

## 路面下空洞調査における人工知能を用いた解析効率化の取組み

応用地質株式会社 正会員 ○鴨下 智裕  
 応用地質株式会社 非会員 山下 善弘  
 SOINN 株式会社 非会員 長谷川 修

### 1. はじめに

日本の道路総延長は、平成30年4月現在で1,279,651.9km<sup>1)</sup>におよび、これらの道路を管理する行政は、舗装面や道路標識の整備、橋梁やトンネルの点検など多種にわたり維持管理を行っている。中でも、道路下の空洞による陥没発生は、平成29年度において報告されているだけで10,634件<sup>2)</sup>あり、その要因となるものは道路排水施設・道路側溝・管渠・上下水道などの道路施設や道路占有物が3分の2を占めている。また、陥没の規模によっては人命にかかわる重大事故につながることもあり、陥没の危険性が高い空洞箇所はいち早く検知する必要があるため、路面下空洞調査が計画的に行われている。この路面下空洞調査では、車載式やけん引式による地中レーダ測定装置（路面下空洞探査車）を用い、一日あたり数十キロ以上の広範囲を効率的に測定している。一方、空洞の存在を示唆する信号（以下、異常信号）を地中レーダデータから漏れなく抽出することは技術者の経験によるところが大きい。また、技術者の疲労や集中力の欠如等に起因する判定のゆらぎが誤判定の原因とならないよう、複数人で同一のデータを解析して結果を統合するダブルチェックで品質（確度）を向上させている。このようなことから解析には多くの時間を要し、かつ、経験豊富な技術者への負担が集中することから、危険性の高い空洞の抽出を迅速に行うことに支障をきたしている。

本報告では、顔認証や音声対話など身近な製品でも多く利用されるようになった人工知能を用いて、異常信号の自動抽出を行い、解析作業の効率化を図った取り組みの紹介をする。

### 2. 機械学習手法を用いた異常信号の抽出

今回用いた機械学習と呼ばれる手法は、人工知能のうち、データに含まれる規則性などを見つけ出し、類似したものの分類・検知などをコンピュータにより実現するための技術群の総称である。本報告では、図-1に示すような、実際に空洞を確認した地中レーダデータおよび非空洞の地中レーダデータによる教師データを作成し、類似したパターンを見つけ出す教師あり機械学習

手法を用いた。処理手順としては、図-1に示したような白黒の画像を教師データとして異常信号を分類・抽出する1段目の分類器、その後、1段目で抽出した信号の波形が空洞の特徴を有するかを分類・抽出する2段目の分類器を用いて異常信号の自動抽出を行った。なお、計算に使用したPCは、一般的に販売されている数十万円で購入可能なもの（CPU:Core i7-6700k, OS:Linux Ubuntu）である。

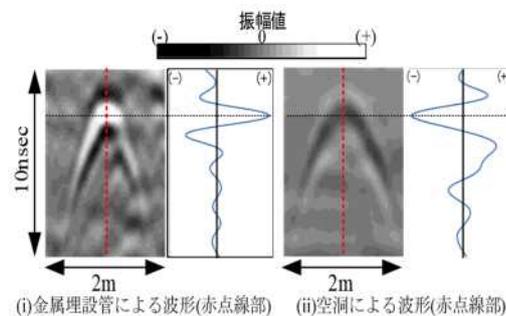


図-1 地中レーダデータの記録例

### 3. 抽出結果

機械学習による自動抽出結果を検証する目的で、教師データを含んでいない調査データをテストデータとして用い、自動抽出と経験豊富な技術者による解析をそれぞれ行い、空洞を掘削確認した結果と比較した。なお、道路や地下構造物の施工法や自然条件などの違いによる結果への影響を考慮し、2地域の調査データを用いた。今回用いた路面下空洞探査車は道路横断方向に6台の地中レーダアンテナを搭載しており、一つの空洞からの信号が複数のアンテナで捉えられることもあるが、それらは独立した信号として計上した。検

キーワード 路面下空洞探査, 人工知能, 機械学習, ディープラーニング, 効率化

連絡先 〒331-8688 埼玉県さいたま市北区土呂町2-61-5 応用地質株式会社 メンテナンス事業部 TEL048-652-4956

表-1 自動抽出検証結果

	検査対象 A	検査対象 B
距離走行 (km)	約 13.3	約 17.3
地中レーダのアンテナ数 (台)	6	6
(1) 確認済み空洞箇所数 (箇所)	8	6
(2) 技術者による空洞確認箇所の抽出数 (全アンテナの合計数) (箇所)	15	16
(3) (2)のうち自動抽出できた箇所数 (箇所)	14	12
(4) (1)のうちいずれかのチャンネルで空洞を抽出できた箇所数 (箇所)	8	6
1 km当たりの自動検出数 (1 アンテナ) (箇所)	31.6	42.5

表-2 過検出数

	(単位: 箇所)		
	検査対象 A	検査対象 B	新検査対象
Ver.1.0	3615	2038	754
Ver.2.0	875	556	154
Ver.2.1	693	417	52

表-3 1チャンネル当たりの計算速度  
(単位: km/h)

	Ver.1.0	Ver.2.0	Ver.2.1
CPU 1core(core i7-6700K)	211		
CPU multi core(core i7-6700K)	455	10	10
GPU (GTX 960)		110	106
GPU (GTX 1080)		205	201

検証結果を表-1 に示した。検証対象 A では技術者が抽出した空洞確認箇所 15 箇所のうち 14 箇所、検証対象 B では同確認箇所 16 箇所のうち 12 箇所を自動抽出した。技術者による抽出と自動抽出の 5 箇所の差について検討したところ、同一空洞からによる信号であることが判明した。よって、空洞の抽出という観点からすれば確認した空洞をすべて捕捉できた結果であった。一方で自動抽出された異常信号数は、各アンテナでの 1km あたりの平均で約 30 個~40 個と、実際の空洞確認箇所数と比較すると過剰に抽出されている（以下、過検出）。そのため、過検出を減らすことを目的として、分類器のアルゴリズムを決定木・kernel-SVM (Ver.1.0)<sup>3)</sup>から CNN を用いたディープラーニングに大幅変更した (Ver.2.0)。これにより、抽出漏れなく、表-2 に示すように過検出を大幅に減らすことができた。しかし、計算に時間が掛かるようになったため GPU を導入したところ、表-3 のように 1チャンネル当たり約 200 km/h の計算速度となり、実用的な速さとなった。対して、技術者の抽出速度を同様に 1チャンネル当たり換算すると、1日の労働時間を 8 時間とし全て解析に当てたとした場合、データの質にも左右されるが約 10km/h である。

#### 4. まとめ

人工知能を用いて、路面下空洞調査における地中レーダデータから空洞と考えられる異常信号の自動抽出を試みた。その結果、技術者が発見・確認した空洞を漏らさずに全て抽出することができた。しかしながら、自動抽出した異常信号数と空洞を確認した異常信号数を比較すると、最新版 (Ver.2.1) では当初 (Ver.1.0) の 1/5 程度、データによっては 1/14 程度まで減らすことができたものの、自動抽出個数が依然として多い。そのため、技術者による異常信号の選別に手間が掛かる。これは、自動抽出による抽出漏れを避けるために過検出をある程度容認するような条件としたためである。

一方、異常信号の抽出に要する速さは、自動抽出は技術者のおおよそ 20 倍の速度である。

以上のことから、路面下空洞調査で得られる膨大な量の地中レーダデータの解析において、異常信号を抽出する手法として人工知能が有効であることが実証できた。これにより、技術者が何もない状態から解析を始めるより、着目する必要がある信号に印が付くことで解析作業の効率を上げることができ、危険性の高い空洞の抽出をこれまでよりも迅速に行えると考える。また本手法により、少子高齢化による技術者不足の問題にも役立つと考える。

今後は、さらなる教師データの拡充と今春から始まる第 5 世代移動通信システムを利用した、より精度が高く、より早い結果を提供できるようなシステムを検討・開発していきたいと考えている。

#### 参考文献

- 1) 道路統計年報 2019 表 2 道路現況総括表 国土交通省  
<https://www.mlit.go.jp/road/ir/ir-data/tokei-nen/2019/nenpo02.html> 2020 年 3 月閲覧
- 2) 路面陥没発生状況 国土交通省  
<http://www.mlit.go.jp/road/sisaku/ijikanri/pdf/h27-29kanbotu.pdf> 2020 年 3 月閲覧
- 3) 山下他 (2017), 機械学習を用いた地中レーダによる舗装道路下空洞箇所の自動抽出の試み, 物理探査学会第 136 回 (平成 29 年度春季) 学術講演会