畳み込みニューラルネットワークと敵対的生成ネットワークによる 地中レーダ画像の物体識別

Object Identification for GPR images with Convolutional Neural Network and Generative Adversarial Network

園田 潤^{*1} 木本 智幸^{*2}

Jun Sonoda

¹ 不不 留辛^{*2} Tomoyuki Kimoto

*1仙台高等専門学校

*2大分工業高等専門学校

National Institute of Technology, Sendai College N

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 studied identification characteristics of the underground objects with the generated GPR images by a convolutional neural network (CNN) and a fine-tuning which is modified VGG16 trained by the ImageNet. In this work, we have investigated to identify experimental GPR images by the generative adversarial network (GAN) which transfers from simulated images to artificial images.

1. はじめに

地中レーダは,数百 MHz 帯の電波を地中に入射し誘電率差 で生じる反射波を地上で受信することで地中物体を検出する技 術であり,近年劣化が深刻な道路やトンネルなどの社会インフ ラのセンシングや,自然災害に対する地盤や河川堤防などの防 災・減災対策に有効である.しかしながら,地中レーダで得ら れる地中の断面に相当する地中レーダ画像から物体の材質や大 きさを識別することが課題であった.

地中レーダ画像の物体識別は、手書き文字認識等と同じよう に、これまで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 [1]、性能は十分でなかった.近年の計算機性能 の向上とともにニューラルネットワークを多層化したディープ ラーニングの適用が考えられるが、地中レーダでは大量の教師 付学習画像を用意するのは現実的に困難という問題があった.

我々はディープラーニングによる地中レーダ画像の地中物体 識別を目的に, GPU クラスタを用いた FDTD 法による地中 レーダシミュレーションで学習用レーダ画像を大量生成し, 畳 み込みニューラルネット CNN を用いて複雑さの異なる多様な 土壌中の地中物体の識別特性を明らかにしている [2][3].

本稿では、CNN の学習で用いるシミュレーション画像を敵 対的生成ネットワーク GAN を用いて擬似実験画像に変換する ことで実際の実験画像の識別率向上を検討する.

2. 学習・検証用地中レーダ画像の生成

ディープラーニングでは大量の教師付学習用画像が必要であ るが、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する [2]. また、実際の地中レーダ画像をの識別する検証用の実験画像

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 は、コンクリートブロックによるモデル実験で生成する.

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、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、コンクリートブロック中の深さ*d*に大きさ $w \times h = 6$ cm × $\ell = 28$ cm の空洞,土,水を設置する.深さ*d*を12,18, 24 cm,幅*w*を7,14,21 cm と変化させ、900 MHz のレー ダで地中レーダ画像を得る.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枚計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枚計180枚の検証画像を生成する.一方, 図3にモデル実験と同一モデルでFDTD 法を用いて生成した シミュレーションによる地中レーダ画像の例を示す.図3のシ ミュレーション画像を学習用データとして用い、図2の実験に よる地中レーダ画像から物体の比誘電率の識別率を調べる.

CNNとGANを用いたシミュレーション 画像による実験画像の物体識別

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 のモデル実験 で生成した地中レーダ画像の地中物体 4 種類の比誘電率の識別 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 画像を各分類 1~45 枚ランダムに選択し学習させ、検証画像と して各分類 45 枚の実験画像の識別率を 20 回試行の平均値から 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、(2) ImageNet で学習済みの VGG16 を用い



図 1: モデル実験とパラメータ





た転移学習と,(3) シミュレーション画像を敵対的生成ネット ワーク GAN で疑似実験画像に変換後に(1)の CNN で学習・ 検証,(4) シミュレーション画像を (1)の CNN で学習後に検 証画像の実験画像を GAN で疑似シミュレーション画像に変換 し(1)の CNN で検証,以上の(1)から(4)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.GAN による画像変換では pix2pix[4]を用 い,シミュレーション画像と実験画像のペアを全 180 枚から 4 枚,12 枚,20 枚を選択し 1000 epoch 学習させ,疑似実験画 像や疑似シミュレーション画像に変換する.

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 類の比誘電率の識別率を示す.この結果,学習枚数80枚程度 で識別率はほぼ飽和しているが,平均識別率は,(1)5層CNN で75%程度,(2)VGG16による転移学習で80%程度であっ た.GANの画像変換により,(3)疑似実験画像に変換後に学 習すると95%程度,(4)疑似シミュレーション画像に変換後に 検証すると90%程度に向上した.図6に学習枚数によるGAN で生成した疑似実験画像の品質を示す.左から変換前のシミュ レーション画像,4枚学習,20枚学習,実際の実験画像であ る.図6から学習画像20枚の方がより実際の実験画像に近い ことが分かる.学習画像4枚でも実験画像に比較的類似して いるが,図5に示した識別率は5層CNNのみとほぼ同程度





図 6: GAN の学習枚数による擬似実験画像(左から変換前の シミュレーション画像,4枚学習,20枚学習,実際の実験画像)

であった. GAN によりシミュレーション画像を疑似実験画像 に変換して学習させることで識別率は向上するが,ある程度の 枚数のシミュレーション画像と実験画像のペアが必要になる.

4. むすび

ディープラーニング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によ る実験画像の識別について調べた.4 種類の地中物体のシミュ レーション画像を学習させ実験画像を識別した結果、5 層 CNN では75%程度であったが、GAN でシミュレーション画像を疑 似実験画像に変換後に学習することで95%程度に向上した.

今後は,GANによる画像変換のさらなる識別率向上や,Cycle GAN や MultiStyle Transfer などの少ない学習画像での 擬似実験画像生成による実験画像の識別を検討する.

謝辞

本研究は、総務省戦略的情報通信研究開発推進事業 SCOPE の支援による.

参考文献

- [1] P. Gamba, et al., IEEE Geo. Remote Sens., 2000.
- [2] 園田, 木本, 昆, 信学総大 CS-2-4, 2016.
- [3] J. Sonoda and T. Kimoto, Proc. of PIERS2018.
- [4] P. Isola, et al., arXiv:1611.07004v1, 2016.