

# 3D-CNN を用いた地中レーダ画像の誘電率とサイズの分類

## Classification of dielectric constant and size of underground radar image using 3D-CNN

木本 智幸<sup>\*1</sup>  
Tomoyuki Kimoto

津野 龍<sup>\*1</sup>  
Ryo Tsuno

園田 潤<sup>\*2</sup>  
Jun Sonoda

<sup>\*1</sup> 大分工業高等専門学校  
National Institute of Technology, Oita College

<sup>\*2</sup> 仙台高等専門学校  
National Institute of Technology, Sendai College

In this study, to classify the underground objects from the ground penetrating radar (GPR) images by the three dimensional convolutional neural network (3D-CNN). Conservation management of roads is important for maintaining infrastructure, and in order to explore the whole road width at once, it is frequently performed to arrange a plurality of GPR in parallel and sweep. In this study, 3D-CNN is used to simultaneously process this plurality of GPR images and improve the classification performance. As a result, it reports that the classification performance improves for the dielectric constant and the size of buried objects.

### 1. はじめに

高度経済成長期から50年以上が経過した現在、道路や橋などの社会インフラの老朽化が急速に進んでいる。社会インフラの維持管理のために、現在主流となっている異常箇所発見方法は打音検査である。しかし、専門家がインフラの点検箇所を全て叩いて調べる必要があり、時間や手間がかかるデメリットがある。他の手法には、地中レーダ装置を用いる方法がある。地中レーダはインフラ内部を可視化できる点や、打音検査に比べて深い場所まで調査できる点で優れているが、レーダ画像は反射画像のため、レントゲンのように実物形状を投影しておらず物体を特定することが難しい。そこで、ディープラーニングを用いて地中レーダで得られた画像情報から物体の比誘電率を分類することが試みられている。

路面インフラの調査では、車両に複数の地中レーダを取り付け、路面内の空洞を調査することがある。本研究では、この複数の地中レーダ画像をディープラーニングで同時に扱うことで、識別精度の向上を狙う。そのために複数画像を3次元データとして学習できる3D-CNN(3次元畳み込みニューラルネットワーク)を構築し、比誘電率の分類実験を行う。また、埋設物の比誘電率および大きさ情報を一緒に学習するマルチタスク学習の実験も行う。

### 2. 地中レーダと観測画像

地中レーダは、地上から地中に向かって電波を放射し、地中と誘電率差がある場所で反射した電波を可視化する装置で、埋設物の捜索などに使われる。このとき、地中レーダに写る反射波形は、地中媒質の誘電率と埋設物の誘電率比によって決まる。また、地中レーダは指向性がワイドであり、埋設物が同じでも埋設深度が深くなるほど反射波は薄くなり、反射画像は大きくなる。

ディープラーニングの学習には、大量に画像が必要になるが、地中レーダ画像は埋設物を地中レーダで撮影後、掘り出さなければならないので十分な数を用意するのは困難である。そこで、学習に用いる地中レーダ画像は、FDTD法でシミュレーションして生成する[1]。シミュレーション上の埋設物は、比誘電率 $\epsilon$ 、幅 $w$ 、奥行 $l$ 、厚み $h$ を持つ直方体とし、比誘電率 $\epsilon$ は6種類(1,

5, 10, 20, 40, pec), 幅 $w$ 、奥行 $l$ 、厚み $h$ は各4種類(5cm, 10cm, 15cm, 20cm)の計384種類になる。地中媒質の比誘電率は $\epsilon_g=5$ とするため、 $\epsilon=5$ の埋設物は反射の無い画像となる。また、この埋設物が埋まっている座標 $(x,y,z)$ をずらした場合についても画像を生成する。 $x$ は地中レーダを引く方向、 $y$ は $x$ に対して垂直な方向、 $z$ は物体が埋設している深さ方向である。埋設物を $x, y$ は5種類(-20cm, -10cm, 0cm, 10cm, 20cm)、 $z$ は4種類(20cm, 30cm, 40cm, 50cm)の間隔ですらして配置した場合における、総計38400枚の画像を生成する。また、図1に示すように、地中媒質中に埋設物が一つだけである場合と、ターゲットの周囲にターゲットより小さめの複数の物体を配置して媒質の不均質性を持たせた場合の両方の画像で実験を行う。




図1 地中レーダ画像の例。上3枚は均質媒質(TypeA)、下3枚は不均質媒質(TypeB)

### 3. 2D/3D-CNN モデル

本研究では、畳み込みニューラルネットワーク CNN のうち一般的な2次元型(2D-CNN)と、それを拡張した3次元型(3D-CNN)を用いる。3D-CNNの基本構造は2D-CNNと同じだが、入力データに動画などの3次元データを扱える点が異なる。

元となるCNNには様々なモデルが提案されているが、本研究では、2015年のILSVRC物体識別の世界大会で優勝したResNetのうち、ResNet18とResNet34を用いる[2]。ResNetは、shortcut connectionという迂回路の導入が特徴であり、2015年以前のCNNモデルの持つ深い層で学習が進まなくなるという問題が改善されている。また、畳み込み層を増やすためにプー

連絡先: 木本智幸, 大分工業高等専門学校, 〒870-0152, 大分市牧 1666, kimoto@oita-ct.ac.jp, 園田 潤, 仙台高等専門学校, 〒989-3128 仙台市青葉区愛子中央 4-16-1, sonoda@sendai-nct.ac.jp

リング層を取り除いた点や深い層を持ちながら、最終層にしか全結合層がないためパラメータ数が少ない点も特徴である。ResNetは、2次元画像しか扱うことができないため、本研究では、各層で扱える次元数を増やし3次元データを扱えるように3D-CNN化したResNetを構築した。また、CNNで比誘電率 $\epsilon$ だけでなく、幅 $w$ 、奥行 $l$ 、厚さ $h$ も分類できるように、出力層の全結合層を分岐させ、中間層を共有するマルチタスク学習を行うモデルも構築した。

#### 4. 2D/3D-CNNを用いた地中レーダ画像からの埋設物の比誘電率およびサイズの識別

3D-CNNでは、地中レーダを引っ張る方向に垂直な $y$ 方向に等間隔に並べた複数の地中レーダの画像を同時に入力した場合において埋設物の誘電率およびサイズを識別させる。3D-CNNでは、埋設物を $(x,y,z)$ 方向にずらした画像の組みが一つの3D画像としたが、2D-CNNでは $y$ 方向の地中レーダ画像は独立した画像として学習させる。学習画像と検証画像には、均質媒質(TypeA)と不均質媒質(TypeB)の画像を使用する。表1の「画像」の列は、CNNの学習と検証に使った画像の組み合わせを示している。例えば、A-Bは学習画像がTypeAで検証画像がTypeBという意味である。「次元」の列は、CNNモデルが2D-CNNと3D-CNNのどちらであるかを示している。また、地中レーダ画像は、埋設物の $\epsilon$ で決定されるが、埋設物の大きさにも影響を受ける。そこで、埋設物の $\epsilon$ だけでなく、幅 $w$ 、奥行 $l$ 、厚さ $h$ といった大きさ情報と一緒に学習するマルチタスク学習の識別率実験も同様に調査する。CNNモデルは、ResNet18とResNet34を使用した。300epochの学習を5回行い、1試行ごとに学習画像と検証画像をランダムに入れ替えた。検証画像には、学習で用いた同種の埋設物を平行移動した画像が入らないようにした。

表1 2D/3D-CNNモデルの識別結果

画像	次元	CNNの モデル	誘電率 $\epsilon$ の 識別率[%]	幅 $w$ の 識別率[%]	奥行 $l$ の 識別率[%]	厚み $h$ の 識別率[%]
A-A	2D	ResNet18	95.2 $\pm$ 1.1	-	-	-
A-A	2D	ResNet18	95.1 $\pm$ 1.8	90.3 $\pm$ 1.0	79.4 $\pm$ 1.5	95.9 $\pm$ 1.8
A-A	2D	ResNet34	95.4 $\pm$ 1.9	-	-	-
A-A	2D	ResNet34	95.5 $\pm$ 1.3	92.0 $\pm$ 1.2	77.0 $\pm$ 3.7	96.0 $\pm$ 0.9
A-A	3D	ResNet18	94.7 $\pm$ 0.9	-	-	-
A-A	3D	ResNet18	94.8 $\pm$ 0.8	86.3 $\pm$ 1.8	91.7 $\pm$ 4.4	94.8 $\pm$ 1.0
A-A	3D	ResNet34	95.1 $\pm$ 1.6	-	-	-
A-A	3D	ResNet34	94.3 $\pm$ 1.6	86.1 $\pm$ 4.8	91.8 $\pm$ 5.5	94.2 $\pm$ 1.8
B-B	2D	ResNet18	95.2 $\pm$ 1.5	-	-	-
B-B	2D	ResNet18	97.3 $\pm$ 0.7	81.0 $\pm$ 2.8	75.8 $\pm$ 2.9	92.1 $\pm$ 1.9
B-B	2D	ResNet34	95.7 $\pm$ 0.9	-	-	-
B-B	2D	ResNet34	95.7 $\pm$ 1.5	82.2 $\pm$ 4.0	72.7 $\pm$ 3.1	89.9 $\pm$ 5.0
B-B	3D	ResNet18	98.4 $\pm$ 0.2	-	-	-
B-B	3D	ResNet18	98.0 $\pm$ 1.7	85.2 $\pm$ 4.3	92.3 $\pm$ 1.5	90.7 $\pm$ 0.7
B-B	3D	ResNet34	97.9 $\pm$ 0.6	-	-	-
B-B	3D	ResNet34	97.9 $\pm$ 1.0	88.4 $\pm$ 1.7	89.7 $\pm$ 2.0	89.4 $\pm$ 2.8
A-B	2D	ResNet18	63.9 $\pm$ 5.7	-	-	-
A-B	2D	ResNet18	71.8 $\pm$ 3.0	60.8 $\pm$ 3.6	50.9 $\pm$ 3.0	60.3 $\pm$ 2.0
A-B	2D	ResNet34	67.6 $\pm$ 2.0	-	-	-
A-B	2D	ResNet34	68.7 $\pm$ 5.0	62.1 $\pm$ 2.3	52.1 $\pm$ 3.1	61.1 $\pm$ 5.3
A-B	3D	ResNet18	78.0 $\pm$ 4.6	-	-	-
A-B	3D	ResNet18	75.1 $\pm$ 2.6	68.6 $\pm$ 4.9	78.3 $\pm$ 2.6	71.0 $\pm$ 3.6
A-B	3D	ResNet34	76.8 $\pm$ 1.7	-	-	-
A-B	3D	ResNet34	75.2 $\pm$ 2.5	71.0 $\pm$ 6.2	72.5 $\pm$ 3.2	75.9 $\pm$ 4.6

まず、表1の上部に学習画像をTypeA、検証画像をTypeAとした場合における結果について示す。2D-CNNと3D-CNNでの $\epsilon$ の識別率に差が見られない。また、マルチタスク学習にお

いても $\epsilon$ の識別率の向上は見られない。次に、学習画像をTypeB、検証画像をTypeBとした場合においては、3D-CNNは、2D-CNNよりも $\epsilon$ の識別率が2~3%程度改善されている。3D構造を持つCNNで学習したことによって、不均質媒質における地中レーダ画像に対して強い識別装置となっていると思われる。マルチタスク学習は、学習画像をTypeA、検証画像をTypeAとした場合と同様に、 $\epsilon$ の識別率に向上は見られなかった。最後に、学習画像をTypeA、検証画像をTypeBとした場合においては、3D-CNNの方が2D-CNNに比べて大きく $\epsilon$ の識別率が向上した。識別率は、画像セットA-AやB-Bの場合には及ばないが、画像TypeAは理想的環境での画像であるため、TypeAの識別率は参考程度にとどめるべきである。実際の現場において、地中の不均質性は現場毎に大きく異なるため、学習セットを様々な準備するのではなく、均質媒質のTypeAを学習して、不均質媒質のTypeBで検証することが実用上の性能評価として重要であり、この学習セットA-Bにおいて、3D-CNNが2D-CNNよりも $\epsilon$ の識別率が向上していることは重要な知見であると考えられる。図2に、画像セットA-Bにおける2D/3D-ResNet18の $\epsilon$ の識別率の混同行列を示す。この結果から、2D-CNNは $\epsilon=5$ の埋設物のほとんどを $\epsilon=1$ に誤答しているが、3D-CNNにすることで $\epsilon=5$ の識別率が改善されている。

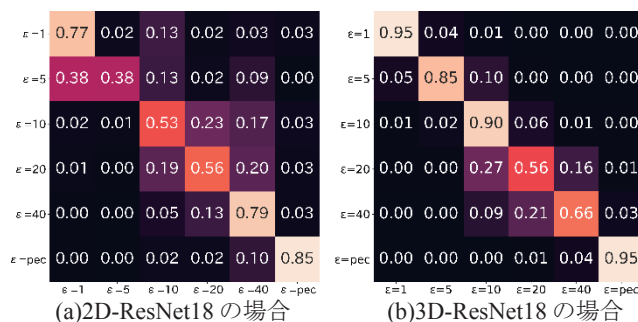


図2 学習画像をTypeA、検証画像をTypeBとした場合の2D/3D-ResNet18の $\epsilon$ の識別率混同行列

#### 5. むすび

現場に近い環境を模倣した地中の不均質媒質下において、2D-CNNより3D-CNNの方が比誘電率 $\epsilon$ の識別率を向上できることを示した。現場では地中媒質の不均質性があり、その不均質性も現場毎で異なるため、識別を困難なものにしている。よって、3D-CNNにすることで実際の現場での識別率向上が期待できる。また、埋設物の奥行方向の長さを識別するためには、地中レーダ画像の3D情報を用いることは必須であるが、本研究において、3D-CNNに入力して検証した結果、奥行方向の長さの識別率も大きく向上することが確認できた。一つのCNNモデルで、埋設物の比誘電率とサイズを同時に識別でき、計算コストも大幅に削減できる可能性が確かめられた。

#### 謝辞

本研究の一部は、総務省戦略的情報通信研究開発推進事業SCOPE、科研費・基盤研究(B)15H02997および基盤研究(C)17K00357の支援による。

#### 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画像の物体識別特性", 信学技報 EST2017-25 (2017)
- [2] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun, "Deep Residual Learning for Image Recognition", arXiv:1512.03385v1 (2015)