

地表付近の地下速度構造の推定

菊池 愛子* 木村 春里*

Estimation of Near Surface Ground Velocity Structure

Aiko Kikuchi* and Harusato Kimura*

地盤内部の速度構造については従来より地震波の計測値を用いた走時トモグラフィーやフルウェイブインバージョンなどにより広域地盤の速度構造の推定が行われてきた。一方、最近では地下の陥没事故などが頻発しており、浅部地盤の構造を推定するニーズが高まっている。しかし地表付近の地盤においては横波速度の影響が大きいため音響的なアプローチでは不十分で、有限要素法や有限差分法等を用いて弾性方程式を解く必要があると考えられる。またフルウェイブインバージョンでは初期の速度構造地盤の応答を観測波形と比較しながら残差を最小化する速度構造を求める逆解析が行われているが、多大な計算負荷や初期値依存性、局所解に陥る問題が指摘されている。本報ではこの問題の解決のために有限要素法による地震波動解析と CNN による機械学習の組み合わせで地表の地震波から地下の構造を逆推定することを試みた。その結果、地下の地層境界や空孔の形状の推定に、この手法が有効であることを見出した。

<https://doi.org/10.69290/j.001176-vol32>

Keywords: 地震波動解析、CNN、機械学習、表層地盤、速度構造、地層境界、陥没孔

1. はじめに

現在、有限要素法 (FEM) による解析は広く浸透し、構造物や機械製品の健全性評価に威力を発揮しているが、入力データ準備に対する多くの工数、計算に多大な時間が必要となるため、限られたケースで実施されているのが実態である。また計算ケースは個別の条件の結果にすぎず、設計変更や経年変化があれば、その都度、新たな解析を実行する必要が発生する。そのため実際のモデルの状態を逆推定する場合は、多くのパラメタスタディが必要となり、パラメタ数が多ければ、その実施すら不可能となる。

しかし図 1 に示すように FEM の構造パラメタと計算結果の関係を事前に機械学習させておけば、構造モデルのパラメタの逆推定や任意条件のモデルの応答が短時間で予測可能となると予想される。今回の地盤速度構造の推定はその一

つの例として実施したものである。

今回採用した畳み込みニューラルネットワーク (CNN) は、画像認識の分野で極めて有用で、具体的には分類や回帰に使用されている。回帰では地下構造や構造内部のき裂などと表面での振動情報などを結び付け、見えない形状などを逆推定する問題に適用できると思われる。この学習モデルの訓練には多くの教師データが必要となるが、実現象で十分なデータをとることは困難なため、FEM (Advance/FrontSTR を使用) でデータを生成した。

まず工学的基盤と堆積層で構成されるような二層地盤の境界形状の推定を試みた。推定結果は良好で、この手法の有効性が確かめられた。そこでさらにこの手法を用いて地盤内に存在する空孔の形状推定を行い、これについても有益な結果を得ることができた。

*アドバンスソフト株式会社 第2事業部

2nd Computational Science and Engineering Group,
AdvanceSoft Corporation

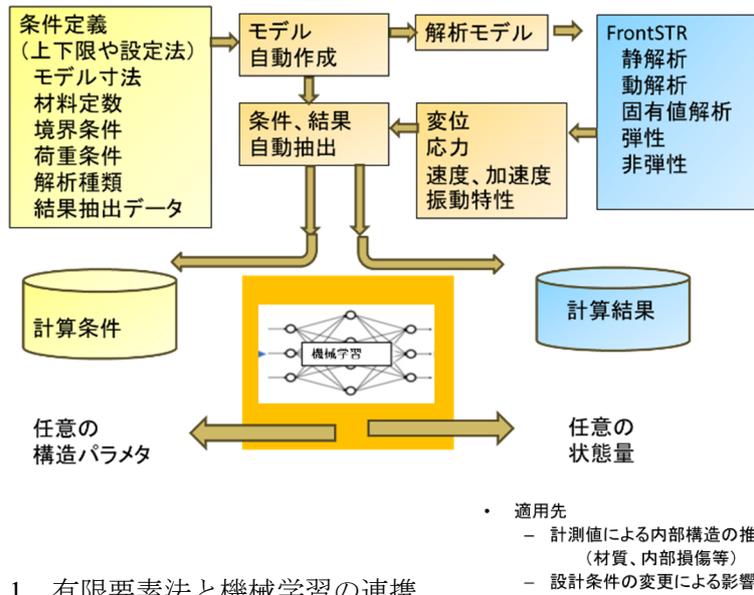


図 1 有限要素法と機械学習の連携

2. 解析概要

解析対象とする地盤は深さ 24m の地表付近を選ぶ。地表付近は表面波が大きいので、P 波のみならず S 波の影響が大きいと考えられる。地震波動解析を行うプログラム Advance/FrontSTR は両者を考慮している。

解析のイメージを図 2 に示す。地盤の地表の中央に中心周波数 1.5Hz のパルスを与え、地表面に並べたセンサー（リニアアレイ）の観測記録から境界面の形状を逆推定することを試みる。つまり地盤の構造を人工的に起こした弾性波に対する地表面の応答から推定する問題である。

地表面の応答は 2m 間隔の 25 個のセンサーで計測される。この応答は地盤の速度構造により異なるが、計測値から速度構造を直接求めることはできないため、CNN による学習を用いて速度構造を推定する。

まず仮定した速度構造に対する地表面の応答を FEM で多数のケースについて求め、これを教師データとして地下の速度構造と地表面の応答の関係を学習する。学習させた CNN を用いて実際に観測された地表面の応答から地盤の速度構造を求める。仮定した速度構造を表 1 に示す。

3. 解析手法

3.1. 地震波動解析

Advance/FrontSTR は 3 次元不均質構造における波動場の計算を行うプログラムである。線形問題として取り扱うことができる微小変形を仮定すると、解くべき弾性波動方程式は以下となる。

$$\begin{aligned}
 \rho \frac{\partial^2 u_x}{\partial t^2} &= \frac{\partial \sigma_{xx}}{\partial x} + \frac{\partial \tau_{xy}}{\partial y} + \frac{\partial \tau_{xz}}{\partial z} + f_x \\
 \rho \frac{\partial^2 u_y}{\partial t^2} &= \frac{\partial \tau_{xy}}{\partial x} + \frac{\partial \sigma_{yy}}{\partial y} + \frac{\partial \tau_{yz}}{\partial z} + f_y \\
 \rho \frac{\partial^2 u_z}{\partial t^2} &= \frac{\partial \tau_{xz}}{\partial x} + \frac{\partial \tau_{yz}}{\partial y} + \frac{\partial \sigma_{zz}}{\partial z} + f_z
 \end{aligned} \tag{1}$$

応力-ひずみ関係（Hooke の法則）は

$$\begin{aligned}
 \sigma_{xx} &= (\lambda + 2\mu) \varepsilon_{xx} + \lambda (\varepsilon_{yy} + \varepsilon_{zz}) \\
 \sigma_{yy} &= (\lambda + 2\mu) \varepsilon_{yy} + \lambda (\varepsilon_{xx} + \varepsilon_{zz}) \\
 \sigma_{zz} &= (\lambda + 2\mu) \varepsilon_{zz} + \lambda (\varepsilon_{xx} + \varepsilon_{yy}) \\
 \tau_{xy} &= \mu \varepsilon_{xy} \\
 \tau_{xz} &= \mu \varepsilon_{xz} \\
 \tau_{yz} &= \mu \varepsilon_{yz}
 \end{aligned} \tag{2}$$

と書ける。ここに、 $u_i, \sigma_{ii}, \tau_{ij} (i, j = x, y, z)$ は変位および応力、 f_i は i 点に作用する等価な体積力、 λ, μ は Lamé 定数を表し、質量密度 ρ とすれば、P 波と S 波の速度から求められる。

$$\lambda = \rho (V_p^2 - 2V_s^2) \quad \mu = \rho V_s^2 \tag{3}$$

表 1 地盤の条件

区分	項目	仕様	備考	
1	材質	土壌	伝搬速度 $V_p=387\text{m/S}$ $V_s=195\text{m/S}$	$E=2.128 \times 10^8 \text{ Pas}$ $\nu = 0.33$ $\rho = 2000 \text{ kg/m}^3$
		風化岩	$V_p=1171\text{m/S}$ $V_s=717\text{m/S}$	$E=2.4696 \times 10^9 \text{ Pas}$ $\nu = 0.20$ $\rho = 2100 \text{ kg/m}^3$

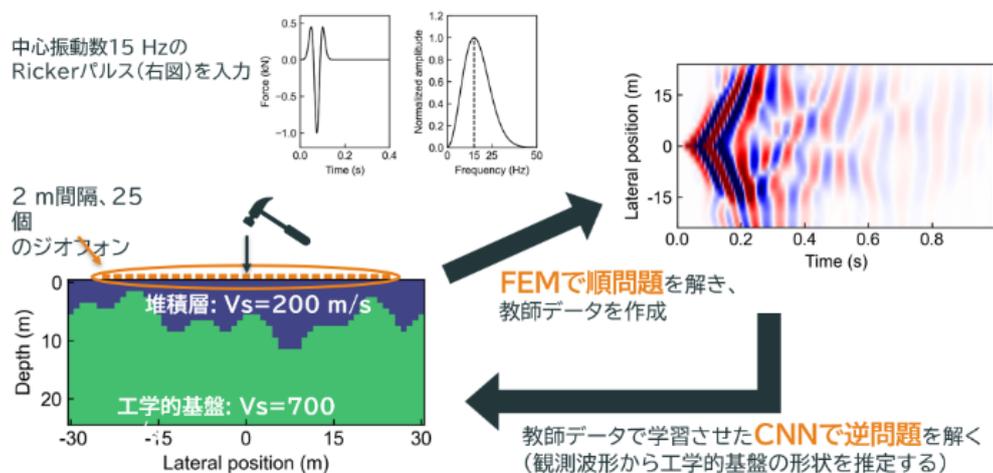


図 2 地盤速度構造の逆推定モデル

3.2. 学習モデル

CNN による学習モデルは一連のネットワーク層で構成される。各層の構成を図 3 に示す。図上部の分布図は地表面の位置における振動速度の履歴を表している。縦軸が地表面の位置を表し、横軸は時間を表している。地表面中央に振動速度パルスを与えており、中央から離れるほど、振動の伝わる時刻が遅れることになる。

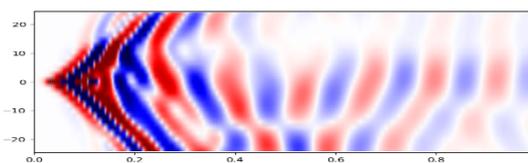
図下部の分布図は地盤の速度構造を表している。FEM の順解析によって地盤の速度構造から地表面の振動履歴が求められ、これにより多数の地盤の速度構造と地表面の応答波形のペアが準備できる。

学習時には地表面の振動速度波形の入力から地盤内の速度構造を出力として、CNN 畳み込みニューラルネットワークを学習する。学習プログラム

は PyTorch を用いて作成した。

ネットワーク層は文献[1]に提案されたものをほぼそのまま使用している。ただし計算処理の簡素化のために地盤の速度構造については要素中心の値ではなく節点値を使用(24×60 ではなく 25×61) している。

最初の第 1 層は地表面の点数 25×計測時間数 400 の振動履歴のデータに、最後の層は地盤の節点における速度の分布に相当する。



	Layer	Process	input	output	kernal_size
Encoding In Time	1	Conv2d	25×400×1	25×398×32	1,3
		MaxPool2d	25×398×32	25×132×32	1,3
	2	Conv2d	25×132×32	25×130×32	1,3
		MaxPool2d	25×130×32	25×43×32	1,3
	3	Conv2d	25×43×32	25×41×64	1,3
		MaxPool2d	25×41×64	12×13×64	2,3
Encoding In Time&Space	4	Conv2d	12×13×64	10×11×128	3,3
		MaxPool2d	10×11×128	5×5×128	2, 2
	5	Conv2d	5×5×128	3×3×128	3,3
Flattern		3×3×128	1152	—	
reshape		Linear	1152	1525	—

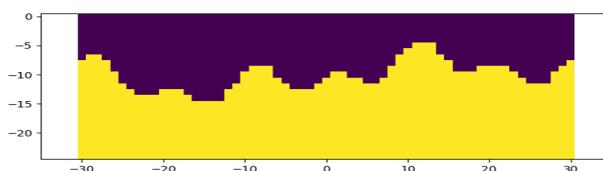


図3 学習モデル (CNN 各層の構成)

4. 地層境界の推定

地盤はS波速度が大きい工学的基盤とその上の柔らかい堆積層の2層構造で構成されていると仮定する。事前に多数の地盤モデルを生成し、弾性波動解析することにより地盤の速度構造と地表の速度履歴との関係を学習する。その後、与えられた地表面の観測波形により地盤内部の側御構造を推定する。

この図は黒い矢印の位置で地盤を加振した時の加振初期の速度コンタを表している。速度のコンタが放射状の円形ではなくゆがんでいるのは近傍に地層の境界がある影響を示している。

計算条件を表2に示す。時間積分にはNewmarkのβ法を使用した。地盤の減衰はRayleigh減衰で与え、5Hzと2.5Hzで減衰比2%となるよう設定している。

4.1. 地震波動解析 (順問題)

今回の地盤は2Dモデルとし、400m×24mの地盤領域に対し1秒間の地震波動解析を行う。400mのうち中央の60mが速度構造を推定する対象領域である。(図4の黒枠で囲まれた領域)

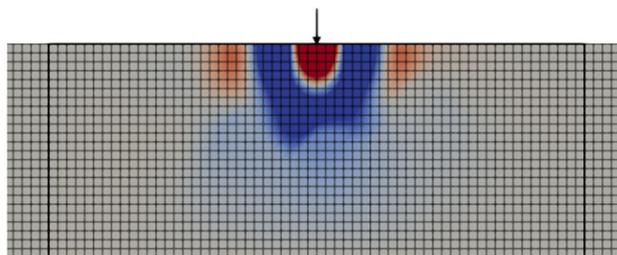


図4 地盤モデルと振動の伝搬状況

表 2 解析条件

諸元	仕様
1 計算領域	400m×24m×1S (内 CNN の対象は 60m×24m×1S)
2 離散化間隔	空間方向に 1m、時間方向に 5.0×10^{-4} S
3 時間積分法	Newmark の β 法 ($\beta = 0.25, \gamma = 0.5$)
4 減衰	Rayleigh 減衰 ($\alpha = 0.167, \beta = 0.0133$) 5Hz と 25Hz で 2% とした
5 境界条件	左右両端、下端で固定端 外力は集中荷重として上天中央の節点に入力 今回は 2 次元平面歪問題として解くため、全節点の Z 方向変位を拘束している。

4.2. 教師データの作成

教師データを大量に作る必要があるため、GUI を利用したマニュアル操作ではなく、プログラムによる自動生成を行っている。今回は CLI (コマンドラインインターフェイス) を使って、モデル自動作成、計算実行、データ抽出の一連の処理を行っている。両層の境界線は乱数を利用して設定した。

順解析の自動実行のためには、生成しやすい設定ファイルであること、CLI からの解析ソルバーの実行が容易であることが重要な条件と思われる。Advance/FrontSTR では問題なく実行できる。メッシュや計算パラメータのファイルも同時に生成し、応答を計算、結果の抽出まですべて自動計算している。

図 5 に地震波動解析の入力と出力のデータ例を示す。図は 1000 ケースのテストデータからランダムに抽出した 12 ケースについて示している。

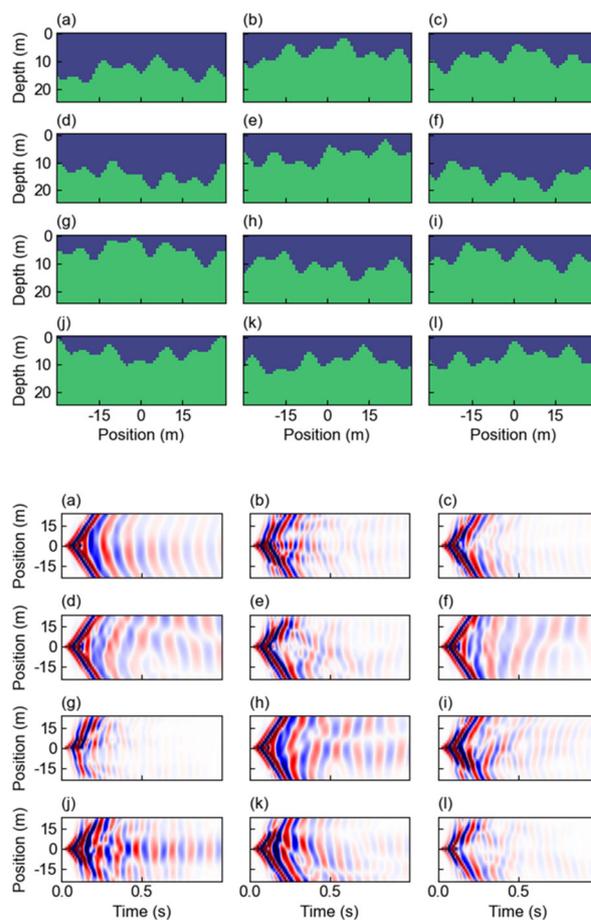


図 5 教師データの作成 (上; 地盤速度構造
下; 地表面の速度応答履歴)

4.3. CNN の学習

4.3.1. 学習の条件と学習誤差

CNN の学習では、Vantassel et al. (2022)を参考に、表 3 のようなハイパーパラメータを設定した。順解析で 6000 ケースの入力と結果のペアデータを取得しており、そのうちの 1000 データを共通のテストデータに設定している。テスト用データを除いたデータから 100 個、500 個、1000 個、5000 個のトレーニング用データを順次、取り出して学習を行った経過の比較を図 6 に示す。

図中の各グラフはエポック数の増加に伴い CNN のネットワークを最適化中の損失関数の推移を示している。青線は学習のエポック数が進む

ごとのトレーニングデータの損失関数の変化を示し、赤の点線は学習した CNN を用いてテストデータを用いて評価テストを行った際の損失関数を示している。

エポックに対する評価テストの損失関数が増加しないことから、過学習にはなっていないことが分かる。トレーニングのデータ数が増加するにつれて最終的な損失誤差は低下し、かつ評価テストの損失誤差も安定していることから、学習結果は妥当であると判断できる。

トレーニングデータ 5000 個による学習の損失誤差は 0.02 と小さい。

表 3 学習の条件

	諸元	仕様
1	バッチサイズ	5
2	学習率	5×10^{-4}
3	エポック数	40
4	オプティマイザ	Adam
5	損失関数	平均自乗誤差 (MSE)

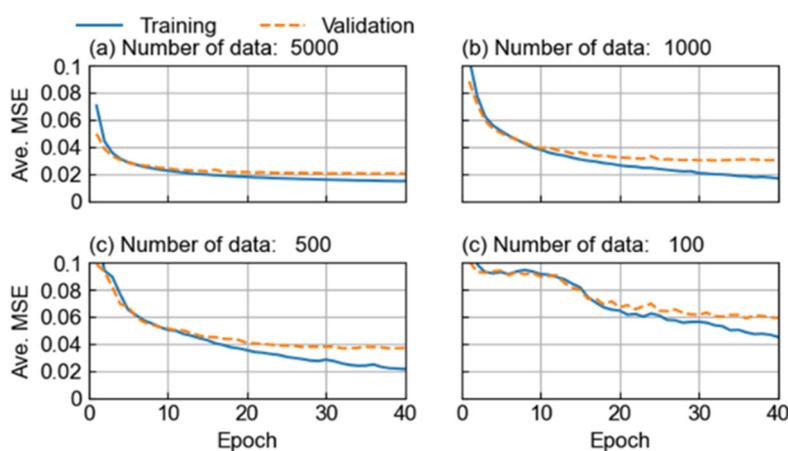


図 6 教師データ数と学習経過の比較

4.4. CNN に推定された速度構造

4.4.1. 地盤の速度構造の正解と推定値

ここでは評価テストを行った地盤の速度構造の正解と推定値を示す。

図 7 は順解析を行った地盤の S 波の速度分布で

ある。これが学習のターゲットである。

図 8 は順解析の結果の地表の振動履歴から、学習済みの CNN を使って推定した地盤の S 波の速度分布である。

堆積層および工学的基盤の V_s の値はそれほど

正確ではないが、工学的基盤の形状の傾向は正しい。また基盤の形状だけでなく、各層内の V_s の擾乱で波形を再現しようとしているように見える。

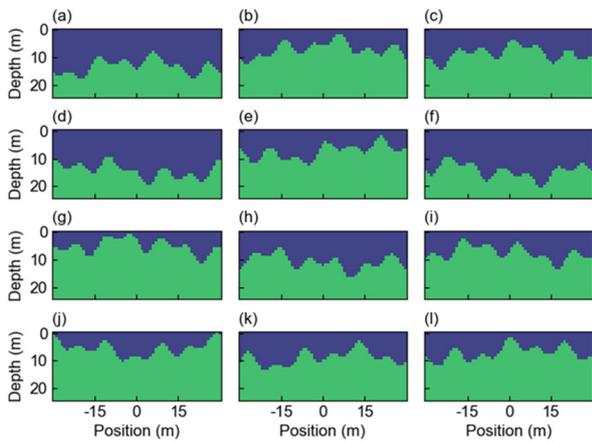


図7 地盤の速度構造 (V_s) ; ターゲットの速度構造 ; 順解析の入力データ

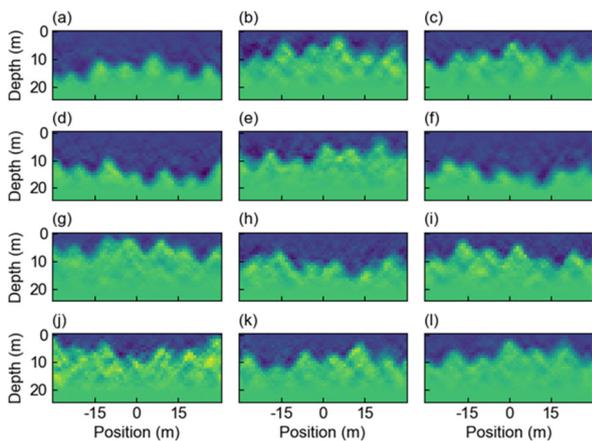


図8 地盤の速度分布 (V_s) ; CNNにより推定された結果

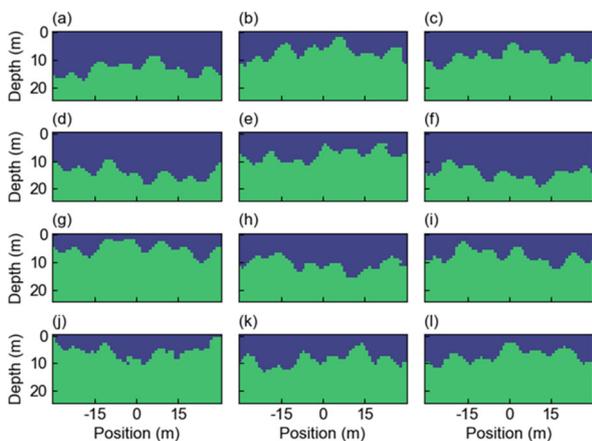


図9 地盤の速度分布 (V_s) ; CNN推定値を二値化した値

CNNにより推定された速度構造を二値化した形状を図9に示す。図7に示した正解である境界線と右のCNNにより求めた境界線の形状がほぼ類似の形状となっていることが分かる。

4.4.2. CNNによる推定値と正解の差

地盤メッシュにおけるCNNの推定値と正解値のS波速度の差を図10に表示する。これはCNNが推定した値そのままによるS波速度の差を示している。赤は推定値が正側に青は負側にずれていることを示す。境界線が最も差が大きい、堆積層内部、工学基盤内部にも、ずれは生じている。ただし差の絶対値は境界線上より小さい。

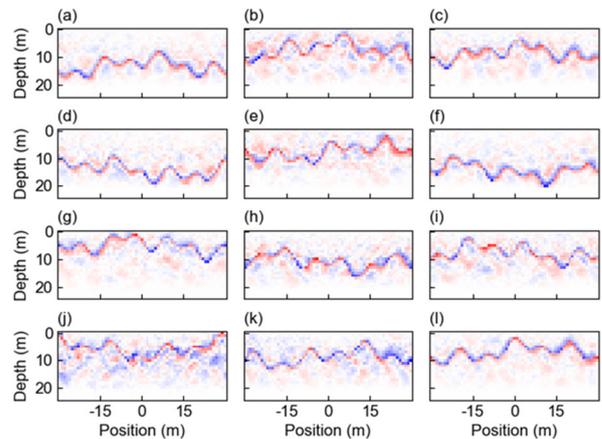


図10 地盤の速度構造 ; 正解値—CNNによる推定値

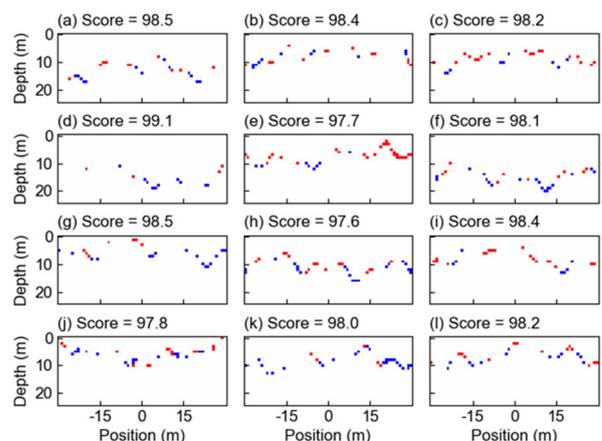


図11 地盤の速度構造 (V_s) ; 正解値—CNNによる推定値 (二値化)

CNN推定値を二値化して求めた境界線形状と

正解値の境界線形状との差を図 11 に表示する。

誤差はほぼ境界線のピクセル上であるが、わずかに一部 2 ピクセルの幅がある箇所もある。1 ピクセルの寸法は 1m 四方であるので、境界線のずれの誤差は 1~2m 以内となる。

Score と表示しているのは地盤全体のピクセルにおける正答率で 97% 以上であることから、S 波速度の推定の誤りは 3% 以内である。

4.5. 結果の評価

今回の問題では CNN による学習は安定的に実施でき、得られた地層境界面の形状は概ね正解と近いものとなった。地表で観測される振動応答から地盤内部の速度構造を推定する本方法は貫入試験などを必要としない点からも有益な方法であると考えられる。

一方、Vantassel et al. (2022) は CNN での逆推定結果が十分な精度を有さないとし、従来の Full waveform inversion (FWI) の初期モデルとして活用するにとどめている。

今回の問題では、CNN で直接に地盤構造を推定しているが、これは対象とする地盤構造を二層地盤に限っているために可能となった可能性も考えられる。しかし地盤の構造が離散的な層により構成されると仮定することは地震工学の分野で

は一般的に受け入れられており、今回採用した堆積層と工学的基盤という区分は単純ではあるものの、十分に現実的であると考えられる。このような単純な構造を扱う場合、CNN 単独での地盤構造の逆推定が可能であることを確認した。また Advance/FrontSTR を用いて教師データを自動生成することにより、教師データの作成にかかる負荷が抑えられることも確認した。

4.6. 計算時間

CNN による地盤推定にかかった時間を表 4 に示す。順解析ソルバーにかかった時間は 1 ケース当たり 250 秒、約 4 分で、全解析ケース 5000 ケースでは 208 時間であった。それに対し、CNN の学習にかかった時間は 5000 ケースで 25 分程度である。

学習より順解析に多大な時間がかかるので、学習する上でも、解析ソルバーの性能が今後、より重要となると思われる。今回は 2 次元の動解析であるため、シリアル計算で対処可能であったが、3 次元の動解析になる場合は並列処理等の利用も必要となると思われる。

学習の後は、解析ソルバーなしに各構造パラメータに対する推定を行なえるので、推定は迅速に行えると思われる。

表 4 計算環境と計算時間

No	諸元	仕様
1	計算機種	CPU : Corei9-13900
2		GPU : Nvidia T1000
3	OS	WSL (Ubuntu 22.04)
4	順解析	Advance/FrontSTR CPU 上でシリアル実行 約 250S/ケース 全ケースで 208 h (8.7 日)
5	学習	PyTorch GPU 上で実行 数分~数十分 教師データ数 5000 で約 25 分

5. 地下の空孔の検出

前章で地盤内部の速度構造を推定する手法で地層の境界形状を求めることができた。ここでは同じく地表付近の地盤を対象にするが、均質な地盤に空孔が発生している状況を想定し、その空孔の位置、寸法を推定する問題を考える。

5.1. 地震波動解析（順解析）

地盤の解析条件を表 5 に示す。地盤メッシュおよび荷重は前章のものを使用した。教師データとしては地盤の材質は標準的な 1 種類とし、地盤の内部に空孔が 1 つあるとした。空孔の形状は楕円形とし、一様乱数を用いて対象領域の任意の位置

に任意の寸法で空孔を設けた。

空孔の材質の特定が難しかったので、 V_p, V_s ともに地盤よりも小さくなるような値を仮に設定した。

5.2. 教師データ

ここでは地震波動解析を全 1000 ケース計算し、そのうち 990 ケースを学習用に、残り 10 ケースを評価テストに用いた。評価データで用いた 10 ケースの地表の振動速度履歴を図 12 に示す。

表 5 地盤の条件

	区分	項目	仕様	備考
1	モデル	地盤メッシュ	前章と同様	
2		荷重条件	前章と同様	
3	ケース	解析ケース数	1000	0~989 をトレーニングデータ 990~999 を評価データ
4	材質	地盤材質	$V_p=387\text{m/S}$ $V_s=195\text{m/S}$	$E=2.128 \times 10^8 \text{ Pas}$ $\nu = 0.33$ $\rho = 2100 \text{ kg/m}^3$
5		空孔材質	$V_p=107\text{m/S}$ $V_s=53.9\text{m/S}$	$E=1.00 \times 10^4 \text{ Pas}$ $\nu = 0.33$ $\rho = 1.293 \text{ kg/m}^3$
6	空孔	中心位置 (水平方向)	X; -20m~20m	
		中心位置 (鉛直方向)	Y; -16.5m~-7.5m	
7		長径	5m~10m	短径は長径の 75%とする

5.3. 学習経過

学習の条件を表 6 に示す。前章のデータと同様とした。学習における損失係数の履歴を図 13 に示す。今回の学習データ数は 1000 に満たず十分とは言えないが、青線で示す訓練データの損失係数は順調に低下している。また赤線で示すテストデータの損失係数はエポック数 40 時点で多少の変動があるものの、その値は 0.02 と小さく、一応の収束が得られていると判断される。

表 6 学習の条件

	諸元	仕様
1	バッチサイズ	5
2	学習率	5×10^{-4}
3	エポック数	40
4	オプティマイザ	Adam
5	損失関数	平均自乗誤差 (MSE)

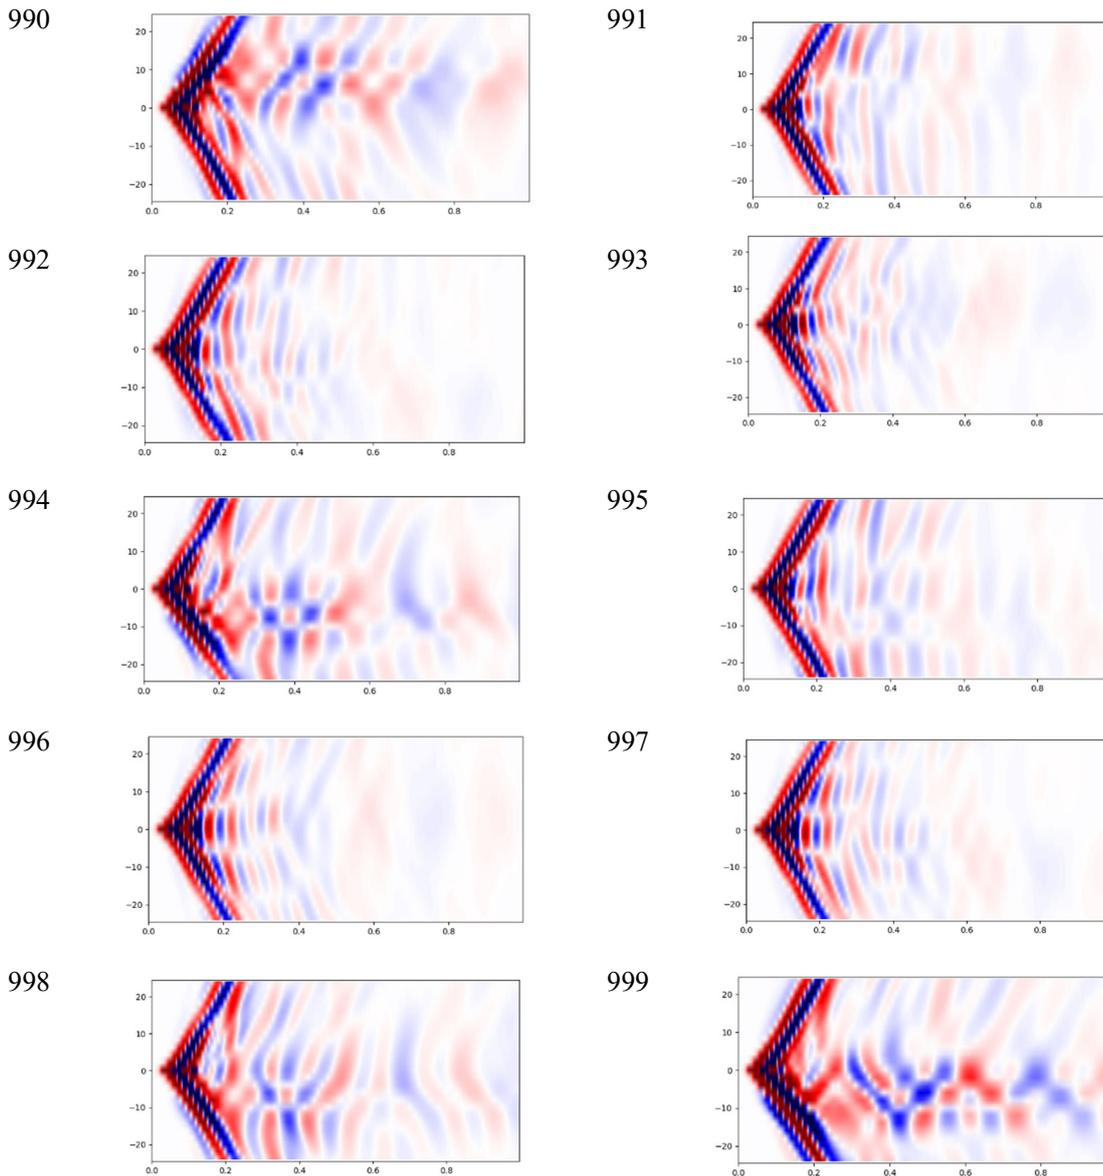


図 12 評価データの作成 (地表面の速度応答履歴)

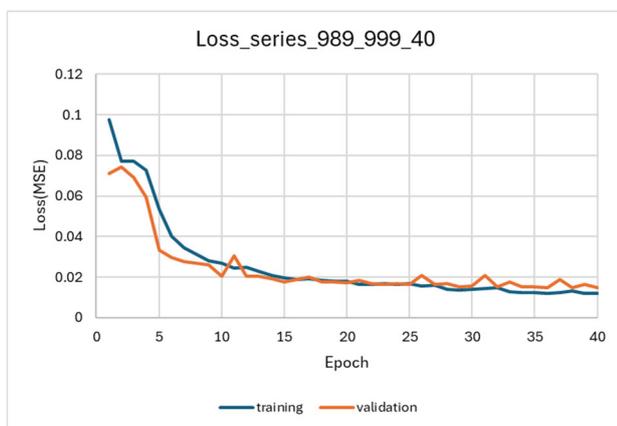


図 13 学習経過

5.4. 学習結果の評価

地盤メッシュにおける S 波速度の CNN による推定値と正解値および両者の差を図 14 に表示する。この図では CNN が推定した値をそのまま示している。正解の穴位置以外にも誤差が存在する。右側の図が誤差を表している。赤は推定値が正側に青は負側にずれていることを示す。穴の境界線上が最も差が大きい。境界線以外にも、ずれは生じているが、その差の絶対値は境界線上より小さい。

一方、S 波速度の CNN 推定値を 2 値化して求めた分布と正解値および両者の差を図 15 に表示する。差はほぼ空孔の境界線のピクセル上にある

が、まれに一部2ピクセルの幅がある箇所もある。1ピクセルの寸法は1m四方であるので、境界線のずれの誤差は1~2m以内となる。

図中に Score と表示しているのは地盤全体のピ

クセルにおける正答率で、Score が 98%以上であることから、S 波速度の推定の誤りは 2%以内であり、推定値は概ね正解の穴形状を近似できていることが分かる。

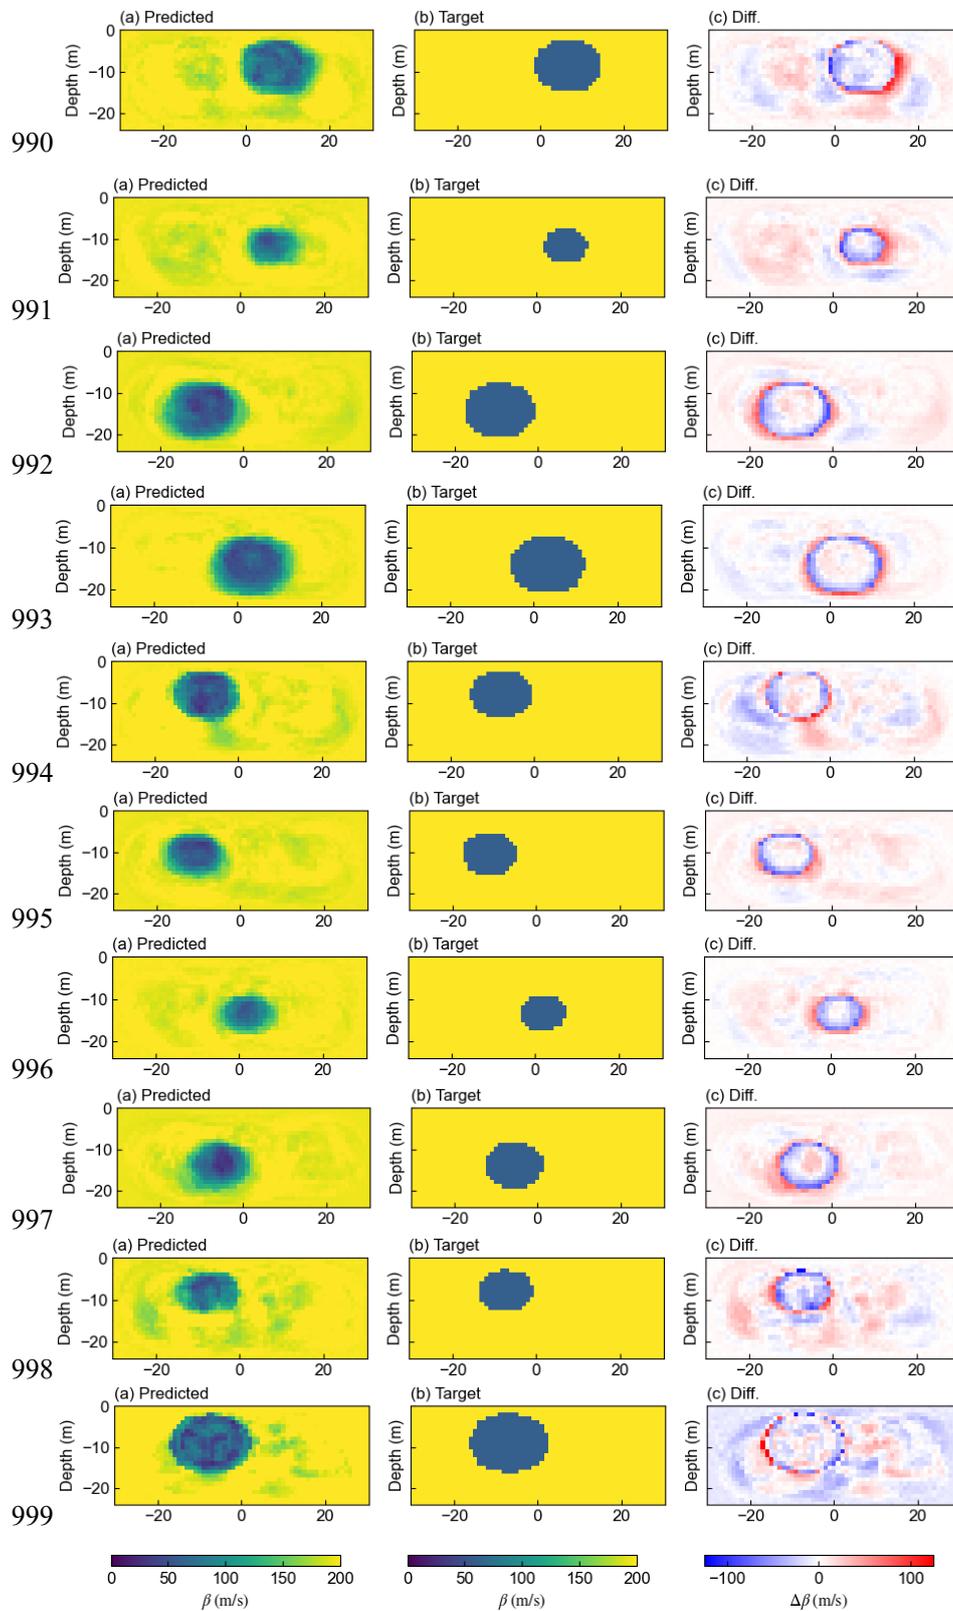


図 14 地盤速度構造 (Vs) の CNN 推定値と正解と両者の差異

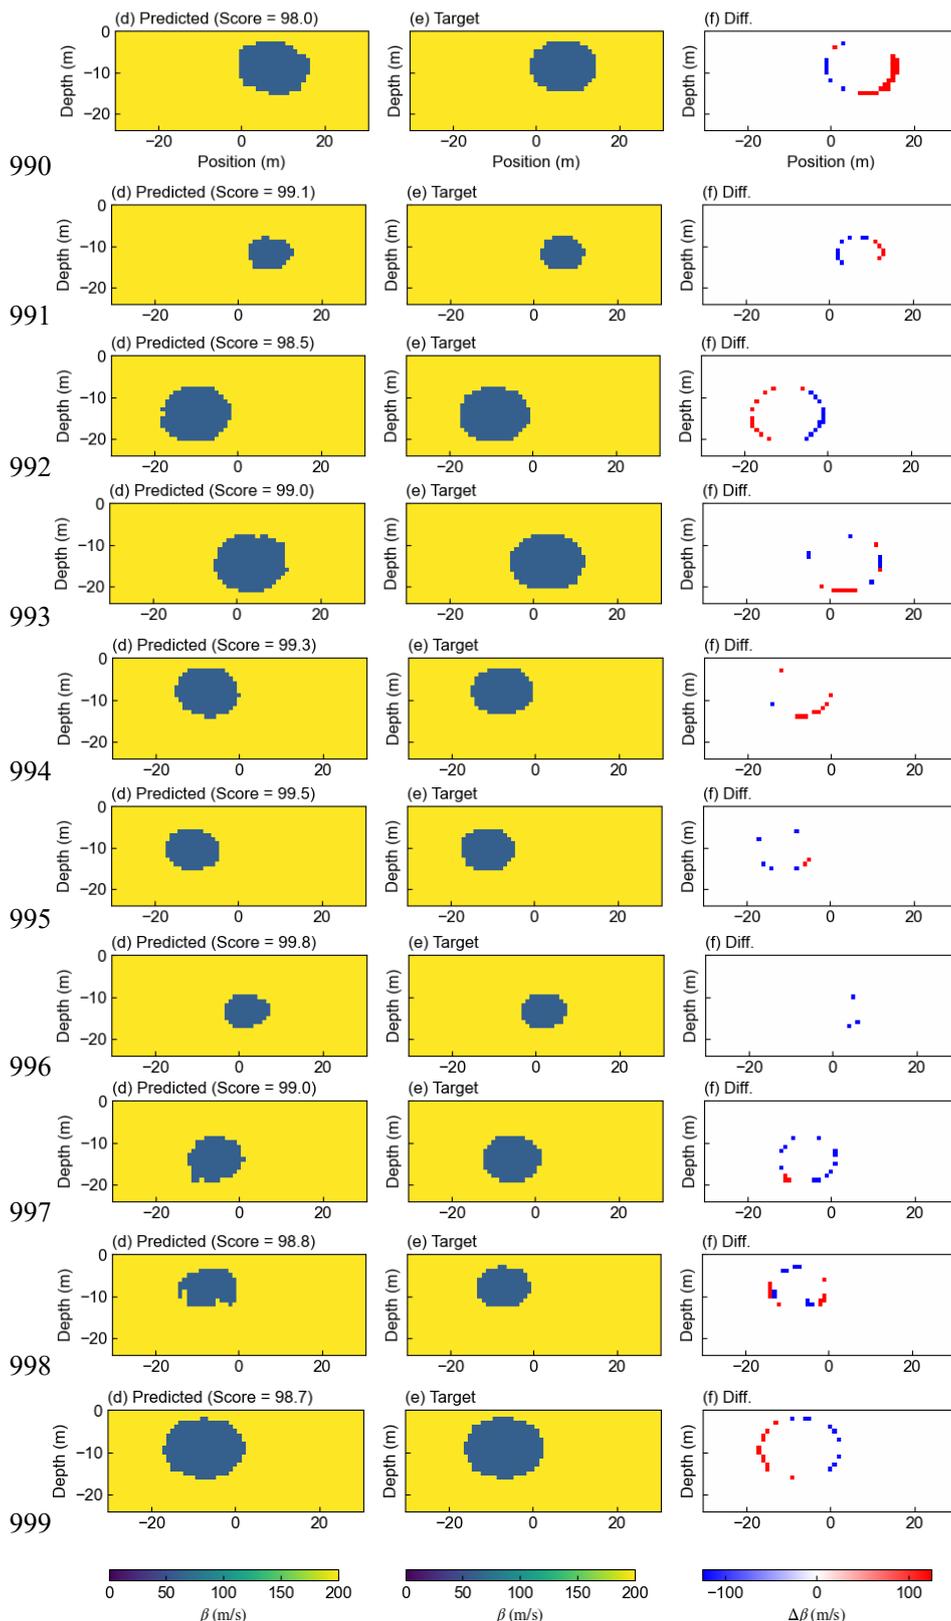


図 15 地盤速度構造 (V_s) の CNN 推定値 (二値化) と正解と両者の差異

6. まとめ

本報では有限要素法と畳み込みニューラルネットワークを用いた機械学習の組み合わせにより地表付近の地盤の速度構造を推定する仕組み

を作り、2 種類の問題に適用して、以下のような結論が得られた。

- (1) FEM (弾性波動解析) で作成した教師データ

で学習した CNN により、地表の観測波形から工学的基盤の形状を逆推定することを試みた。

- (2) 教師データの数が数千程度でも、適切なモデル化を行えば、十分に精度の良い結果を得ることができ、本手法の有効性を確認した。
- (3) 今回の問題では CNN モデルの学習に要する時間（数分から数十分）に比べ順問題を解く時間（数日）の方が明らかに大きく、実際の利用に際しては順問題を解くソルバーの性能がより一層、重要である。
- (4) 上記で確認した手法を用いて地盤内部の空孔の検出に適用したところ、空孔の形状をほぼ把握することができた。
- (5) 今回対象とした問題と類似している、地下構造探査や構造物のモニタリングの問題についても FEM と CNN を組み合わせるアプローチは有効と思われる。

※ 技術情報誌アドバンスシミュレーションは、それぞれの文献タイトルの下に記載した DOI から、PDF ファイル（カラー版）がダウンロードできます。また、本雑誌に記載された文献は、発行後に、JDREAMIII（日本最大級の科学技術文献情報データベース）に登録されます。

参考文献

- [1] Joseph P. Vantassel, Krishna Kumar I and Brady R. Cox, Using convolutional neural networks to develop starting models for near-surface 2-D full waveform inversion, *Geophysical Journal International*, (2022) 231, 72-90
- [2] 亀井理瑛、三善孝之、他、陸上屈曲二次元地震記録を用いたフルウェイブインバージョンの適用、*石油技術協会誌* 79 巻、1 号（平成 26 年 1 月） 63-70
- [3] Khiem T Tran, Michael C McVay, Michael Faraone, David Horhota, Sinkhole detection using 2D full seismic waveform tomography, *GEOPHISICS*, VOL. 78. NO. 5 (SEPTEMBER-OCTOBER 2013); P. R175-R183