

3次元畳み込みニューラルネットワークを利用した 地中レーダデータにおけるイベント検知

松岡俊文¹・鳥取稜平²・東 宏幸²・小田義也²

¹ 深田地質研究所

² 東京都立大学

Event detection in ground penetrating radar data using 3D convolutional neural network

MATSUOKA Toshifumi¹, TOTTORI Ryohei², AZUMA Hiroyuki², ODA Yoshinari²

¹Fukada Geological Institute

²Tokyo Metropolitan University

要旨：下水管など地下埋設物に起因する道路陥没事故は多数発生しており，道路インフラの整備と保守の観点から問題となっている．このため陥没の原因となる路面下の空洞に対する調査は重要であり，地中レーダ(GPR)を用いた調査が利用されている．GPR探査は，比誘電率の違いによって生じる電磁波の反射を利用した物理探査手法の1つであり，地下浅部を高速かつ高精度に可視化できる手法である．現在では20個に及ぶアンテナを装備し，3次元探査が可能なシステムが開発され，車で走行しながら路面下の調査が可能となっている．その結果，データ量は飛躍的に増加し，その解析には多くの人的資源が必要となっている．この課題解決のため，本研究では近年飛躍的な技術進歩を見せている深層学習の手法をGPRのデータ解析に適用した．GPRデータに対して，3D-CNN手法を適用しその技術評価を行った結果，十分実用に耐えられる結果を得た．
キーワード：道路陥没，路面下空洞，地中レーダ，3次元畳み込みニューラルネットワーク

Abstract: Many road cave-in accidents have occurred due to underground cavities caused by sewage pipe leakage, a problem from the viewpoint of road infrastructure development and maintenance. GPR is one of the geophysical survey methods that utilize the reflection of electromagnetic waves caused by differences in relative permittivity. This method can visualize shallow underground areas with high speed and precision. Currently, a three-dimensional survey system equipped with as many as 20 antennas has been developed, enabling the subsurface survey while driving a car. As a result, the amount of data has increased dramatically, and many human resources are required to analyze the data. In order to solve this problem, we applied the deep learning technique, which has shown dramatic technological progress in recent years, to GPR data analysis. We evaluated the 3D-CNN technique on GPR data and obtained the possibility of daily use.

Keywords: road subsidence, under-road cavities, ground-penetrating radar, 3D-CNN

1. はじめに

我が国では，地震や地下掘削工事，管路施設などに起因した道路陥没が幹線道路や住宅街で発生している．中でも，2016年の博多駅前道路陥

没事故をはじめ，2020年の東京都調布市における外環道トンネル工事付近や2021年の東京都武蔵野市吉祥寺などでの大規模な道路陥没は記憶に新しい．しかしながら，このような大規模な陥没事故は極めて例外的である．発生した道路陥没の

約9割は深さ50cm未満の浅い陥没であり、下水管路などの地下埋設物に起因する小規模なものが多数を占めている。

下水管路などの地下埋設物に起因する小規模な道路陥没は、年間約3,000件程度発生しており、深刻な問題となっている(竹内ほか, 2017)。社会インフラとして舗装道路下に敷設された埋設管は、老朽化に伴う破損などにより周囲の土砂が管内に流れ込み、管の周囲に空洞が形成される。空洞が大きくなると、道路を走行する車両の振動などに耐えられなくなった舗装面が破壊され、道路陥没が発生すると考えられている(桑野ほか, 2010b; Mukunoki et al., 2009)。日本の路面下には、下水道管だけでも約48万キロメートル(地球12周に相当)が埋設されており、そのうち老朽化したものは全国で10万箇所以上あると言われている。

このような道路陥没の原因となる空洞を事前に発見し、事故を未然に防ぐことは道路管理上非常に重要である。そのための調査方法として、地中レーダ(Ground Penetrating Rader: 以下, GPR)を用いた路面下空洞探査が提案されている(桑野ほか, 2010a; Yoon et al., 2020)。このGPR探査は、比誘電率の違いによって生じる電磁波の地下物体からの反射を利用した物理探査手法の1つであり、地下浅部を高速かつ高精度に可視化できる手法である。取得されたデータは、専門技術者の目視による人的解析によって評価と検討が加えられる。GPRのデータ取得技術の向上、さらに道路の陥没問題に対する有効な手段としてのニーズの急増により、現在解析すべきデータ量が大幅に増加している。このような背景のもとで、GPRデータ解析の自動化及び省力化が求められている。

本研究ではこの課題に対し、近年様々な分野で活用されている深層学習に着目し課題解決を試

みた。昨今の計算技術や計算能力の著しい発展により物体認識能力が大幅に向上してきた深層学習は、今なお世界中の研究者などによって数多くのモデルが提案され続けている。特に畳み込みニューラルネットワーク(Convolutional Neural Network: 以下, CNN)は画像認識の分野で広く用いられている(岡谷, 2022; Chollet, 2022)。

本研究では、路面下の空洞や埋設物の調査に用いられているGPRデータから、深層学習を利用して路面下空洞や埋設物などのイベント検出の自動化を試みた。これまでGPRデータに対する深層学習の適用としては、2次元の畳み込みニューラルネットワーク(2D-CNN)が適用された例がある(Ishituka et al., 2018; 磯ほか, 2019)。近年の技術革新により道路を走行する車両にGPRのアンテナを複数個設置することで、3次元的な地下映像の取得が可能となっている(Liu et al., 2021)。今回は、3次元的に取得されたGPRデータを対象とし、3次元の畳み込みニューラルネットワーク(3D-CNN)を用いて解析を進めた。2次元解析では空洞と埋設管との分類が困難であったが、3次元的な反射パターンの形状に着目し、自動識別の可能性を示すことができた。

2. 地中レーダ

電磁波を利用して地下構造を探査しようとする着想は古くからあり、1910年にドイツ人のGotthelf LeimbachとHeinrich Löwyによる特許が最初と言われている(Francke, 2020)。その後、アメリカを中心に研究が進められてきたが、本格的な研究はCookが行った氷雪の厚さの測定に始まる(原・坂山, 1984)。現在のGPR探査システムの基本構成は、1970年代から1980年代前半に確立された。当時の装置は非常に大きいもので

あったが、1990年代以降は電子機器の発展により、より軽く、強力で、精巧な機器が開発されてきた。

日本においても1971年頃から研究が始められ、地層や土層構造の調査、路面下の空洞や埋設管の探査、あるいは埋蔵文化財の調査に利用されてきた。GPRは地中やコンクリートを非破壊で調査するのに最適な技術であり、現在ではその用途は非常に多岐に渡っている。

GPRは地中に放射する電磁波の照射方向を制御することはできないため、装置を移動させながら計測を行う。地表の送信アンテナから電磁波を照射し、地層境界面や埋設物及び空洞などの異常箇所では反射された電磁波を、地表の受信アンテナで受信する。電磁波の反射強度は地中媒質と地中に存在する異常箇所の誘電率の比で決定され、地中に空洞や埋設物が存在している場合には、反射波の波形に特有の双曲線状のパターンが現れる。GPRによる測定方法の概略図を図1に示す。

GPRの性能は以下の2点で評価することがで

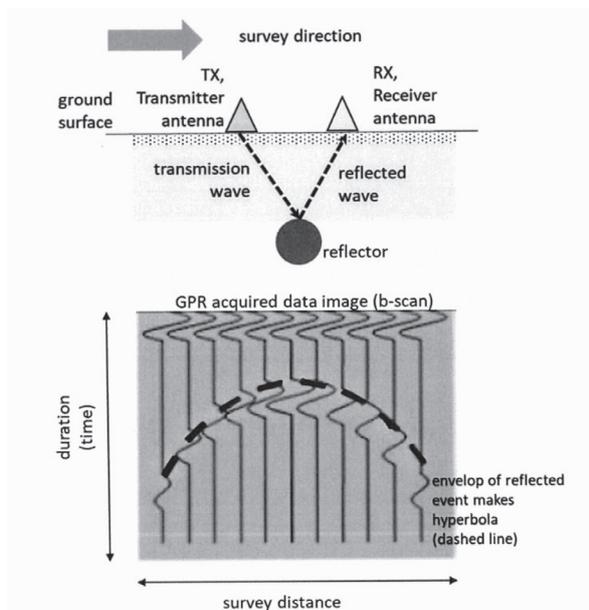


図1 GPR探査の概略図(磯, 2019).

きる。

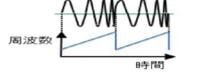
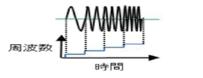
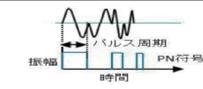
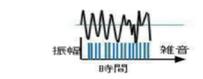
- ① 探査深度：異常箇所を検出できる最大深度
- ② 分解能：取得された画像上で2つの異常箇所を分離できる最小距離

電磁波は地中を伝播する際に減衰していく。この減衰は周波数に対して一様ではなく、周波数が高くなるほどに大きな減衰を受ける。このため、同一の媒質において異なる周波数を用いて探査を行った場合、高い周波数では探査深度が低下するが、波長が短くなるために分解能が向上する。一方、低周波数の場合には分解能が低下するが、探査深度は深くなる。このように、GPR探査において探査深度と分解能はトレードオフの関係にあるため、探査を行う目的や目標の深度に応じて適切な周波数を選択する必要がある。通常用いられるGPRの電磁波の周波数は50MHz～4.5GHz程度である。

GPRのシステムは、変調をかけない直流パルス照射し時間領域で計測を行うインパルスレーダシステムと、変調方式を用いて周波数領域で計測を行うシステムに大別される。周波数領域で計測をするシステムには、無変調連続波方式レーダシステム、変調連続波方式レーダシステム、疑似雑音レーダシステムなどが存在する(総務省, 2017)。これらの違いと特徴を表1に示す。周波数領域で取得した波形は逆フーリエ変換で時間帯領域に変換することで、インパルスレーダシステムで取得した波形データと同様に扱うことが可能となる。

本研究で用いた3次元GPRデータは、ノルウェーにある3D-Radar社(現: Kontur社)の3D-Radarを用いて取得されたものである。これは、多素子の超広帯域アンテナを60MHz～3GHzの正弦波ステップ周波数を高速に切り替えながら、面的に20チャンネル分の測定が可能な

表 1 レーダ波の変調方式とその特徴（総務省，2019）.

| レーダー方式 | 変調方式 | 送信波形 | 動作原理 | 特徴 |
|------------------|----------------------|---|---|--|
| インパルスレーダーシステム | 無変調 |  | 変調をかけない直流パルスを送信し、反射波を時間領域で計測する。 | 反射波形が反射体位置・形状に対応するから信号処理を経ずに受信信号から直接反射体の深度や位置を特定できる。 |
| 無変調連続波方式レーダーシステム | CW (continuous wave) |  | 単一周波数を用いたシステム。 | アンテナに対して固定された物体までの距離情報が特定できない。 |
| 変調連続波方式レーダーシステム | FM-CW (チャープ) |  | 連続的に周波数を掃引しながら電磁波を送信し、反射波と送信波のビート周波数（差周波数）から、反射波までの距離を検出。 | 反射対距離検出のための帯域フィルタあるいは FFT アルゴリズムなどの信号処理を必要とする。 |
| | SF-CW (ステップ周波数) |  | 離散的に変化する多周波数において、各周波数毎の送信波に対する反射波の振幅・位相を計測する。 | 反射体までの距離や反射係数を求めることができ、実際の測定したスペクトルから時間領域波形を得るために FFT アルゴリズムなどの信号処理を必要とする。 |
| 疑似雑音レーダーシステム | 符号化パルス |  | PN (Pseudorandom Noise) 符号を用いて離散的に位相変調を行い、受信時に符号系列の相互相関処理により計測する。 | 反射対距離検出のための FFT アルゴリズムなどの信号処理を必要とする。 |
| | 疑似雑音 |  | 雑音を用いて離散的に位相変調を行い、受信時に符号系列の相互相関処理により計測する。 | 反射対距離検出のための FFT アルゴリズムなどの信号処理を必要とする。 |

周波数領域型の高分解能 3 次元 GPR である。アンテナは、地面から 20～30 cm 程度離れた状態で測定を行うエアークップル型で、図 2 のようにアンテナを車両に搭載して調査対象の道路を走行しながらデータ取得を行う。今回は同じ場所で測定の実験を兼ねて実施され、測線長の短い 4 調査のデータを利用した。観測諸元を表 2 に示す。20 チャンネル分のプロファイル測定を車両の進行方向に 1 cm ごとに行っている。データのボリュームは測線により多少の違いはあるが、深さ方向に 330 サンプル（サンプリング間隔：0.098 ns），移動方向に 27000 サンプル（測線長 270m）程度である。解析に使用されたデータには、ノイズ低減処理やバンドパスフィルタなどの基本的な前処理が施されている。

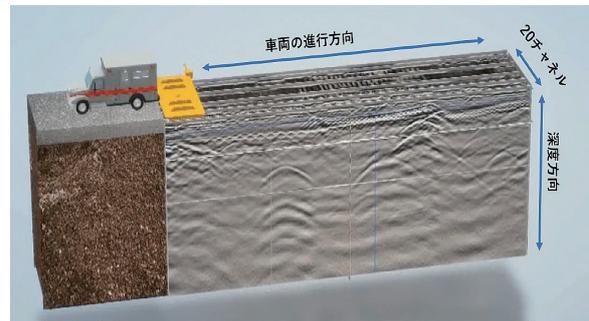


図 2 3 次元 GPR の測定概念図.

表 2 GPR の諸元.

| | |
|-----------------------------------|-------|
| Number of channels | 20 |
| Horizontal sampling interval (cm) | 1 |
| Depth sampling interval (ns) | 0.098 |
| Start Frequency (MHz) | 60 |
| End Frequency (MHz) | 2990 |
| Width of step (MHz) | 10 |
| Data type | 16bit |

3. 深層学習

人工知能 (Artificial Intelligence, AI) の研究は、過去に 3 回の「ブーム」と「冬の時代」を繰り返

している。第1次AIブーム(推論・探索の時代)は、1950年代後半から1960年代に起こった。計算機を使った「推論」や「探索」の試みが始まり、迷路やパズル、定理の証明のような規則的で簡単な問題を解くことはできたが、複雑な問題が解けないことが明らかとなり、ブームが終息した。

1970年代の冬の時代を迎えた後、1980年代には、コンピュータに「知識」を与えることで能力が向上することが分かり、データベースに大量の専門知識を蓄えたエキスパートシステムと呼ばれる実用的なシステムが多数開発された。これが第2次AIブーム(知識の時代)である。しかし、当時のコンピュータでは必要な情報を自ら収集し蓄積することが不可能であったため、必要となる全ての情報を人間がコンピュータに入力する必要があった。その結果、このような方法での知識を蓄積し管理することの困難さが明らかとなり、1995年頃からブームは再び衰退した。

第3次AIブーム(機械学習・特徴表現学習の時代)は2000年代から現在にかけて続いている。計算技術の発達によって、大量のデータ(ビッグデータ)を扱うことが可能となり、AIが自ら知識を獲得する機械学習が実用化され、さらに特徴量を自ら習得する深層学習(Deep Learning)が登場した。深層学習は、2012年に画像認識技術のコンペティションでトロント大学のHinton教授らのチームが驚異的な成績で勝利を収めたことを契機に、現在の第3次AIブームをもたらした。

ニューラルネットワーク(Neural Network)は、生物の脳を構成する神経細胞(ニューロン)を多層に重ね合わせた情報処理機構を模倣した数理モデルである。与えられたデータに基づく学習を通して、必要とされる情報処理を実現するものである。層状に並べた人工ニューロン(パーセプトロン)が隣接した層間でのみ結合し、複数の入力に

対して1つの出力を持つ。図3は3層のニューラルネットワークを模式的に表したものである。入力を行う第1層を入力層、出力を行う最終層を出力層とし、これらの間の層を隠れ層と呼ぶ。ニューロン同士の情報伝達は隣り合う層で行われる。

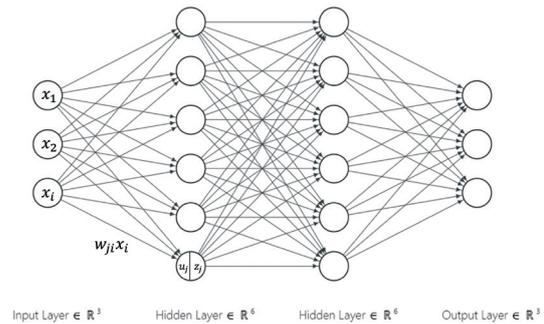


図3 3層ニューラルネットワークの模式図。

各ニューロンはその入力値に対して活性化関数と呼ばれる連続非線形関数 f を介して出力される。またそれぞれのニューロン間の接続強度が重み w で表現される。人間の脳には思考の偏りが存在しており、それをバイアス b として隠れ層に加えている。重みとバイアスは一般的にパラメータと呼ばれる。

任意の $(l-1)$ 層 i ユニットから、 l 層 j ユニットへの入力 $x_i^{(l)}$ に対する重み $w_{ji}^{(l)}$ との積 $(w_{ji}^{(l)} x_i^{(l)})$ を定義すると、 j ユニットへの入力の総和 $u_j^{(l)}$ は次のように表される。

$$u_j^{(l)} = \sum_i w_{ji}^{(l)} x_i^{(l)} + b_j^{(l)} \quad (1)$$

この j ユニットの出力 $z_j^{(l)}$ は、前述のように活性化関数 $f_j^{(l)} \rightarrow u_j^{(l)}$ を入力した結果であり、次のように表される。

$$z_j^{(l)} = f_j^{(l)}(u_j^{(l)}) \quad (2)$$

この $z_j^{(l)}$ は次の層 $(l+1)$ への入力 $x_j^{(l+1)}$ である。活性化関数には様々な種類が存在しているが、現在一般的に用いられるのは、双曲線正接関数、ReLU

関数、シグモイド関数などである (岡谷, 2022)。

ニューラルネットワークの学習では、ネットワークの出力と正解データの違い (損失関数) を小さくするように各層の重みとバイアスを更新する。損失関数 $E(\mathbf{w})$ は一般的に正解ラベル d_n と実際の出力値 $y_k = z_j^{(l)}$ との平均二乗誤差 (式 (3)) や交差エントロピー (式 (4)) で定義される。

$$E(\mathbf{w}) = \frac{1}{n} \sum_k (d_k - y_k)^2 \quad (3)$$

$$E(\mathbf{w}) = - \sum_k d_k \log y_k \quad (4)$$

深層学習では非常に多数の重みとバイアスを更新する必要があるために勾配降下法が用いられる。任意の $(l-1)$ 層 i ユニットからの入力要素に対して、 l 層 j ユニットへの入力の重み $w_{ji}^{(l)}$ の更新は次の式で表される。

$$w_{ji}^{(l)} \leftarrow w_{ji}^{(l)} - \epsilon_j^{(l)} \frac{\partial E(\mathbf{w})}{\partial w_{ji}^{(l)}} \quad (5)$$

ここで、 $\epsilon_j^{(l)}$ は l 層 j ユニットの学習係数、出力層 $l=L$ でのユニット数を n 、 $E(\mathbf{w})$ は損失関数である。

式 (5) の計算には各層での損失関数のパラメータに関する偏微分 (勾配) が必要になる。この計算には誤差逆伝播法 (Back propagation) が用いられる。これにより、各層での損失関数のパラメータに関する偏微分 (勾配) を、連鎖律の法則 (Chain rule) を用いたことで簡易なアルゴリズムを利用して求めることができる。

学習データとは、機械学習でモデルを学習させる際に与えられる正解データのことである。教師あり学習においては、入力するデータとそれが何かを表すラベルがセットになったデータが利用され、データに対して正しいラベル付けを行う作業のことをアノテーションと呼ぶ。このデータセットを用いて学習が行われるが、その際、モデルに

汎用性を持たせるために交差検証が行われる。これは、学習データを訓練用と検証用に分けて、学習は訓練データでのみ行い、モデルの検証には学習に用いられていない検証データで行う。

畳み込みニューラルネットワーク (CNN) は、全結合層 (Fully-Connected Layer) に加え、畳み込み層 (Convolutional Layer) とプーリング層 (Pooling Layer) から構成される (図 4)。これは、生物の脳の視覚野に関する神経生理学的な知見を基に考案された Neocognitron (Fukushima and Miyake, 1982) をベースとして開発されたニューラルネットワークの 1 種である。

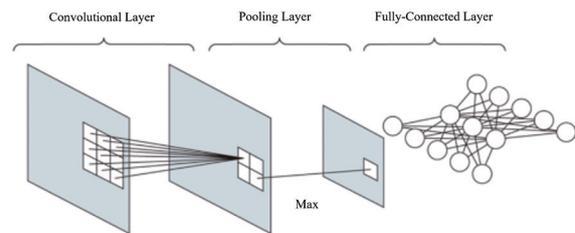


図4 畳み込みニューラルネットワークの模式図。

2012年に開催された ImageNet Large Scale Visual Recognition Competition (ILSVRC) において、AlexNet (Krizhevsky et al., 2012) と呼ばれる CNN のモデルが従来の手法に大差をつけて優勝したことがきっかけとなり、第3次 AI ブームをもたらした。それ以降、ILSVRC では、CNN を用いた手法が主流となっている。現在でも、研究者らによって新たな CNN のモデルが提案され続けており、ILSVRC で優秀な成績を収めたモデルが、画像認識やその他様々なタスクを解くためのデファクトスタンダードとして利用されている。図4の場合、画像が白黒である場合の模式図であり、データは1チャンネルである。しかしながら画像認識問題では、入力データはカラーデータが多いため、RGBの三原色を持つ3チャンネルのデータが一般的である。

4. 深層学習のGPR解析への応用

GPR 探査によって得られたデータに対する深層学習を用いた自動解析は、近年活発に研究が進められている (Shaw et al., 2005 ; Ishitsuka et al., 2018 ; 磯ほか, 2019 ; 伊東ほか, 2021). これらの研究では、3次元で取得されるGPRデータに対して、チャンネルごとのデータを2次元の地下断面画像と見なして、2D-CNNを用いて解析が進められている。伊東ほか (2021) では、2次元の断面画像ではなく、スライス画像を重ね合わせることで作成した2種類 (深度断面, 深度スライス) の3次元データを、AlexNetで20チャンネルのデータを取り扱えるように修正したモデルを用いて解析を行っている。これは疑似的な3次元解析になっており、2次元断面画像と見なして解析を行った場合よりも良い結果を得られる可能性と、発展性を見出すことができた。

5. 3次元畳み込みニューラルネットワーク

本研究では深層学習のモデルとしてZunair et al., (2020) により提案された、3次元畳み込みを利用する3D-CNNを採用した (鳥取ほか, 2021). この手法は、医療の分野においてMRIやCTスキャンで取得された3次元データに対する早期異常検知手法として、現在盛んに研究が進められている。

3D-CNNは3次元ボリュームデータを入力し、立体的な構造を対象にそのまま学習できるために、2次元断面データを利用している深層学習モデルよりも正確であると言える。一方、3D-CNNの弱点として、畳み込みのカーネルが3次元であるため、比較的浅い深層学習モデルでも学習時間が長く、推定する重みの数が飛躍的に増加するこ

とが挙げられる。基本構成を図5に示す。

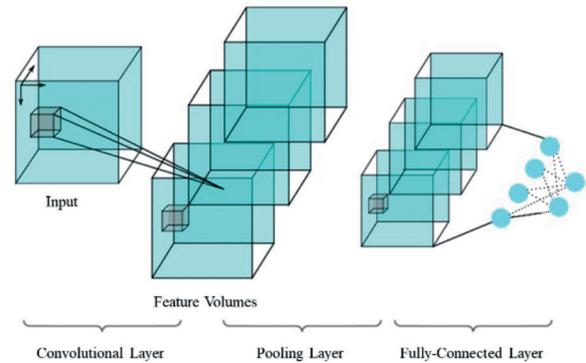


図5 3D-CNNの基本構成(Roy & Mishra, 2019に追記).

Zunair et al., (2020) によって開発された3D-CNNのモデルをベースに、本研究では入力層、さらにConv3d・Max pooling・Batch normalizationの組み合わせを4層用意し、その後全結合層、出力層で構成した。入力データは65×65グリッド画像20チャンネル分で、65×65×20のボリュームデータとし、畳み込み層におけるカーネルサイズは3×3×3で固定した。1層目と2層目の畳み込み層におけるカーネル数は64個であり、3層目では128個、4層目では256個となり、その後512ユニットの全結合層の構成とした。

6. 深層学習の能力評価指標

本研究では3D-CNNを用いて既往の研究と同様に、GPR画像に見られる双曲線パターンが地下空洞からのイベントであるか否かの2クラス分類に加え、空洞、埋設管 (パイプ)、その他と地下の異常体の3クラス分類も試みた。

深層学習における能力の評価に関しては通常、以下で述べる指標が広く利用されている。2クラス分類では、実際のクラスと予測したクラスの組み合わせによって、結果を以下の4種類に分けることができる (表3参照)。この表は混同行列と

呼ばれる。イベント有のラベルを陽性、イベント無のラベルを陰性とした。

1. 真陽性 (TP : True Positive) : 実際のクラスが陽性で予測も陽性 (正解)
2. 真陰性 (TN : True Negative) : 実際のクラスが陰性で予測も陰性 (正解)
3. 偽陽性 (FP : False Positive) : 実際のクラスは陰性で予測が陽性 (不正解)
4. 偽陰性 (FN : False Negative) : 実際のクラスは陽性で予測が陰性 (不正解)

表 3 深層学習結果の評価に利用される混同行列.

| | | Predicted | |
|--------|----------|--------------------|--------------------|
| | | Positive(P) | Negative (N) |
| Actual | Positive | True Positive(TP) | False Negative(FN) |
| | Negative | False Positive(FP) | True Negative(TN) |

この混同行列の数値を用いて学習結果の評価指標として、Accuracy (正解率), Precision (適合率), Recall (再現率), F1-score の値を求めることができる。いずれも値が 1.0 に近いほど良い結果であると言える。以下にそれぞれの概要と計算式を示す。

Accuracy は、深層学習の予測結果全体がどれほど真値と一致しているかを表す指標である。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

Precision は、深層学習が陽性と予測した結果の中で、真陽性が占める割合を表す指標である。この値は、予測の確実性を上げたい場合に重要視される。

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

Recall は、真値が陽性のものの中で、真陽性が占める割合を表す指標である。すなわち、異常検

知のような取りこぼしを抑えたい場合に重視される評価量で、偽陽性を許容できる場合に利用される。

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

次に、Precision と Recall はトレードオフの関係にあるため、その調和平均を計算することでバランスを重視した指標が F1-score である。

$$F1 - score = \frac{2 * TP}{2 * TP + FP + FN} \quad (9)$$

これらの指標を利用して、学習させたニューラルネットワークの評価がなされる。

クラス分類とは、与えられた GPR の画像データを 3 種類以上のクラスに分類する問題である。ここでは空洞、埋設管、それ以外の 3 種類の分類問題を考える。この場合、二値分類とは評価の仕方が若干異なるが、混同行列を用いて同様に計算することが可能である。具体的には、各クラスに対する TP, TN, FP, FN を計算して、それらの値からクラスごとの指標が算出できる。次に全体としての学習効果を知るために、クラスごとではなくそれらの平均値が計算できる (マクロ平均)。m クラス分類問題の混同行列を C とした場合、Accuracy, Precision, Recall, F1-score は以下に示すような式で表される。

$$Accuracy = \frac{\sum_{i=1}^m C_{ii}}{\sum_{i=1}^m \sum_{j=1}^m C_{ij}} \quad (10)$$

$$Precision_i = \frac{TP_i}{TP_i + FP_i} = \frac{C_{ii}}{\sum_{j=1}^m C_{ji}} \quad (11)$$

$$Precision_{macro} = \frac{1}{m} \sum_{i=1}^m Precision_i \quad (12)$$

$$Recall_i = \frac{TP_i}{TP_i + FN_i} = \frac{C_{ii}}{\sum_{j=1}^m C_{ij}} \quad (13)$$

$$Recall_{macro} = \frac{1}{m} \sum_{i=1}^m Recall_i \quad (14)$$

$$F1 - score_i = \frac{2(Precision_i \times Recall_i)}{Precision_i + Recall_i} \quad (15)$$

$$F1 - score_{macro} = \frac{1}{m} \sum_{i=1}^m F1 score_i \quad (16)$$

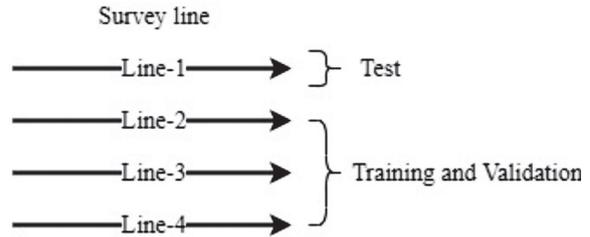


図7 同一道路を複数回観測した状況.

7. 適用結果

7.1 2クラス分類の場合

まず地下に空洞が存在するかどうかの2クラス分類問題として深層学習を適用した. 既往研究との結果の比較を行うために, 作成したデータセットは伊東ほか (2021) と同様のサイズを用いた. 1つのチャンネルにおいてイベントを読み取った座標を中心とした 65×65 の2次元断面図を基準とし, その座標における20チャンネル分のボリュームデータ, つまり $65 \times 65 \times 20$ の3次元データを作成した (図6参照).

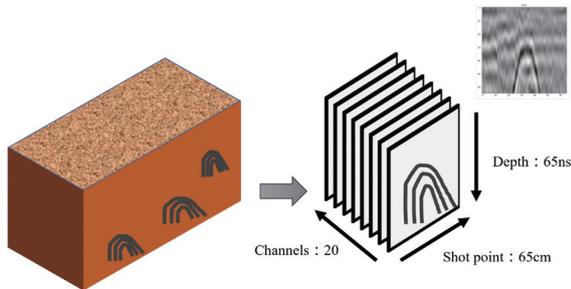


図6 3D-CNNのデータセット作成法.

今回使用したデータは同じ場所を4回測定したテストデータを利用した. モデルの訓練データと検証データには3測線分のデータを使用し, 残りの1測線はテスト用のデータとした (図7). 作成したそれぞれのデータ数を表4に示す. 訓練データと検証データは8:2の割合でランダムにデータの重複がないように分割してモデルの学習を実施した.

バッチサイズは2とし, 最大エポック数を100

表4 訓練・検証とテストデータ数.

| | Events | None | Total |
|-----------------|--------|------|-------|
| Training data | 441 | 682 | 1123 |
| Validation data | | | |
| Test data | 353 | 220 | 573 |

として学習を行った. ただし, エポック数に関しては, 過学習を防ぐために検証データに対する Accuracy (Validation Accuracy) が15エポック間に向上しなければ, その時点で学習を終了とした.

モデルの学習では, 訓練データと検証データそれぞれの Accuracy と Loss の学習曲線を用いて, 学習不足や過学習が起きていないかを確認し, 最適なモデルを検討した. 図8にそれぞれの学習曲線を示す.

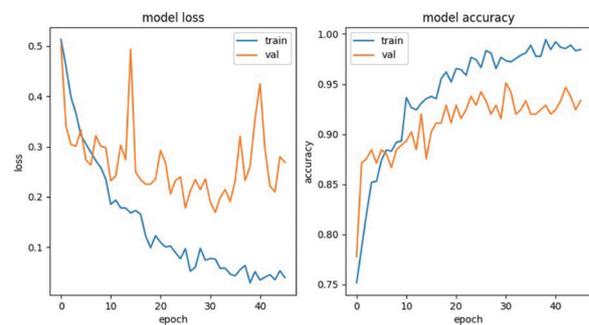


図8 2クラス分類の場合の学習曲線.

学習は45エポックで終了した. すなわち, 30エポック目のモデルが最も成績の良い学習済み3D-CNNモデルと言える. その時の Validation

loss は 0.1903, Validation accuracy は 0.9511 という結果になった. Loss のグラフ (図 8 の左) を見ると, 32 エポック付近から Validation loss が増加傾向へと変化しており, それ以降では過学習が起きていることが示唆される.

このモデルの適用結果を表 5 の混同行列に示す. これを基に学習能力の評価指標を式 (6) から (9) を用いて算出した (表 6 参照).

表 5 2 クラス分類の場合の混同行列の結果.

| | | Predicted | |
|--------|----------|-------------|--------------|
| | | Positive(P) | Negative (N) |
| Actual | Positive | 165 | 55 |
| | Negative | 9 | 344 |

表 6 2 クラス分類の場合の評価指標.

| 学習能力指標 | スコア |
|-----------|--------|
| Accuracy | 0.8883 |
| Precision | 0.8621 |
| Recall | 0.9745 |
| F1-score | 0.9148 |

表 6 の結果を見ると, テストデータに対する Recall が 0.9745 であった. GPR データ解釈において, イベントを見逃さないことが非常に重要であるため, この結果は良好であると言える. また, 伊東 (2021) では, 同じデータセットに対して 2D-CNN を利用している AlexNet を用いた学習を行っているが, テストデータに対する結果を比較すると, 本研究で学習した 3D-CNN のイベント検知能力のほうが良好な結果を得ることができている (表 7 参照). これらの結果は 3 次元 GPR データに対しては, 2D-CNN を用いた疑似 3 次元解析よりも, 3 次元畳み込みを行う

3D-CNN を用いた手法が有用であることを表している.

表 7 伊藤ほか (2021) の結果と今回の結果の比較.

| | Accuracy | Precision | Recall | F1-score |
|-------------------------------------|----------|-----------|--------|----------|
| 3D-CNN | 0.8883 | 0.8621 | 0.9745 | 0.9148 |
| Depth cross-section (伊藤ほか, 2021) | 0.85 | 0.88 | 0.73 | 0.8 |
| Depth slice (伊藤ほか, 2021) | 0.8 | 0.6 | 0.86 | 0.82 |

7.2 3 クラス分類の場合

次に複数チャンネル間に渡って存在する空洞の特徴も, 学習可能である 3D-CNN の性質を活かして, GPR データに現れるイベントに対して 3 つのクラス (空洞, 埋設管, イベント無) に分類する問題を考えることにする. 空洞と埋設管が作り出す GPR の反射波の特徴は, 1 つのチャンネルデータの断面では区別がつかないが, 20 チャンネル分を俯瞰することで, 両者の違いは認識できる点にある. 形状ごとの分類が可能であれば, GPR データ解析にかかるコストを大幅に減らすことが可能になり, 解析作業時間を短縮することができる.

深層学習を行う前に, GPR データに対してイベント位置の深度スライス画像と横断面画像を見て, イベント形状を判断しラベル付けを行い, 学習データを用意した. 学習に利用したそれぞれのデータ数を表 8 に示す.

表 8 3 クラス分けの場合の訓練・検証とテストデータ数.

| | Cavity | Pipe | None | Total |
|-----------------|--------|------|------|-------|
| Training data | 265 | 176 | 682 | 1123 |
| Validation data | 202 | 151 | 220 | 573 |

学習モデルは、出力するクラス数を3クラスに変更し、さらに損失関数を binary crossentropy から categorical crossentropy, 出力層の活性化関数を sigmoid から softmax に変更した。

学習曲線を図9に示す。学習は26エポックで終了した。11エポック目のモデルが学習済み3D-CNNモデルとして保存され、その時の Validation loss は 0.3328, Validation accuracy は 0.9067 という結果を得た。Loss のグラフ (図9の左) を見ると、12エポック付近から Validation loss が増加傾向へと変化しており、過学習が起きていることが示唆される。

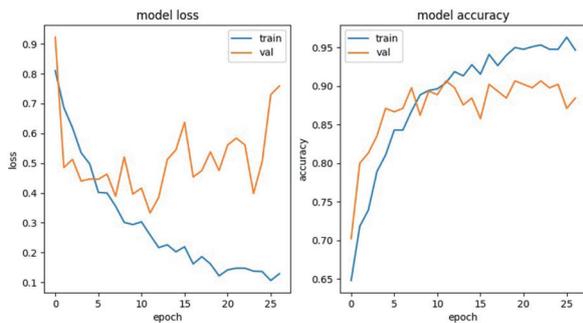


図9 3クラス分類の場合の学習曲線。

3D-CNN を用いた3クラス分類の深層学習の混同行列の結果を表9に示す。さらにこれらの値を基に、式(10)から(16)を用いて算出した学習モデルの評価結果のうち、マクロ評価指標を表10に、クラス別評価指標を表11に示す。

表9 3クラス分けの場合の混同行列の結果。

| | | Predicted | | |
|--------|--------|-----------|--------|------|
| | | None | Cavity | Pipe |
| Actual | None | 199 | 21 | 0 |
| | Cavity | 24 | 104 | 74 |
| | Pipe | 1 | 11 | 139 |

表10 3クラス分けの場合の評価指標 (マクロ平均)。

| 学習能力指標 | スコア |
|-----------|--------|
| Accuracy | 0.7783 |
| Precision | 0.7722 |
| Recall | 0.7847 |
| F1-score | 0.7684 |

表11 3クラス分けの場合のクラス別評価指標。

| | Precision | Recall | F1-score |
|--------|-----------|--------|----------|
| None | 0.83 | 0.91 | 0.87 |
| Cavity | 0.76 | 0.54 | 0.64 |
| Pipe | 0.72 | 0.9 | 0.8 |

3クラス分けの場合の学習曲線における Validation accuracy は図9のように良好であったが、テスト時におけるマクロ平均を用いた学習モデルの総合的な評価では、表10に示すように、どの評価指標も0.8以下であり、決して良好な結果とは言えない値となった。この理由は学習用データに対しては過学習が生じ始めていることと、学習と検証用のデータが少ないことが考えられる。

また表11に示すクラス別の評価指標を見ると、空洞 (Cavity) に対する識別能力が低くなっている。地下に存在する空洞の大きさや形は様々であるため、埋設管 (Pipe) に比べて分類が難しくなっていると考えられる。今後、空洞と埋設管の識別に対する認識精度を高めるためには、より多くの学習データが必要であると言える。

8. まとめ

本研究は、GPR 探査データを3次元のボリューム画像とみなし、深層学習モデルを用いることで地下での対象物の自動認識が可能であることを示した。従来のGPRデータにおける深層学習の適用では、3次元GPRデータに対しても、断面画像における2次元の解析手法が用いられていた。今回は3次元畳み込みを用いた3D-CNNを利用することで、GPRデータ解析にとって重要な埋設物や空洞によるイベントの存在有無を十分な認識精度で判定可能であること、さらに、対象の形状による分類の可能性も示せた。さらに本研究では、スーパーコンピュータのような大型の計算機を用いておらず、多大なコストをかけずに実施できることも利点である。

本研究で用いた学習データセットではデータ量が不足しており、今後の発展には効率的に学習データの収集を行い、データ不足を解決する必要がある。しかし、GPR探査によって大量のデータが取得されているが、探査が行われた場所の地下構造や、確認されたイベントが何であるかといった情報が照合されておらず、学習データとして扱えるものは僅かである。深層学習を用いたGPRデータの解析は非常に有用なアプローチではあるが、学習データの作成方法を確立しなければ、データ不足が大きな問題として残り続けると考えられる。

教師あり学習では、アノテーションが必要となるが、GPRに限らず地下構造を対象にする場合、アノテーションのコストは膨大であり、教師あり学習に不向きであると考えられる。そこで、少数のラベル有りのデータと多数のラベル無しデータによって構成された学習データセットを用いる半教師あり分類問題として定式化することで

(Sakata et al., 2017)、アノテーション作りに必要となるコストとデータ量不足の問題を解決することができる可能性がある。これらは今後の課題である。

謝辞

本研究を進めるに当たっては、深田地質研究所の磯真一郎博士から有益なご意見を頂きました。また株式会社カナンジオリサーチ様からは、本研究で使用したデータを借用した。ここに記して心より感謝の意を表します。

文献

- Chollet, F. (2022): Pythonによるディープラーニング。巢籠悠輔訳，マイナビ出版，199–236.
- Francke, J. (2020): The magic of GPR – a brief history of hype, specsmanship and misunderstanding, 18th International Conference on Ground Penetrating Radar, 14–19.
- Fukushima, K. and Miyake, S. (1982): Neocognitron: A new algorithm for pattern recognition tolerant of deformations and shifts in position. *Pattern Recognition*, **15** (6): 455–469.
- 原 徹夫・坂山利彦 (1984) : 地下レーダーによる地下構造探査. 応用地質, **25**, 31–37.
- Ishitsuka, K., Iso, S., Onishi, K. and Matsuoka, T. (2018): Object detection in ground-penetrating radar images using a deep convolutional neural network and image set preparation by migration, *International Journal of Geophysics*, doi:org/10.1155/2018/9365184
- 磯 真一郎・石塚師也・尾西恭亮・松岡俊文 (2019) : カラー画像化された地中レーダに対する深層

- 学習. 物理探査, **72**, 68–77.
- 伊東快起・東 宏幸・小田義也・松岡俊文・篠原潤 (2021) : 3次元 GPR データへの深層学習によるイベント検知の試み. 物理探査学会学術講演会講演論文集, **144**, 133–136.
- Krizhevsky, A., Sutskever, I. and Hinton, G. E. (2012): ImageNet Classification with Deep Convolutional Neural Networks. In Pereira, F., Burges, C. J., Bottou, L. and Weinberger, K. Q. editors, *Advances in Neural Information Processing Systems*, Curran Associates, **25**, 1097–1105.
- 桑野玲子・佐藤真理・瀬良良子 (2010a) : 地盤陥没未然防止のための地盤内空洞・ゆるみの探知に向けた基礎的検討. 地盤工学ジャーナル, **5**(2), 219–229.
- 桑野玲子・堀井俊孝・山内慶太・小橋秀俊 (2010b) : 老朽下水管損傷部からの土砂流出に伴う地盤内空洞・ゆるみ形成過程に関する検討. 地盤工学ジャーナル, **5**(2), 349–361.
- Liu, H., Shi, Z., Li, J., Liu, C., Meng, X., Du, Y., and Chen., J. (2021): Detection of road cavities in urban cities by 3D ground-penetrating radar, *Geophysics*, **86**(3), WA25–WA33.
- Mukunoki, T., Numano, N., Otani, J. and Kuwano, R. (2009): Visualization of three dimensional failure in sand due to water inflow and soil drainage from defective underground pipe using X-ray CT, *Soils and Foundations*, **49**(6), 959–968.
- 岡谷貴之 (2022) : 深層学習 改訂第2版. 講談社, 77–124.
- Sakai, T., Plessis, M. C., Niu, G. and Sugiyama, M. (2017): Semi-Supervised Classification Based on Classification from Positive and Unlabeled Data. *Proceedings of the 34th International Conference on Machine Learning*, **70**, 2998–3006.
- Shaw, M.R., Millard, S.G., Molyneaux, T.C.K., Taylor, M. J. and Bungey, J.H. (2005): Location of steel reinforcement in concrete using ground penetrating radar and neural networks, *NDT & E International*, **38**(3), 203–212.
- 総務省 (2017) : 地中レーダー技術に関する調査検討会報告書, 6–7
http://www.soumu.go.jp/main_content/000477180.pdf, (2022年1月13日閲覧).
- 竹内大輔・深谷 渉・宮本豊尚・横田敏宏 (2017) : 下水道管路の異常と道路陥没の関係性, 土木技術資料, **59**(3), 30–33.
- 鳥取稔平・東 宏幸・小田義也・松岡俊文・浴 信博・川本悠司 (2021) : 3次元 GPR データへの深層学習によるイベント検知の試み その2, 物理探査学会学術講演会講演論文集, **145**, 117–120.
- Yoon, J., Youm, M., Park, S. and Kim, J. (2020): Technique for detecting subsurface cavities of urban road using multichannel ground-penetrating radar equipment. *Sensors and Materials*, **32**(12), 4413–4427.
- Zunair, H., Rahman, A., Mohammed, N. and Cohen, J. P. (2020): Uniformizing techniques to process CT scans with 3D CNNs for tuberculosis prediction. *Predictive Intelligence In Medicine*, 156–168.