

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 シミュレーション画像と転移学習による実験画像の識別

Experimental Images Identificaton with Simulation Images and Finetuning
for Objects Identificaton of Ground Penetrating Radar Using Deep Learning

園田 潤*¹
Jun Sonoda

木本 智幸*²
Tomoyuki Kimoto

*¹仙台高等専門学校

National Institute of Technology, Sendai College

*²大分工業高等専門学校

National Institute of Technology, Oita College

In this study, to automatically detect underground objects from the ground penetrating radar (GPR) images by the deep neural network (DNN), we have generated GPR images for training the DNN using a fast finite-difference time-domain (FDTD) simulation with graphics processing units (GPUs). Also we have obtained characteristics of underground objects using the generated GPR images with a convolutional neural network (CNN) and finetuning using a modified VGG16 trained by the ImageNet. It is shown that the CNN and the VGG16 can identify four materials of experimental GPR images roughly 75 % and 80 % accuracy, respectively.

1. はじめに

2011年の東日本大震災では現在でも2546名が行方不明者であり、警察やボランティア等が捜索活動を継続している。我々は、東日本大震災後の行方不明者捜索に地中レーダを使用しており[1]、地中物体を効率的に検出できるようになっているが、物体の種類や大きさの識別が困難な問題があった。また現在、トンネルや道路など社会インフラ劣化が問題になっており、このような社会インフラ点検にも地中レーダが有効であるが、同様に地中レーダ画像からの異常箇所の抽出は熟練技術者による判読であり、計算機による客観的な自動識別が必要である。

地中レーダ画像の物体識別では、手書き文字認識等の画像認識と同じように、ニューラルネットワークによる機械判定が研究されているが[2][3]、識別率のさらなる向上や、物体の有無だけでなく材質や大きさの識別等のより高度な識別に課題があった。近年の計算機性能の向上とともにディープラーニングが注目されており、これらの課題を解決できる可能性があるが、実際の地中レーダ探査では多くの教師付学習データを用意するのは現実的に困難という問題があった。

我々はこれまでに、ディープラーニングで必要になる教師付学習用地中レーダ画像について、GPUを複数台使用するGPUクラスターを用いたFDTD法により100万個程度を生成しており、生成した学習用地中レーダ画像を用いた畳み込みニューラルネットワークCNNによる物体識別特性を検討している[4]。この結果、CNNに一部VGG[5]やドロップアウト構造等を導入したネットワークにより不均質な土壌においても地中物体の比誘電率や大きさを80%程度以上で識別できることを確認している[6]。

本稿では、これまでに確認しているCNNを用いたFDTDシミュレーションによる地中レーダ画像の物体識別について、シミュレーション画像を用いた学習モデルによる実際の実験画像の識別を検討する。ここでは、ImageNetで学習済みのVGG16を用いた転移学習の有効性について述べる。

連絡先: 園田 潤, 独立行政法人国立高等専門学校機構 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 木本智幸, 独立行政法人国立高等専門学校機構 大分工業高等専門学校, 〒870-0152, 大分市牧1666, kimoto@oita-ct.ac.jp

2. 学習・検証用地中レーダ画像の生成

地中レーダは、数百MHz帯の電波を地中に送信し、地中内の誘電率差で生じる反射波を地上で観測することで地中構造を推定するものである。実際の地中レーダでは、地中に大きさや材質が既知の物体を埋設して実験する必要があるため、教師付学習画像を生成するのは現実的には困難である。ここでは、学習用の教師付地中レーダ画像をFDTD法による物理シミュレーションで生成し[4]、コンクリートブロックによるモデル実験により実際の地中レーダ画像の識別を検証するための実験画像を生成する。







図1にコンクリートブロックによるモデル実験の外観とパラメータを示す。モデル実験では、TDRで誘電率を測定した物体をブロック中に設置することで材質や大きさを制御できる。ここでは、深さ d に大きさ $w \times h = 6 \text{ cm} \times l = 28 \text{ cm}$ の空洞、土、水をコンクリートブロック中に設置する。深さ d を12, 18, 24 cm, 幅 w を7, 14, 21 cmと変化させ、900 MHzの地中レーダでレーダ画像を得る。モデル実験では、図2に示すような物体なしを含め4種類各9枚全36枚の地中レーダ画像が得られるが、枚数が少ないため左右に2枚ずつ平行移動することで4種類各45枚の全180枚の画像を生成する。一方、図3にモデル実験と同一モデルを用いたFDTD法で生成したシミュレーションによる地中レーダ画像の例を示す。

3. シミュレーション画像と転移学習による地中レーダ画像の物体識別

図3のFDTD法で生成したシミュレーションによる地中レーダ画像を図4の5層CNNで学習させ、図2のモデル実



図1: モデル実験とパラメータ

(a) $d = 12$ cm の $w = 0, 7, 14, 21$ cm の空洞(b) $d = 12, 18, 24$ cm の $w = 14$ cm の空洞 (左 $w = 0$)(c) $d = 18$ cm で $w = 14$ cm の物体なし, 空洞, 土, 水
図 2: モデル実験によるレーダ画像の例@900 MHz(a) $d = 12$ cm の $w = 0, 7, 14, 21$ cm の空洞(b) $d = 12, 18, 24$ cm の $w = 14$ cm の空洞 (左 $w = 0$)(c) $d = 18$ cm で $w = 14$ cm の物体なし, 空洞, 土, 水
図 3: シミュレーションによるレーダ画像の例

験で生成した地中レーダ画像の地中物体 4 種類の識別率を調べる。ここで、シミュレーションで生成した地中レーダ画像をランダムに各分類 1~45 枚を学習させ、各分類 45 枚の実験画像の識別率を 20 回の試行の平均値により求める。ここでは、(1) 図 4 の 5 層 CNN とドロップアウト 0.5 の全結合層 2 層 (転移学習なし), (2) ImageNet で学習済みの VGG16 を用いた転移学習の識別率を調べる。VGG16 は全結合層を 3 層 (200 層+200 層+4 層) を追加し、200 層+200 層部分はドロップアウト 0.6 および Sigmoid 活性化関数を利用した。また、VGG16 の CNN 部分の結合荷重は、Imagenet を学習した結合荷重に転移学習を行った。

図 5 に学習した地中レーダ画像の枚数による地中物体 4 種類の材質の識別率を示す。この結果、(1) の転移学習なしの 5 層 CNN では各 45 枚の学習で識別率は 76 %であった。(2) の VGG16 による転移学習では 80 %に向上した。学習枚数による特性は図 5 より 10 枚程度で飽和しているが、いずれの学習枚数においても (2) の VGG16 の識別率は 5 %程度高いことが分かる。識別率が 80 %程度である理由は、図 2 に示したように土とコンクリートブロックの比誘電率差が小さいため反射波の振幅が小さくなり、物体なしと土の地中レーダ画像の類似度が高くなることから誤判定が生じるためである。一方、土を除いた物体なし、空洞、水の 3 種類での識別率は (1) で 90 %




図 4: 学習と識別に使用する 5 層 CNN

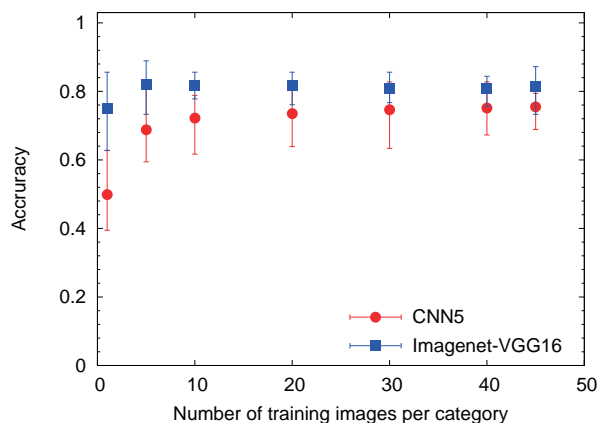


図 5: 地中物体の材質 4 種類の識別率

(2) で 92 %であった。土とコンクリートブロックのような周囲の媒質と対象物体の比誘電率差が小さい場合は、地中レーダの原理的に反射波が小さくなり識別率は低下するが、例えば、道路空洞調査のような問題では、空洞、水が入った空洞、その他の 3 分類程度でよい場合もあり、シミュレーションで生成した地中レーダ画像でも実際の地中レーダ画像を精度よく識別できる。シミュレーションで生成した地中レーダ画像が使用できれば、地中物体の大きさや形状等も自由に変えられるので、材質だけでなく大きさや形状の識別等も可能になる [6]。

4. むすび

ディープラーニングによる地中レーダ画像の物体識別について、FDTD シミュレーションで生成した地中レーダ画像を学習させた場合の実験画像の識別について調べた。材質 4 種の地中物体の地中レーダ画像数十枚を学習させ実験画像を識別した結果、転移学習なしの 5 層 CNN では 75 %程度、ImageNet で学習済みの VGG16 を用いた転移学習では 80 %程度と 5 %程度向上した。今後は、震災不明者捜索等で実証実験を行う。

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, 渡辺, 米澤, 金澤, 信学技報 SANE, Nov. 2013.
- [2] P. Gamba, et al., IEEE Geo. Remote Sens., 2000.
- [3] T.Hara and A.Hirose, Neural Networks, 2004.
- [4] 園田, 木本, 昆, 信学総大 CS-2-4, 2016.
- [5] K.Simonyan and A.Zisserman, arXiv:1409.1556.
- [6] 園田, 木本, 信学技報 PRMU2017-91, 2017.