサンプル画像

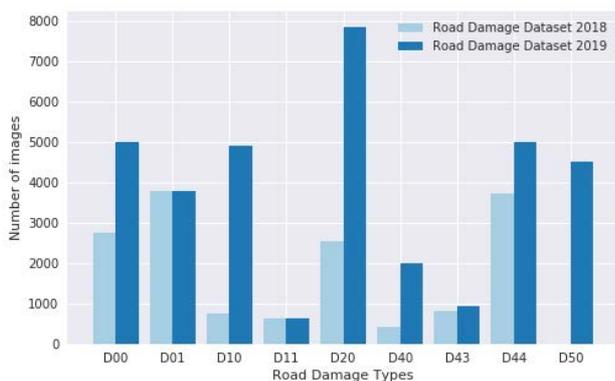


図-3 Road Damage Dataset 2018 と 2019 のデータ数比較

いは、図-3の通りである。2018と2019では、特にポットホール (D40) の画像数が大幅に増加している点特徴的である。また、マンホール (D50) は新設カテゴリであるため、2018年データセットには含まれていない。矩形情報は PASCAL VOC と同様の形式である (<https://github.com/sekilab/RoadDamageDetector>)。

## (2) 道路損傷検出モデルの構築

道路損傷検出モデルを構築するために、SSD MobileNet と SSD Resnet50 を採用した。2章(1)節で説明した道路損傷データセットに含まれる元画像の解像度は 600x600 pixel であるが、スマートフォン上での処理速度向上のため、SSD MobileNet の学習時には 300x300 pixel にリサイズしている。SSD Resnet50 は元画像の解像度のまま学習を行っている。学習データは全体の8割に相当する7,240枚、評価には残り2割の1,813枚を用いる。データ増幅のために、元画像をランダムに左右反転させた画像を学習データに追加し学習を行った。スマートフォン側で学習済みの SSD MobileNet により道路損傷候補画像を検出した場合のみ、損傷候補画像をサーバーに送信する。サーバー側では学習済みの SSD Resnet50 によりより詳細な損傷検出を行う。また、精度向上の取り組みとして、高解像度画像を生成することができる手法である Progressive Growing GAN を活用し、道路損傷画像を擬似的に生成し、新たな教師データとすることで、損傷検出モデルのF値が5%向上した<sup>4)</sup>。さらに、2018年6月10日から2018年11月20日までの約半年間に渡り、IEEE Bigdata 2018 のワークショップの一つとして、Road damage classification and detection challenge が開催された。2章(1)節のデータセットを学習用と評価用に分割し、学習データのみを用いて最もよく道路損傷を検出するモデルを構築するというデータコンテストである。結果評価はF値で行った。世界中の14カ国59チームが参加し、深層学習モデルを中心に、様々なアルゴリズムが提案された。優勝チームは深層学習モデル

を複数組み合わせるアンサンブル学習を行い、F値0.68を記録した中国民生銀行データサイエンスチームとなった。

### (3) スマートフォンアプリの開発

道路路面の損傷をリアルタイムで検出することができるスマートフォンアプリケーションを開発した(図4)。このアプリケーションは車のダッシュボードにスマートフォンを設置して、カメラ機能を用いて道路路面を撮影すると、深層学習で学習させたモデルによって道路路面の損傷を検出することができ、損傷発見時のみ外部サーバーに損傷箇所の画像と位置情報を送信するというものである。現時点では1フレームの道路画像に対して、損傷の有無を判定するのに1秒かかる。時速40kmで車が走行したとすると、1秒あたり約12m進行することになるので、本アプリケーションの処理速度で道路路面ほぼ全てを網羅的に処理することが可能である。このアプリケーションは最新の道路損傷学習済みモデルをダウンロードする機能も備えており、日々最新のモデルを用いてインフラの点検を行うことが可能となっている。また、画像データだけでなく、加速度等のデータも取得している。

### (4) ウェブダッシュボードの開発

スマートフォンアプリが路面損傷があると判定した場合のみ、該当画像と位置情報を外部サーバーに送信する。しかしながらあくまでも深層学習モデルのみによる判定であり、誤判定をしてしまうこともある。そこで、スマ

ートフォンの判定に対して、道路管理者が再判定を行う仕組みを設けている。具体的には、図5のような道路管理者向けのダッシュボードを用いて、各自治体の道路管理の専門職員がスマートフォンの判定の正誤判定をし、誤判定の場合には訂正をする。このようにしてスマートフォンの判定を人間の経験知により補完し、新たな教師データとする。この教師データを用いモデルを再度学習することで、スマートフォンの判定精度を日々向上させることができる。また、ダッシュボード上では、スマートフォンアプリによる道路損傷判定に基づいて道路路線の評価と維持修繕費用予測をリンクごとに確認することができる。



図4 スマートフォンの設置とアプリ操作画面

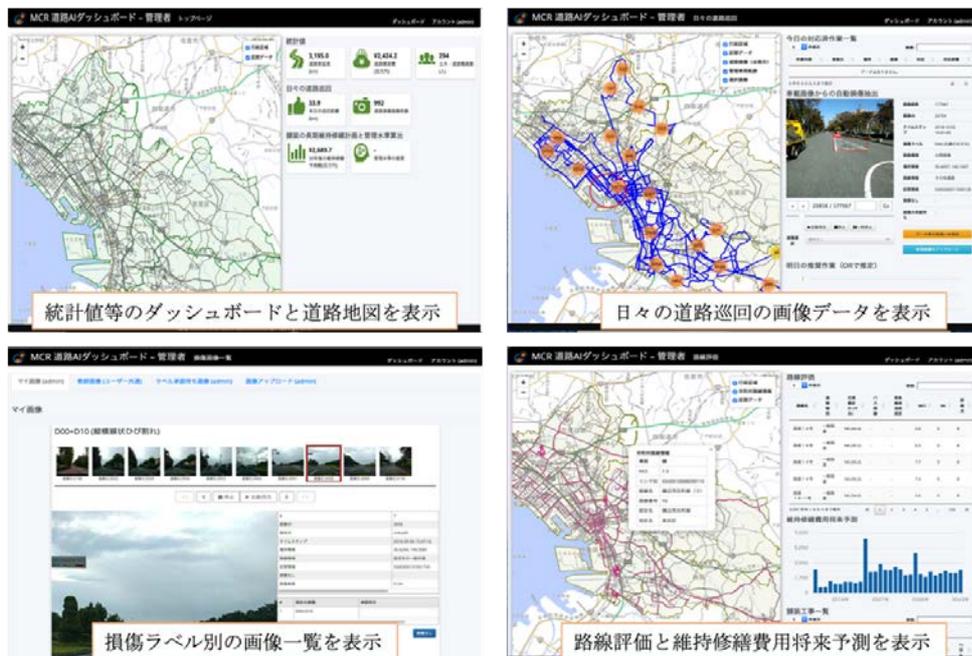


図5 ダッシュボードの操作画面 (左上：トップページ，右上：道路巡回の結果を表示，左下：損傷画像を種類ごとに表示，右下：路線評価と維持管理費用の将来推計を表示)

### 3. 実験状況

My City Report コンソーシアムに参画している千葉市、大津市、東広島市、加賀市、花巻市、実証実験として東京都、品川区、茨城県、常陸大宮市、大子町、裾野市にて、本研究で開発されたアプリケーションを用いた道路損傷画像の収集実験を2019年4月から2020年3月まで1年間にわたり実施した。表-1は収集したデータ数のうち、縦線状ひび割れ（D00）、横線状ひび割れ（D10）、亀甲上ひび割れ（D20）、ポットホール（D40）、すべての損傷種類の合計枚数を示している。複数回同一地点を走行した場合に、道路損傷箇所が重複してカウントされてしまうことや、そもそも誤検出となってしまうこともあるため、実際の道路損傷箇所の数を示しているわけではないことに注意されたい。実際に道路巡回の現場で、本研究で構築したシステムを運用を行うと、いくつか課題も明らかになった。例えば、交通量の多い道路リンクでは、前方車両が道路損傷箇所を覆い隠してしまったり（オクルージョン）、複数回の走行により、同一の損傷箇所を重複して検出してしまったり（ダブルカウント）することなどである。

表-1 代表的な道路損傷カテゴリの画像数

	D00	D10	D20	D40	合計
画像数	408,187	73,472	208,911	26,574	1,324,817

### 4. 今後の展望

本研究で構築した手法を用いると、日本国内の道路の時系列ごとの点検結果を網羅的に、高頻度に取り得をすることができる。一方で、実際の道路巡回の現場で、本研究で構築したシステムの運用を行うことを通じて、前方車両のオクルージョンや複数回同一地点を走行した際のダブルカウントが発生するという課題が明らかになった。今後はこれらの課題に対応するために、同一の損傷箇所を一意に特定することや、複数回の検出結果を用いて、道路損傷箇所の存在・非存在を確率的に取り扱うことを検討している。また、本システムの運用を通じて、得られたデータを用いることで、道路損傷の発生モデルを構築するとともに、道路損傷の進展モデルを構築することを検討している。

#### 参考文献

- 1) 富山和也, 川村彰, 藤田旬, 石田樹 : 地方自治体の舗装維持管理実態を考慮した市街地道路の効果的な路面点検手法の開発, 土木学会論文集F3(土木情報学), 69巻2号 p. I\_54-I\_62, 2013.
- 2) Hiroya Maeda, Yoshihide Sekimoto, Takehiro Kashiya, Toshikazu Seto, Hiroshi Omata, : Road damage detection and classification using deep neural networks with smartphone images, *Computer-Aided Civil and Infrastructure Engineering*, Volume33, p.1127-1141, 2018.
- 3) Kluger, F., Reinders, C., Raetz, K., Schelske, P., Wandt, B., Ackermann, H., & Rosenhahn, B. : Region-based cycle-consistent data augmentation for object detection., *IEEE International Conference on Big Data (Big Data)*, p.5205-5211, 2018.
- 4) Hiroya Maeda, Takehiro Kashiya, Yoshihide Sekimoto, Toshikazu Seto, Hiroshi Omata, : Generative adversarial network for road damage detection, *Computer-Aided Civil and Infrastructure Engineering*, 2020.