

人工知能を活用した道路補修業務の効率化の取組みについて

東京大学生産技術研究所人間・社会系部門 准教授 関本 義秀

課題先進国と言われる日本のインフラ維持管理は、財源・専門家不足が深刻であり問題となっている。一方で、ここ数年の深層学習等の技術発展により高度な画像認識が可能になっており、さらに世界中広く普及しているスマートフォンのカメラ機能は高精細化している。

そこで本研究では、6つの自治体の道路管理者と連携し、深層学習により路面損傷画像のリアルタイム検出を行うとともに、ランダムフォレスト法により自治体ごとの維持管理水準の自動生成を試みた。その結果、一般的なスマートフォンのみを用い、路面損傷を検出率（真陽性率）89%で検出することができ、自治体ごとの維持管理水準の違いを垣間見ることができた。この成果により、安価で簡易なインフラ点検が可能となり、財源・専門家不足に悩む諸地域においてブレークスルーとなる可能性がある。なお、本研究は、国立研究開発法人情報通信研究機構（NICT）の委託研究「ソーシャル・ビッグデータ利活用・基盤技術の研究開発」（課題D：現場の知、市民の知を有機的に組み込んだ次世代型市民協働プラットフォームの開発）（通称：次世代ちばレポ“My City Report”）の一環で行われている。また、本原稿は第37回交通工学研究発表会（2017年8月）での発表原稿を¹⁾もとに加筆修正を行ったものである。

1 はじめに

日本において高度経済成長期に作られた、道路、橋、トンネル等のインフラは50年以上を経て老朽化しており²⁾、今後数十年で点検すべきインフラの数が早いスピードで増加することが想定されている。加えて、これまでインフラの老朽箇所の発見はベテランの現場技術者による検査等に頼ってきたために、増加が見込まれる点検需要に対応するための現場技術者（専門家）や財源が不足している。実際に、財源不足や専門家不足によって十分な点検ができていない自治体が増えている³⁾。このようなインフラ

維持管理を取り巻く厳しい状況を鑑みると、インフラ維持管理の効率化・高度化が早急に求められていることは言うまでもない。具体的には、より安価なインフラ点検手法を開発し、かつ専門家の経験知をなんらかの手法を用いて形式知へと移行させ、専門家不足に対処できるような仕組みが求められている。日本は課題先進国と言われており、現在日本が抱えているインフラ維持管理における問題は、今後世界中の国々が経験する可能性が極めて高い。そこで、この難局をいかにして乗り切るかを世界に示すことは、課題先進国としての腕の見せ所であろう。また、

各自治体の財政や人材は有限であり、維持管理水準は自治体ごとに異なる。各自治体の規模や財政状況に応じた維持管理水準を客観的に市民に示すことにより、市民と行政の相互理解を進めたいというニーズもある。

一方、ここ数年で深層学習の発展や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の画像認識が可能であり^{4) 5) 6)}、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、ここ最近では徐々に実例が増えてきた⁷⁾。例えば、深層学習を用いスマートフォン上で画像を解析し、写真中の人物を自動的にタグ付けするような技術が開発されている⁸⁾。

このような状況から、日進月歩で高性能化するモバイル端末と深層学習による画像処理を用いて、財源・専門家不足などインフラ維持管理を取り巻く厳しい状況を打破することに期待感

がある。実際スマートフォンを用いたインフラ点検の取組みとしてはバンプレコーダー株式会社による路面性状計測などがある⁹⁾。また、ダッシュボードに設置したスマートフォンが、急ブレーキや衝撃を検知した時のみ自動的に前後の動画を録画するドライブレコーダー機能を備えている例もある。しかしながら、道路路面の損傷画像を、スマートフォンを用いてリアルタイムに収集している例はない。また、自治体ごとの維持管理水準の違いを、実データを用いて定量化した例もない。そこで本研究では、6つの自治体の道路管理者と連携し教師画像を生成し、深層学習によりスマートフォン上で路面損傷画像のリアルタイム検出を行うとともに、ランダムフォレスト法を用いることで自治体ごとの維持管理水準の自動生成を試みた。

2 本研究の全体像と手法

(1) 全体像

本研究のフレームワークとしては大きく4つのパートで構成される(図1)。

1) スマートフォンカメラで取得した動画をスマートフォン上で処理しインフラの異常を

図1 本研究のスマートフォンを用いた画像の収集からモデル更新のフレームワーク



出典：筆者作成

検出する。損傷を検出した場合、異常個所の画像と位置情報を外部サーバーに転送する。

- 2) 検出されたインフラの異常を含む画像を外部サーバーに蓄積する。この際、画像に含まれる位置情報から道路統計情報を抽出・付与する。
- 3) スマートフォンが提示した異常個所を行政の道路管理者が確認。スマートフォンによる判定が間違えている場合は訂正するとともに、異常個所の画像と道路統計情報とを合わせて、「修繕する」「経過観察する」「修繕しない」という三つの選択肢から対応を決定する。
- 4) 道路管理者によって確認・訂正された異常個所の画像をさらに教師データとしてモデルを学習させ精度向上を図る。

上記4つのパートを日々繰り返すことで、道路管理者の知と、深層学習の技術を効果的に組み合わせることができる。ここで蓄積されるデータを用いて、自治体ごとの維持管理水準の生成を行う。

(2) スマートフォンを用いた道路路面の損傷検出

近年では道路路面の点検をより効率的に行うために、画像処理技術を用いて、車載カメラから路面性状を把握しようという試みも数多く存在する¹⁰⁾。しかしながら、このような研究では比較的性能の高い専用カメラで取得した動画を外部サーバーで処理をすることがほとんどである¹¹⁾。このような手法では、専用カメラにもコストがかかり、専用カメラの画像を外部サーバーに移すことにもコストがかかる。一方で本研究では、安価で簡易なインフラ点検手法の確立をめざしているため、世界中広く普及しているスマートフォンのみを用いて、スマートフォン上で損傷検出の処理をしていることが重要である。スマートフォン上で損傷検出の処理を済ませることができれば、インターネット回線への

負荷を低減することができる。

ア 物体検出手法

物体検出手法としては、画像分類器を物体検出タスクに応用するものが従来は主流であった。このような手法ではテスト画像内部で大きさや位置を様々に変えて、分類器で物体を判定していく。有名なものとしては、sliding windowアプローチがある¹²⁾。また、ここ数年では、R-CNNに代表されるような物体領域提案(region proposal)を用いて、物体の候補領域を複数抽出し、その後候補領域について分類器で判定をするようなアプローチ¹³⁾も出てきている。

しかしながら上述のような手法では、推論の際の処理速度が遅いことに加えて、物体の背景を考慮した学習ができないことが課題であった。例えば、道路路面の損傷は道路路面上にしか存在しないにもかかわらず、上述のようなアプローチではそのような背景情報を考慮できない。この2つの課題を乗り越える手法がYOLOである¹⁴⁾。YOLOは単一の畳み込みニューラルネットワークで物体の領域とクラスを予測することができる。YOLOの特徴は、単なる回帰として問題を解いているため処理速度が極めて速いこと、かつ背景情報も考慮した検出ができることである。スマートフォン上で物体検出処理をするためには、軽量で高速な処理と、路面損傷は道路路面上にのみ存在するという背景情報を考慮することが求められるので、本研究ではYOLOを用いて道路路面の損傷検出を試みた。また、本研究では各層フィルタ数のみを変更した9層の畳み込みニューラルネットワークを3つ設計し、処理速度と判定精度の観点から性能を評価した。

イ 実際の使用方法

車載スマートフォンは図2のように車のダッ

図2 スマートフォンの設置例



出典：筆者作成

シュボードに設置することが想定されている。フロントウィンドウに設置することも可能であるが、日本では「道路運送車両の保安基準」によりフロントウィンドウに物体を設置することが基本的に禁止されているからである。3章以降の複数自治体による実験も図2のようにダッシュボードにスマートフォンを設置して行なっている。このようにスマートフォンを設置すると前方約10m程度の路面がスマートフォンカメラに映る。

また、実験を円滑に行うためにスマートフォンアプリケーションを作成した。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を処理し、損傷の有無を判定するのに1.2秒程度かかる。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すべてを網羅的に処理することが可能である。さらに、本フレームワークでは日々外部サーバーでモデルを再学習し精度を高めていく。そこで、このアプ

図3 スマートフォンの操作画面



「開始」押下で路面損傷検出が開始される。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が送信される。「ダウンロード」押下で最新の学習済みモデルがダウンロードされる。

出典：筆者作成

リケーションは最新の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、GPS機能を用いて、車が停止している場合には処理を停止するなどの工夫も施されている。使用方法は図3のようになっている。自治体職員が簡単に使用できるよう配慮されている。本アプリケーションは深層学習による学習済み道路損傷判定モデルと合わせて今後公開していく予定である。

(3) Webツールを用いた道路管理者によるラベル付け

本フレームワークでは、車載スマートフォンが、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スマートフォン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、本フレームワークでは、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4のようなWebツールを用いて、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。いわゆ

るAIの判定と人間の経験知が融合している点が極めて重要である。この教師データを用いモデルを再度学習していくことで、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。最新の学習済みモデルはスマートフォンアプリケーションの操作でダウンロードが可能である。

また、画像の再判定と合わせて、路面損傷の周辺情報を加味して、「修繕する」「経過観察する」「修繕しない」のどの対応を取るかを、道路管理者がWebツールを用いて決定する。このデータを用いて維持管理水準の生成を試みる。

図4 教師データ作成用のWebツール

図4は、教師データ作成用のWebツールのスクリーンショットを示しています。左側には道路の写真を、右側には地図を表示しています。下部には、交通量、車線数、MCH値、道路種別などの入力欄があり、また「損傷の種類」を選択するためのプルダウンメニューと「損傷程度」を選択するためのラジオボタンがあります。さらに「損傷取扱い」を選択するためのラジオボタンと「選択」ボタンも表示されています。

Copyright © 2017 Sekimoto lab Institute of Industrial Science, University of Tokyo, All rights reserved.

(スマートフォンによって損傷があるとされた画像がWebツールに表示される。合わせて損傷箇所の位置情報から道路統計情報(右)が抽出され表示される。自治体職員はこのWebツールを用いて、「損傷の種類」「損傷の度合い」「損傷に対する今後の対応」を入力する。ここで自治体職員によって入力された損傷データを用い、再度モデルを学習させ、日々精度向上を図る。) 出典：筆者作成

(4) ランダムフォレスト法による維持管理基準の生成

本研究では、ランダムフォレスト法¹⁵⁾を用いて、道路統計情報「損傷種類」「損傷程度」「交通量」「道路種別」「最高速度」「幅員」「車線数」の中で自治体職員の意思決定にとって重要な特徴量を抽出することを試みた。

ランダムフォレスト法は、決定木の各非終端ノードにおいて識別に用いる特徴をあらかじめ決められた数だけランダムに選択することで、相関の低い多様な決定木を生成できるようにした手法である。ランダムフォレスト法では、各

特徴量がノード分割に使われた時の不純度(ジニ係数 $I(t)$) の減少量を見ることで、各特徴量がどれほど識別に重要な特徴となっているかがわかる。 $I(t)$ は次式で表され、

$$\begin{aligned} I(t) &= \sum_{i \neq j} P(C_i|t) P(C_j|t) \\ &= \sum_{i=1}^n P(C_i|t)(1 - P(C_i|t)) \\ &= 1 - \sum_{i=1}^n P(C_i|t)^2 \end{aligned}$$

$P(C_i|t)$ はノード t で i 番目のクラスのデータが選ばれる確率、 $P(C_j|t)$ は $j \neq i$ のクラスに間違われる確率を表している。このジニ係数の減少量

が一番大きな現象を選ぶように学習させていくことになるが、減少量が一番大きい分割を与える特徴量が、重要度が高いということである。

3 複数自治体における実証実験

本章では、前章までに述べたインフラ点検フレームワークを用いて、実際に複数自治体で実証実験を行った結果について述べる。複数自治体とは、東京都足立区、千葉県千葉市、千葉県市原市、横浜市（港南区）、北海道室蘭市、愛知県長久手市の6つである。本研究では上記6つの自治体で実証実験を行い、その評価を東京都目黒区駒場付近の道路で行っている。これは、実証実験を行っている自治体の道路では、同一の損傷箇所の画像データが複数回取得され、教師データと評価データに同一の画像が含まれる可能性があり、適切に評価ができないと考えたからである。東京都目黒区駒場付近での実験においては、教師データは上記7つの自治体で取得したものであり、恣意的ではない適切な評価である。本研究では、本提案フレームワークが実際に日々運用される中で、専門家の経験知をAIが組み込み、スマートフォンアプリケーションの判定精度が向上していくことを実証するために、二段階の実験を行っている。

本章ではまず（1）で、損傷判定モデルを学習させた際の教師データを第一段階実験と第二段階実験について分けて説明し、次に（2）で、本フレームワークで使用しているニューラルネットワークについて、（3）で、実証実験の成果を目黒区駒場付近の道路で評価した結果について、最後に（4）節で、今後研究の可能性が大いにある自治体ごとの管理水準の抽出について述べる。

（1）学習に使用した教師データ

図5は学習に使用した教師データの例を示している。日本道路協会編「舗装の維持修繕ガイ

ドブック2013」¹⁶⁾によれば、路面損傷は表1のようにひび割れ、轍ぼれとその他損傷に大別でき、さらにそれぞれのカテゴリ内で細分化させると全部で14種類のクラスに分かれる。ただし、今回は、教師データ枚数の制約上、14クラスの損傷種類を検出するのではなく、損傷があるかないかの1クラスの検出問題としている。第一段階実験では、千葉市内の道路300kmを走行し、道路管理者によって判定された損傷を含む路面損傷画像514枚と損傷を含まない路面画像1,000枚の総計1,514枚を用いて学習させたモデルを用いた。第二段階実験では、6つの自治体における道路数十～100km程度をそれぞれ走行し、道路管理者によって判定された損傷を含む路面損傷画像1,651枚と損傷を含まない路

図5 道路管理者によって作成された教師データ例



出典：筆者作成

表1 路面損傷の種類と各クラスの画像数

破損の種類			詳細
ひび割れ	線状ひび割れ	縦方向	車輪走行部
			施工ジョイント部
		横方向	施工ジョイント部やBWP等様々
			間隔が均等
	亀甲状ひび割れ	施工ジョイント部	
		車輪走行部	
わだち掘れ			舗装面全域
			部分的
その他破損			わだち掘れ
			段差
			ポットホール
			剥離
			横断歩道のかすれ
			白線のかすれ

出典：筆者作成

面画像29,960枚の総計31,611枚を用いて第一段階実験時のモデルを再学習させたモデルを用いた。

(2) ニューラルネットワークごとの性能比較


YOLOは単一のニューラルネットワークのモデルによって画像内における対象オブジェクトの矩形特定・分類を合わせて行うアルゴリズムである。そこで、ニューラルネットワークの構造を選択する必要がある。本研究では、図6に示すように、モデルの各層フィルタ数を変更した3つのニューラルネットワークを学習させ、比較実験を行なった。図6は各ニューラルネットワークの学習済みモデルのモデルサイズ、mAP (mean Average Precision)、1秒間に何枚の画像を処理できるかということを示している。処理を行うスマートフォンとしてNexus 5Xを使用している。スマートフォンを設置した自動車が40km/h (≒12m/s) で走行すると仮定し、スマートフォンカメラに映り込む道路路面の距離が10m程度であることを考えると、

図6 ニューラルネットワークの構造とモデルサイズ、mAP、FPS

	layer1 3x3x4		layer2 3x3x8		layer3 3x3x16		layer4 3x3x32		layer5 3x3x64		layer6 3x3x128		layer7 3x3x256		layer8 3x3x512		layer9 3x3x1024		モデル サイズ	mAP	FPS
モデルA	C1	P1	C2	P2	C3	P3	C4	P4	C5	P5	C6	P6	C7	P7	C8	P8	C9	P9	3.9 MB	0.13	3.3
モデルB																			15.2 MB	0.72	0.81
モデルC																			60.4 MB	0.78	0.27

出典：筆者作成

図7 閾値ごとの Precision と Recall



出典：筆者作成

1 FPS程度以上で道路路面の損傷を判定することが望ましい。それ以上処理速度が遅くなると、映り込まない道路路面、すなわち点検できない道路路面が発生してしまうからである。もっともFPSが大きいものはモデルAであるが、mAPが極めて低いため、本章における実験ではモデルBを採用している。

図7は各ニューラルネットワークのPrecisionとRecallを閾値ごとに示している。本システムはインフラ維持管理に使用することが想定されているため、損傷箇所の取りこぼしができるべく少なくなるようにするべきであり、すなわちRecallの値が高いことが望ましい。そこで本章の実験では、閾値は0.2としている。


(3) 損傷候補取得実験

図8に目黒区駒場における、第一段階と第二段階実験の判定精度、及び教師データの内訳をまとめた。

第一段階実験では、駒場付近での評価では、58箇所の損傷のうち、13箇所を検出することができ、PrecisionとRecallはそれぞれ0.48と0.22であった。第二段階実験では、第一段階で求めたモデルを用いて、各自治体でそれぞれ道路路面を撮影しながら走行した。その結果、31,611枚の路面画像が収集された。このうち本モデルが提示した道路路面の損傷候補は9,900枚で、提示した損傷画像のうち実際に損傷を含む画像は1,287枚で、PrecisionとRecallはそれぞれ0.13と0.35となった。本実験で収集された画像について、各自治体の道路管理者によって再度ラベル付けがなされ、最終的に1,651枚の路面損傷画像を得た。

第二段階実験では、第一段階実験で新たに得られた1,651枚の路面損傷画像を含む31,611枚を第一段階実験の教師データ1,514枚に追加して、モデルを再度学習させた。その結果、駒場付近での評価では、55箇所の損傷のうち、49箇所を

図 8 第一段階実験、第二段階実験の結果比較。目黒区駒場付近の道路による評価（上段）



出典：筆者作成

検出することができ、PrecisionとRecallはそれぞれ0.85と0.89となった。

なお、第一段階実験と第二段階実験時の駒場付近での評価において、路面損傷画像の総数が異なるのは、走行速度や前方車両の有無によって、カメラに映る路面画像の数が異なるからである。本フレームワークの運用を続けることで、路面損傷の検出精度が向上していくことが実証されたという点で、本実験の成果は非常に意義がある。

(4) 自治体ごとの維持管理水準の作成

損傷が発見されたインフラへの対応手順は図9のとおりである。「損傷種類」「損傷程度」など画像や現場調査で明らかになる特徴と、「交通量」「道路種別」など周辺環境（道路統計情報）を合わせて「修繕する」「経過観察」「修繕しない」という決定がなされている。本研究では、同一の深層学習モデルによりスマートフォンを用いて複数の自治体で損傷検出実験を行い、Webツールを用いて、画像から判断される「損傷種類」「損傷程度」と道路統計情報として付加された「交通量」「道路種別」「最高速度」

「幅員」「車線数」を踏まえて、「修繕する」「経過観察」「修繕しない」を自治体の道路管理者に決定していただいた。そして、各自治体から収集した1,651枚の損傷画像について、自治体ごとに意思決定に大きく寄与している特徴量を抽出し、自治体ごとの維持管理水準の抽出を試みた。


図 9 損傷が発見されたインフラへの対応決定手順



出典：筆者作成


ランダムフォレスト法を用いて、ジニ係数の減少量から重要と考えられる特徴量を抽出したのが、図10と図11である。多くの自治体で修繕に関する意思決定に重要な特徴量は「損傷の種類」であり、そのほかの要素については自治体によって基準が異なることがわかる。まだ今回の維持管理基準の抽出は試行レベルであり、より洗練させていく必要があるものの、今後自治体ごとのインフラ維持管理基準を抽出し、全国

図 10 維持修繕の対応決定に重要な特徴量（ひび割れ）



市原市は「幅員」、長久手市は「交通量」、他の自治体では「損傷種類」が最重要な特徴となっている。
出典：筆者作成

図 11 維持修繕の対応決定に重要な特徴量（ひび割れ以外の損傷）



すべての自治体において、「損傷種類」が最重要となっている。これは、ひび割れ以外の損傷にはポットホールなど即時修繕が必要な損傷や、横断歩道のかすれなど即時修繕は不要だが経過観察が必要なものなど、損傷種類が明確であるためだと思われる。
出典：筆者作成

で統一的な基準を設けることは非常に社会的意義があると考えている。

4 おわりに

(1) 本研究の成果

本研究では、深層学習を用いた道路路面損傷検出モデルをスマートフォン上で動作させ、その結果を自治体の道路管理者が確認・訂正するという、専門家の知を組み込んだ新しい簡易なインフラ点検フレームワークの提案を行った。提案したフレームワークでは、従来非常に高価だったインフラ点検が、非常に安価かつ容易に

行える可能性を示しただけでなく、いわゆる人工知能と専門家がどのようにお互いに協力しあっていくかというモデルケースを示すことができた。また、実際に6つの自治体で実証実験を行い、本フレームワークが専門家の知識を日々学習し、日々判定精度が向上していくシステムであることを実証したことも本研究の重要な成果である。日本ではインフラ維持管理における財源不足や専門家不足が深刻化しつつある。本フレームワークは専門家でなくとも簡単に運用することができ、必要なものはスマートフォンのみであるので、日本のインフラ維持管理を

取り巻く厳しい状況を打破できると考えている。また、自治体ごとの維持管理水準の違いを、実データを用いて定量化したことも本研究の大きな成果である。

(2) 今後の展望

ア 点検対象の拡大と判定精度の向上

本研究では道路路面の損傷の有無のみに着目しているが、本来であれば、路面損傷の種類まで判定できることが望ましい。加えて実際のインフラ点検は例えば、トンネル、橋梁、など非常に対象が幅広い。本研究の成果は、そのような多種多様なインフラに対しても非常に有効である。今後は点検可能なインフラの対象を増やしていくとともに、本システムを運用していく中でさらに判定精度を高めていくことが必要である。また、専門家がいらない自治体では、他自治体の専門家によって判定された画像で学習した損傷判定モデルを使うことで専門家不足を乗り越えることや、逆に専門家が十分にいる自治体では、自治体ごとに教師データを作成し自治体特有のモデルを作成することも可能であろう。例えば、実際には積雪地帯では雪解けの時期に道路路面の損傷が目立つし、予算規模の大きな自治体では軽微な損傷も修繕するなど、地域によってインフラの状態や維持管理の基準は大き

く異なる。自治体ごとの損傷判定モデルを作成すれば、よりきめ細かな対応をしていくことが可能になるだろう。

イ 自治体ごとの管理基準の明確化

これまで各自治体では、インフラ維持管理は経験豊富な専門家によって、それぞれ点検がなされてきた。ゆえに、専門家不足に悩む自治体は維持管理の水準が著しく下がってしまっていた。本研究では、同一のシステムを複数自治体で展開することで、自治体ごとの管理水準の違いを抽出することを試みた。その結果、「損傷種類」が最も重要な自治体や、そうでない自治体があることが明らかになった。しかしながら、本研究における自治体ごとの管理水準の明確化の試みは萌芽的研究であり、今後研究の余地が大きく残っている。今後、本フレームワークを運用していく中で、よりデータ数を増やしつつ、詳細に分析をしていきたい。

謝辞

また、実験にご協力いただいた東京都足立区、千葉県千葉市、千葉県市原市、横浜市港南区、北海道室蘭市、愛知県長久手市に厚く御礼申し上げます。

参考文献

- 1) 前田 紘弥、関本 義秀、瀬戸 寿一、樫山 武浩、小俣 博司、機械学習とスマートフォンを用いた道路の損傷画像のリアルタイム検出と維持管理基準の作成、第37回交通工学研究会発表会論文集、pp.435-442, 2017.
- 2) 国土交通省：社会資本の老朽化の現状と将来、インフラメンテナンス情報、http://www.mlit.go.jp/sogoseisaku/maintenance/02research/02_01.html、2016。（最終閲覧日2017年7月27日）
- 3) 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 F 3（土木情報学）
- 4) Krizhevsky, A., Sutskever, I., & Hinton, G. E. : Imagenet classification with deep convolutional neural networks. In Advances in Neural Information Processing Systems (pp.1097-1105) , 2012.
- 5) Srinivas, S., Sarvadevabhatla, R. K., Mopuri, K. R., Prabhu, N., Kruthiventi, S. S., & Babu, R. V. : A taxonomy of deep convolutional neural nets for computer vision. arXiv preprint arXiv:1601.06615, 2016.
- 6) Chatfield, K, Simonyan, K, Vedaldi, A. & Zisserman, A.: Return of the devil in the details: delving deep into convolutional nets, 2014.
- 7) Nicholas D. Lane and Petko Georgiev. : Can Deep Learning Revolutionize Mobile Sensing?. In Proceedings of the 16th International Workshop on Mobile Computing Systems and Applications (HotMobile '15) . ACM, New

- York, NY, USA, 117-122, 2015.
- 8) Song, I., Kim, H. J., & Jeon, P. B. : Deep learning for real-time robust facial expression recognition on a smartphone. In Consumer Electronics (ICCE) , 2014 IEEE International Conference on (pp. 564-567) , 2014.
 - 9) YAGI, Koichi. : Extensional smartphone probe for road bump detection., 17th ITS World Congress, 2010.
 - 10) Chun, P. J., Hashimoto, K., Kataoka, N., Kuramoto, N., & Ohga, M.:Asphalt crack detection using image processing and naive Bayes based machine learning approach. Journal of Japan Society of Civil Engineers, Ser. E 1 (Pavement Engineering) , 2015.
 - 11) Jo, Y., & Ryu, S.:Pothole detection system using a black-box camera. Sensors, 15 (11) , 29316-29331, 2015.
 - 12) P.F.Felzenszwalb,R.B.Girshick,D.McAllester,andD.Ramanan.:Object detection with discriminatively trained part based models. IEEE Transactions on Pattern Analysis and Machine Intelligence, 32 (9) :1627-1645, 2010.
 - 13) S. Ren, K. He, R. Girshick, and J. Sun.:Faster r-cnn: Towards real-time object detection with region proposal networks. arXiv preprint arXiv:1506.01497, 2015.
 - 14) REDMON, Joseph, et al. : You only look once: Unified, real-time object detection. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016.
 - 15) BREIMAN, Leo. : Random forests, Machine learning,45.1: 5 -32,2001.
 - 16) 舗装委員会舗装設計施工小委員会：舗装の維持修繕ガイドブック2013,日本道路協会,2013.