

深層学習および FDTD シミュレーションを用いたレーダ画像からの コンクリート内部の欠陥識別に関する基礎的検討

名古屋大学大学院 学生会員 ○ 光谷 和剛
 名古屋大学大学院 正会員 山本 佳士
 仙台高等専門学校 非会員 園田 潤
 大分工業高等専門学校 非会員 木本 智幸

1 はじめに

既設コンクリート構造物の健全性を的確に評価するためには、表面情報のみならず、角度、幅、間隔等の詳細情報を含む構造内部のひび割れの3次元分布情報の把握が必要である。構造物内部の情報を識別できる可能性のある手法として電磁波レーダ法があるが、ひび割れのような非常に薄い欠陥情報の識別に関してはまだ十分検討が行われておらず、また、レーダ画像を人手により判断する必要があるなど客観性に問題を残している。一方、園田ら¹⁾²⁾は、深層学習を用いてレーダ画像から地中埋設物の識別を行う手法を提案している。一方、土木分野における深層学習の適用においては、学習データ数の不足が課題であるが、園田らは、シミュレーションによりデータを大量に生成し、学習に利用することで精度を上げることに成功している。本研究では、同手法を、コンクリートの内部ひび割れ識別手法として適用することを試み、その前段階として人工的に埋め込んだ欠陥の識別に対する適用性を検討した。

2 欠陥識別手法の概要

本研究では、まず、サイズ、位置を変えて埋め込んだ人工欠陥を有するコンクリート供試体を作製し、同供試体を対象に電磁波レーダ法によって供試体断面のレーダ画像を取得する。また、FDTD法を用いて欠陥を含むコンクリートモデルの電磁波伝播シミュレーションを行い、レーダ画像を取得する。つづいて、欠陥を含むコンクリート供試体の断面の画像を用意し、対応する実験およびシミュレーションから得られたレーダ画像をペアにしてこれを学習データセットとする。この学習データセットを、画像から画像への変換手法で、敵対的生成ネットワーク(GAN)の応用技術である pix2pix³⁾に学習させる




図-1 pix2pix のネットワークの概要

ことで、レーダ画像から欠陥を含む供試体断面画像に変換するネットワークモデルを構築する。学習済みネットワークモデルに、任意のレーダ画像を入力すると、欠陥のサイズ、位置等の情報を含んだ供試体断面画像が生成される。

図-1 に GAN および pix2pix のネットワークの概要を示す。GAN では、入力 x から生成器(Generator) G で、描写像 $G(x)$ を生成し、識別機(Discriminator) D で真の画像 y か生成した画像 $G(x)$ かを判定する。さらに、生成器 G による生成と識別器 D の識別を競合させて繰返し学習することで、より本物に近い画像が生成される。pix2pix では、画像 x を生成器 G への入力とする。すなわち、入力も画像、出力も画像であり、任意の画像のペアの変換を学習するネットワークである。

3. 実験および FDTD 法の概要

図-2、写真-1 および表-1 に示すように、欠陥を模擬した発泡スチロールを、サイズを変化させて所定の深さに埋め込んだコンクリート供試体 1~6 を作成した。測定では、同一供試体でも測定位置を一定間隔でずらして複数の線状を走査しており、レーダ画像を計 228 枚取得している。

FDTD シミュレーションでは、表-1 の 1~8 の供試体モデルを対象とした。解析領域は $512 \times 512 \times 128\text{mm}$ であり、コンクリート層、コンクリート内部の欠陥層、コンクリート供試体上部および下部の空

キーワード コンクリート、内部ひび割れ識別、電磁波レーダ、深層学習、GAN、FDTD 法

連絡先 〒464-8601 愛知県名古屋市千種区不老町 名古屋大学 TEL 052-789-5111




図-2 供試体寸法




写真1 測定の様子

表-1 供試体一覧

	1	2	3	4	5	6	7	8
幅 b(mm)	50	200	25	125	100	150	50	200
奥行 h(mm)	200	50	125	25	150	100	200	50
厚さ t(mm)	5						1	

気層を格子間隔 1mm でモデル化している。境界は 16 層の PML とし、時間刻みは 1.5×10^{-11} s とした。コンクリートは粗骨材とモルタルでモデル化し、粗骨材は、土木学会コンクリート標準示方書の粗骨材の粒度分布の標準値からランダムに配置した。

4. 学習結果の評価

図-3 に実験レーダ画像のみを学習し、さらに、学習では使用していない実験レーダ画像を入力したときの、pix2pixにより得られた推定画像および正解画像の一例を示す。図より、特に欠陥位置が深いケースで、推定された欠陥位置は正解画像よりも下方にずれていることが分かる。これは、1) 深度の計算時にコンクリートの比誘電率を 6 とし、一定と仮定していたが、実際には内部で水分量が分布し、したがって、比誘電率の評価が実際と乖離していたこと、あるいは 2) 埋め込んだ欠陥が当初の想定からずれていた可能性（施工誤差）の影響などが考えられるが、まだ明確ではなく今後の課題としたい。しかしながら、欠陥のサイズは、概ね推定できている。

図-4 にシミュレーションにより得られたレーダ画像のみを学習し、さらに学習では使用していないシミュレーションレーダ画像を入力したときの推定画像および正解画像の比較を示す。図より、シミュレーションレーダ画像から推定するケースでは、位置、大きさともに推定できることが確認できた。さらに、厚さ 1mm と 5mm の結果を比較すると、反応値の違いから厚さを判別し、推定可能であることが確認できた。




図-3 実験画像からの欠陥推定




図-4 シミュレーション画像からの欠陥推定

5. まとめ

実験データのみを学習した場合、欠陥サイズおよび欠陥深さの推定精度が落ち、その理由として、コンクリート供試体の含水状態などが考えられる。シミュレーションデータのみを学習させた場合、サイズ、深さのみならず欠陥の厚さまでも判別可能になることが分かった。なお、シミュレーションレーダ画像と実験レーダ画像の間には、特にアンテナ、供試体表面近傍の領域で乖離が見られた。これは、レーダのアンテナ、シールド等の特性が未知であり、モデルの精度が十分でなかったためであると考えられる。いずれにしても、事前の検証で、実験データと大量のシミュレーションデータをそのまま合わせて学習しても精度は上がらないことが分かっている。今後は、実験データ画像を一旦疑似シミュレーション画像に変換する、あるいは反対にシミュレーション画像を疑似実験画像に変換するなどして、シミュレーションデータの利用について検討していく予定である。

参考文献

- 1) 園田潤, 木本智幸: ディープラーニングによる地中レーダの物体識別におけるシミュレーションレーダ画像と転移学習による実験画像の識別, 人工知能学会全国大会論文集. vol.3Z2-03, 2018.
- 2) 園田潤, 木本智幸: 敵対的生成ネットワークを用いた地中レーダ画像からのモデル推定, 信学技報, vol.118, no.249, pp.115-119, 2018.
- 3) P. Isola., J. Y. Zhu., T. Zhou., A. A. Efros. : Image-to-Image Translation with Conditional Adversarial Networks, arXiv : 1611.07004v1, 2016.